



Innovación para la gestión del pasto, ATN/RF-18077-RG

Producto 6. Nota técnica: Algoritmos que estiman disponibilidad de pasto a partir de valores de índices multiespectrales tomados con drones en pasturas típicas de los Argentina, Uruguay y Costa Rica.

Juan Insúa, Celina Laplacette, Santiago Utsumi, Kevin Carrillo, Edison Araya, William Sánchez, Nicolás Baráibar, Mariana Rosas, Germán Berone.

2024





Códigos JEL: Q16

ISBN:

FONTAGRO (Fondo Regional de Tecnología Agropecuaria) es un mecanismo único de cooperación técnica entre países de América Latina, el Caribe y España, que promueve la competitividad y la seguridad alimentaria. Las opiniones expresadas en esta publicación son de los autores y no necesariamente reflejan el punto de vista del Banco Interamericano de Desarrollo (BID), del Instituto Interamericano de Cooperación para la Agricultura (IICA), FONTAGRO, de sus Directorios Ejecutivos ni de los países que representan.

El presente documento ha sido preparado por Insua, J.R.^{1 2}; Laplacette, C.M.^{1 2 3}; Utsumi, S.A.⁴; Carrillo, K.⁵; Araya, E.⁵; Sánchez, W.⁵; Baráibar, N.⁶; Rosas, M.⁶; Berone, G.D.^{1 3}.

¹Facultad de Ciencias Agrarias, Universidad Nacional de Mar del Plata, Balcarce, Argentina.

²Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET), Buenos Aires, Argentina.

³Instituto Nacional de Tecnología Agropecuaria, Balcarce, Argentina.

⁴Michigan State University, United States of America.

⁵Instituto Nacional de Innovación y Transferencia en Tecnología Agropecuaria, Costa Rica.

⁶Instituto Nacional de Investigación Agropecuaria, Uruguay.

Copyright © 2024 Banco Interamericano de Desarrollo. Esta obra se encuentra sujeta a una licencia Creative Commons IGO 3.0 Reconocimiento-NoComercial- SinObrasDerivadas (CC-IGO 3.0 BY-NC-ND) (<http://creativecommons.org/licenses/by-nc-nd/3.0/igo/legalcode>) y puede ser reproducida para cualquier uso no comercial otorgando el reconocimiento respectivo al BID. No se permiten obras derivadas. Cualquier disputa relacionada con el uso de las obras del BID que no pueda resolverse amistosamente se someterá a arbitraje de conformidad con las reglas de la CNUDMI (UNCITRAL). El uso del nombre del BID para cualquier fin distinto al reconocimiento respectivo y el uso del logotipo del BID no están autorizados por esta licencia CC-IGO y requieren de un acuerdo de licencia adicional. Note que el enlace URL incluye términos y condiciones adicionales de esta licencia.

Esta publicación puede solicitarse a:

FONTAGRO

Correo electrónico: fontagro@fontagro.org

www.fontagro.org



Tabla de Contenidos

Resumen	6
Abstract	7
Resumen EJECUTIVO	8
Palabras Clave:	8
Introducción	9
Relevancia del problema.....	10
Monitoreo de pasturas	10
Nuevas tecnologías para el monitoreo de pasturas.....	10
Calibración para especies relevantes de Argentina y Uruguay	12
Hipótesis y justificación general de la metodología de trabajo	12
Hipótesis de trabajo:.....	13
Objetivos.....	13
Metodología de trabajo	13
Área de estudio y diseño experimental	13
Planificación de vuelos y procesamiento de imágenes.....	14
Análisis estadístico	14
Resultados.....	15
Calibración NDVI – biomasa.....	15
Curva de calibración NDVI – biomasa en distintos momentos del año	15
Calibración NDVI – biomasa en distintas especies.....	17
Calibración NDVI – biomasa con pasturas de diferente estado nutricional.....	17
Discusión.....	18
Calibración indirecta NDVI – biomasa.....	18



Efecto de la especie en las curvas de calibración.....	19
Efecto del momento del año.....	19
Estado de nutrición nitrogenada	20
Conclusiones y recomendaciones	21
Calibraciones especies relevantes Costa Rica	22
Hipótesis y justificación general de la metodología de trabajo	22
Objetivo	23
Metodología de trabajo	23
Área de estudio y diseño experimental	23
Planificación de vuelos y procesamiento de imágenes.....	24
Análisis estadístico	28
Resultados y discusión	28
Calibración del pasto Bermuda (<i>Cynodon sp</i>)	28
Calibración del Pasto Marandú (<i>Brachiaria brizantha</i>)	31
Conclusiones y recomendaciones	33
Conclusiones generales.....	33
Referencias Bibliográficas	34
Instituciones participantes.....	41



INDICE DE TABLAS

Tabla 1: Curvas de calibración ajustadas para cada fecha de vuelo en ambas especies.	15
Tabla 2. Bandas espectrales de la cámara Micasense Altum serie AL05. Fuente: (MicaSense, 2020).	25
Tabla 3 Índices espectrales utilizados en la investigación para la predicción de biomasa en dos pasturas de Costa Rica.	27

INDICE DE GRAFICOS

Gráfico 1. Efecto de la fecha de vuelo sobre las curvas de calibración NDVI – biomasa para agropiro y festuca.	16
Gráfico 2. Efecto de la especie sobre las curvas de calibración NDVI – biomasa. Ejemplo de dos curvas de calibración NDVI – biomasa para agropiro y festuca en la segunda fecha de vuelo de otoño Año 1 (izquierda) y primavera Año 2 (derecha).	17
Gráfico 3: Efecto de la fertilización sobre las curvas de calibración NDVI – biomasa. Ejemplo de dos curvas de calibración NDVI – biomasa para agropiro (izquierda) y festuca (derecha) con distintos niveles de INN (bajo, medio y alto) para una misma fecha de medición.	18
Gráfico 4. Matriz de correlación entre índices de vegetación y biomasa fresca para el pasto Bermuda.	29
Gráfico 5. Relación entre los índices de vegetación NDRE, CIRE y la biomasa seca pasto <i>Cynodon</i> obtenidos con sensor multiespectral acoplado a un dron, Cañas, Costa Rica.	30
Gráfico 6. Algoritmos de aprendizaje automático evaluados para la predicción de biomasa fresca en pasturas; DT: Árboles de Decisión; KNN: Vecinos más Cercanos; R-SVM: Máquinas de soporte de vectores Radiales; RF: Random Forest; RPL: Regresión penalizada-Lasso.	31
Gráfico 7. Matriz de correlación entre índices de vegetación, biomasa fresca y seca para el pasto <i>Brachiaria</i> , Guápiles, Costa Rica.	32



RESUMEN

Una estimación precisa de la disponibilidad de pasto es esencial para el manejo efectivo del pastoreo y la rentabilidad de los sistemas ganaderos basados en pasturas. Este documento técnico presenta el desarrollo de algoritmos que utilizan índices multispectrales capturados por drones para estimar la disponibilidad de pasto de especies representativas de los tres países participantes. Se realizaron estudios en Argentina y Costa Rica, abarcando diversas especies forrajeras, estaciones y niveles de fertilización nitrogenada. En Argentina, se condujeron experimentos durante dos ciclos de crecimiento en 2021, 2022 y 2023 en Balcarce, evaluando agropiro alargado y festuca alta en parcelas de 6m² con diferente dosis de fertilizante nitrogenado. Se realizaron mediciones durante los rebrotes de primavera y otoño, usando modelos de regresión exponencial basados en 15 vuelos, que mostraron un coeficiente de determinación promedio (R^2) de 0.83 y un error absoluto medio (MAE) de 160 kg MS/ha. El análisis confirmó que la relación entre el NDVI y la biomasa es no lineal y varía según la especie y la fecha sin ser influenciada por el estado nutricional de nitrógeno de las pasturas. En Costa Rica, se estudiaron pasturas de *Cynodon sp* y *Brachiaria brizantha*. Para el caso de *Cynodon sp*, los índices como NDRE y CIRE mostraron una precisión moderada en modelos de regresión simples (R^2 de 0,62 y 0,60 respectivamente), mientras que el modelo de Random Forest (RF), integrando varios índices, alcanzó un R^2 de 0.87. Para *Brachiaria brizantha*, el modelo RF obtuvo un R^2 de 0.62. Los resultados obtenidos en estos trabajos demuestran que el monitoreo de pasturas por drones puede ser más preciso que otros métodos de campo, considerando las especies forrajeras y condiciones estacionales. Futuros desarrollos deben enfocarse en algoritmos que permitan un monitoreo sistemático y preciso de la disponibilidad y utilización de pasto por especie y ubicación usando drones.



ABSTRACT

An accurate estimation of available forage is crucial to the efficient management of grazing systems and profitability of pastoral livestock systems. This technical document presents the development of algorithms that use multispectral indices captured by drones to estimate the grass availability of representative species from the three participating countries. Studies were conducted in Argentina and Costa Rica, covering various forage species, seasons, and levels of nitrogen fertilization. In Argentina, experiments were conducted over two growth cycles in 2021, 2022, and 2023 in Balcarce, evaluating tall wheatgrass and tall fescue in 6m² plots. Measurements were made during the spring and autumn regrowth, using exponential regression models based on 15 flights, which showed an average coefficient of determination (R^2) of 0.83 and a mean absolute error (MAE) of 160 kg DM/ha. The analysis confirmed that the relationship between NDVI and biomass is non-linear and varies according to species and date without being influenced by the nitrogen nutritional status of the pastures. In Costa Rica, pastures of *Cynodon* sp and *Brachiaria brizantha* were studied. For *Cynodon* sp, indices such as NDRE and CIRE showed moderate precision in simple regression models (R^2 of 0.62 and 0.60 respectively), while the Random Forest (RF) model, integrating several indices, reached an R^2 of 0.87. For *Brachiaria brizantha*, the RF model achieved an R^2 of 0.62. Monitoring pasture with drones may offer a similar or greater accuracy compared to other field methods if calibrations considered the effect of forage species and time of year. Future efforts should focus on developing advanced algorithms that can enable the systematic and accurate application of drones in monitoring pasture-level forage availability and utilization on farms.



RESUMEN EJECUTIVO

Los resultados de este proyecto de investigación permitieron confirmar que es posible la cuantificación remota (teledetección) de la biomasa de pasto mediante el uso de sensores multiespectrales montados en un dron. Para ello, la calibración de la curva de predicción biomasa mediante el uso de NDVI debe considerar los efectos de la especie forrajera y fecha de vuelo sin verse afectada por la dosis de fertilizante nitrogenado. Esto implicaría que es necesario calibrar modelos de predicción de biomasa para cada una de las especies forrajeras contemplando recalibraciones en diferentes momentos del año. Este resultado marca la necesidad de futuros trabajos orientados al desarrollo de protocolos de recalibraciones temporales para facilitar la correcta implementación de drones con el fin de mantener la precisión de las estimaciones de pasto a lo largo del año. Esto ofrecería realizar una estimación remota de la biomasa de pasturas más objetiva, rápida y comparable, liberando al personal de rutinas de monitoreo semanal, y permitiendo un virtual manejo remoto de las decisiones de pastoreo. Adicionalmente, los resultados obtenidos en esta línea de I+D mediante el uso de sensores multiespectrales montados en drones podrán complementarse o extenderse a otras plataformas con diferentes prestaciones (e.g. diferentes tipos de drones, satélites) que permitan una mayor cobertura de área de monitoreo para establecimientos de mayor escala. De esta manera, se espera un aumento en la eficiencia de utilización de las pasturas, reduciendo costos de alimentación, con un impacto positivo sobre la productividad, rentabilidad y sostenibilidad de la producción ganadera en escenarios climáticamente cambiantes. Debido a la precisión y resolución de la metodología, se prevé que el monitoreo de pasturas por drones se extienda al ámbito académico/científico como una herramienta aplicable a la investigación.

PALABRAS CLAVE:

Monitoreo de pasturas, NDVI, sensores remotos, VANT



INTRODUCCIÓN

En los sistemas ganaderos de base pastoril se ha demostrado que un eficiente manejo y uso de pasturas produce incrementos directos en la producción de carne o leche a través de una mayor producción del forraje (García et al., 2014) y reducciones en los costos de alimentación, mejorando el margen bruto por hectárea (Fariña et al., 2013). Debido a esto, el éxito de estos sistemas está en producir más pasto y en una alta utilización de este (Chapman, 2016). Para ello, el productor requiere implementar un manejo de pastoreo eficiente basado en ajustes de asignación forrajera que contemplen el consumo de forraje por los animales y los cambios en la tasa de crecimiento de las pasturas. Esto permite corregir la superficie de reservas a ensilar/enrollar cuando la tasa de crecimiento de las pasturas es mayor a la demanda de los animales (*e.g.* primavera), o definir la cantidad de suplemento para cubrir los déficits de pasto cuando la tasa de crecimiento es menor a los requerimientos del rodeo (*e.g.* invierno).

Para lograr ese eficiente uso del forraje a lo largo del año resulta imprescindible realizar un monitoreo sistemático (cada una o dos semanas) de la tasa de crecimiento y disponibilidad de pasto en cada potrero del campo (Fariña et al., 2011; Chapman 2016). En la práctica, esto generalmente no se realiza debido a que las técnicas ‘tradicionales’ para estimar la cantidad de pasto (*e.g.* corte y pesado, estimaciones visuales, medición de altura) demandan gran cantidad de tiempo y trabajo para representar de manera efectiva la variabilidad en un área específica (López-Díaz et al., 2011; Baeza et al., 2011; Martin et al., 2005; Sanderson et al., 2001; Wang et al., 2022). A esta dificultad se le agrega la falta de precisión que conllevan las técnicas o métodos de estimación cuando no son correctamente calibradas para la pastura o el sitio donde se van a utilizar (Ganguli et al., 2000). En Latinoamérica, estos problemas se amplifican en los sistemas de producción extensivos, donde la falta de monitoreo de pasturas está asociada a una baja eficiencia en el uso del pasto y bajos índices productivos.

Por lo dicho anteriormente, se desprende la necesidad de desarrollar tecnologías aplicables al manejo ganadero para poder estimar de forma rápida, precisa y repetible la variación espacial y temporal de la cantidad de pasto. El objetivo general de este trabajo plantea la implementación de teledetección multiespectral mediante Vehículos Aéreos No Tripulados (VANT) o “drones”, para estimar de forma rápida y remota la cantidad de biomasa disponible de pasto.



Relevancia del problema

Monitoreo de pasturas

Los métodos más utilizados para medir pasto se pueden clasificar en métodos directos (corte y pesado de pasto) y métodos indirectos (o no destructivos) como una regla graduada o el plato medidor de pasto (López-Díaz et al., 2011). Para que un método indirecto de estimación de pasto sea confiable debe ser sometido a estudios de calibración en diferentes condiciones de crecimiento (Ganguli et al., 2000; Hernández, 2023). La calibración consiste en ajustar una ecuación con aceptable precisión (i.e. alto R^2) que permite convertir el indicador indirecto de la biomasa de la pastura (e.g. altura, cobertura, índice verde) en los kg de materia seca de biomasa disponible de pasto (kg MS ha^{-1}). Las calibraciones de los métodos suelen ser sitio-específicas debido a que la asociación entre el indicador indirecto y la biomasa de pasto puede cambiar con la estructura de las plantas, las especies forrajeras, la estación del año y la fertilización (López-Díaz et al., 2011).

La relación de la altura (cm) con los kg de materia seca (MS) de la pastura es, junto con la estimación visual, la medida indirecta más utilizada para estimar disponibilidad de pasto a campo (Bazzo et al., 2023). Esta técnica, sin embargo, requiere dedicación y tiempo o variar con el grado de experiencia del observador. Los métodos indirectos también requieren de una cantidad de muestras suficiente (n) para lograr una representación precisa de la disponibilidad de pasto en todo el establecimiento (Ganguli et al., 2000; Hernández, 2023). Por este motivo, resulta imprescindible el desarrollo y calibración de técnicas que estimen de forma fácil, rápida y precisa la cantidad de pasto para mejorar la toma de decisiones en cuanto al manejo del pastoreo y la formulación de la dieta de los animales.

Nuevas tecnologías para el monitoreo de pasturas

En la última década, se ha avanzado en la aplicación de nuevas tecnologías para agilizar y aumentar la precisión de las estimaciones de biomasa, integrando el uso de Sistemas de Posicionamiento Global (GPS), Sistemas de Información Geográficos (GIS) y sensores proximales (Cicore et al., 2019) o remotos montados en cuatriciclos (King et al., 2010) o en satélites (Cicore et al., 2016; Gargiulo et al., 2020). Más recientemente, el desarrollo en tecnología de sensores ha lanzado al mercado nuevos sensores remotos multiespectrales de bajo costo, capaces de ser acoplados a drones (Viljanen et al., 2018). Esta novedosa tecnología presenta el potencial de generar mapas de alta resolución (< 10 cm) construidos con índices de vegetación, los cuales pueden ser interpretados como indicadores de biomasa disponible (Insua et al., 2019c; Michez et al., 2019; Oliveira et al., 2020).

Dentro de la variedad de índices espectrales de vegetación, el índice de vegetación de diferencia normalizada (NDVI) es uno de los más utilizados para estimar producción de forraje. Estudios previos indican que el NDVI es un buen indicador del porcentaje de radiación absorbida por la canopia (Baret y Guyot, 1991; Grigera et al., 2007; Pellegrini et al., 2020), y por lo tanto de las



tasas de crecimiento (Piñeiro et al., 2006). Sin embargo, el uso del NDVI para estimar disponibilidad de pasto suele presentar problemas de precisión cuando la pastura cubre la totalidad del suelo y el valor de NDVI llega a un máximo de 0,7-0,8 (Carlson y Ripley, 1997; Flynn et al., 2008; Insua et al., 2019). Este problema de saturación que alcanza el NDVI a altas acumulaciones de biomasa hace que los métodos de medición de NDVI sean usualmente ineficientes como herramienta de estimación de disponibilidad de pasto en establecimientos donde las pasturas acumulan $> 3000 \text{ kg MS ha}^{-1}$. Un estudio previo de nuestro grupo de investigación (Insua et al., 2019) ha demostrado que el problema de precisión que presenta el NDVI para estimar altos valores de biomasa podría ser resuelto mediante el uso combinado de i) una curva de calibración exponencial entre NDVI-biomasa y, ii) sensores con mayor frecuencia de lectura.

Recientemente, algunos trabajos (Ali et al., 2016; Bareth and Schellberg, 2018; Bazzo et al., 2023; Gargiulo et al., 2023; Insua et al., 2019; Lussem et al., 2021; Viljanen et al., 2018; Wang et al., 2016) demostraron que el uso de drones para estimar la disponibilidad de pasto a partir del NDVI medido con sensores multiespectrales puede resultar un método exitoso para estimar las variaciones espaciales de acumulación de biomasa del forraje debidas al pastoreo de los animales. Aunque esta novedosa propuesta fue exitosamente probada en situaciones experimentales específicas, limitaciones de los trabajos existentes asociadas al bajo número de intervalos de muestreo y la baja representatividad de sitios e intensidades de manejo, impiden transferir los resultados a otros sitios o momentos del año (Bazzo et al., 2023; Nguyen et al. 2022). Debido a esto, resulta necesario evaluar el empleo de drones bajo condiciones de pasturas contrastantes que contemple diferencias de especies forrajeras, épocas del año y niveles de fertilizante nitrogenado. Esto permitiría definir si las estimaciones remotas con drones se pueden generalizar mediante una única curva de calibración, o si se requiere del desarrollo futuro de un algoritmo que permita calcular la biomasa en función del NDVI dependiendo de la especie forrajera, la fertilización nitrogenada y/o la estación del año.

Considerando que el NDVI está indirectamente relacionado al área foliar de la cubierta verde (Baret y Guyot, 1991; Piñeiro et al., 2006), entonces se espera que la relación entre el NDVI y la biomasa disponible (curva de calibración) se vea afectada por los cambios de estructura (área foliar/biomasa) que pueden ocurrir entre estaciones del año y entre especies. Debe tenerse en cuenta, además, que si los índices de vegetación son buenos indicadores del estado nutricional de nitrógeno (N) de la planta (Errecart et al., 2012; Fitzgerald et al., 2010; Schlemmer et al., 2013; Wang et al., 2019), entonces es posible que la relación entre NDVI y biomasa cambie entre dosis de fertilización de N. Este último razonamiento se basa en que si se espera que a igual contenido de N (y por ende NDVI; Islam et al., 2011) haya más biomasa en una pastura fertilizada (Lemaire y Gastal, 1997), esto implicaría que la relación entre NDVI y biomasa disponible debería contemplar el estado nutricional de la pastura, el cuál va a depender básicamente de la fertilidad del suelo y de la dosis de fertilizante nitrogenado.



CALIBRACION PARA ESPECIES RELEVANTES DE ARGENTINA Y URUGUAY

Hipótesis y justificación general de la metodología de trabajo

La hipótesis general del trabajo plantea que los datos de NDVI recolectados mediante vuelos con dron servirán como herramienta para estimar disponibilidad de pasto a campo, pero de forma diferente entre especies forrajeras y estaciones del año. Ello se basa en que los posibles cambios de estructura de planta (área foliar/biomasa) y biomasa que sufren distintas especies forrajeras a lo largo del estén relacionados a cambios en la radiación absorbida y por lo tanto al NDVI medido (Baret y Guyot, 1991; Pellegrini et al., 2020; Sellers, 1985). Esto resultaría en potenciales variaciones de la relación entre el NDVI y biomasa (variación no explicada por la relación NDVI-biomasa). Si este fuera el caso, la calibración debería realizarse cada vez que las pasturas difieran en estructura, como puede ocurrir entre primavera y otoño o entre especies de diferente porte. Si no hubiera evidencia suficiente para aceptar esta hipótesis, en cambio, eso significaría que para un mismo valor de NDVI, la biomasa disponible sería independiente ante cambios en estructura de pastura, y ello justificaría el uso de una única curva de calibración general para distintas especies forrajeras durante todo el año.

Adicionalmente la hipótesis también plantea que la curva de calibración va a depender de la fertilización con N. Ello se basa en que es bien sabido que el estado nutricional de la planta afecta el contenido de N y por lo tanto el verdor de las hojas (Errecart et al., 2012). Debido a esto se espera que, a igual biomasa acumulada, el contenido de N (y el NDVI) sea mayor en una pastura fertilizada con N. Dicho de otra forma, se espera que a igual contenido de N o NDVI, haya más biomasa en una pastura fertilizada (Lemaire y Gastal, 1997). Si esto fuera así, implicaría que la curva de calibración NDVI-biomasa debería contemplar el estado nutricional de la pastura, el cuál va a depender básicamente de la fertilidad del suelo y de la dosis de fertilizante nitrogenado. Aunque este razonamiento pareciera ser muy lógico, podría ocurrir que la hipótesis no se acepte si el efecto de la fertilización no es lo suficientemente importante (estadísticamente significativo) sobre el contenido de N en hojas o estructuras de planta que justifique el desarrollo de distintas curvas de calibración en función de la dosis de N fertilizado.



Hipótesis de trabajo:

1. La relación entre la biomasa disponible de pasto (kg MS ha^{-1}) y el NDVI registrado con el dron varía conforme a una función exponencial negativa (ecuación de calibración).
2. Los parámetros de la ecuación de calibración entre el NDVI medido con el dron y la biomasa de pasto disponible (kg MS ha^{-1}):
 - a. varían entre especies (ecuaciones diferentes).
 - b. varían entre estaciones del año (ecuaciones diferentes).
 - c. varían con el nivel de nutrición nitrogenada de la pastura (ecuaciones diferentes).

Objetivos

Calibrar el uso de sensores multispectrales montados en drones para determinar diferencias en el índice verde de diferencia normalizado (NDVI) y su relación con la cantidad de pasto disponible en pasturas de festuca alta y agropiro alargado creciendo en diferentes estaciones del año y con diferente suministro de fertilizante nitrogenado.

Metodología de trabajo

Área de estudio y diseño experimental

El ensayo se llevó a cabo sobre dos pasturas de gramíneas templadas ubicadas en dos sitios experimentales de la Universidad Nacional de Mar del Plata – INTA EEA Balcarce ($37^{\circ}45'S$, $58^{\circ}18'O$, Buenos Aires, Argentina). En la “Reserva 6” se trabajó sobre una pastura de agropiro alargado (*Thinopyrum ponticum*) y en la “Reserva 7” sobre una pastura de festuca alta (*Festuca arundinacea*), ambas implantadas sobre un suelo Natracualf con aptitud ganadera. Se seleccionó la especie festuca alta dado que es una especie representativa de los sistemas pastoriles de la Argentina y Uruguay. Con el fin de estudiar condiciones meteorológicas y estructuras de pasturas contrastantes, los experimentos se llevaron a cabo en rebrotes de festuca alta y agropiro alargado durante la primavera y el otoño de dos años (Año 1: primavera 2021 - otoño 2022; Año 2: primavera 2022 - otoño 2023). En los sitios experimentales se delimitaron 30 y 72 parcelas de 6 m^2 dispuestas en 3 bloques en agropiro y festuca, respectivamente. Para generar la mayor variabilidad posible en términos de biomasa acumulada y estado nitrogenado, se aplicó aleatoriamente a cada parcela distinta dosis de fertilizante nitrogenado (agropiro: 0, 50 y 100 kg N ha^{-1} ; festuca: 0, 50, 100, 200, 400 y 600 kg N ha^{-1}) en forma de urea granulada aplicada al voleo.

Para cada rebrote se realizaron dos vuelos con las pasturas en estado vegetativo. A cada vuelo se le asignó un código de acuerdo a la fecha en que se ejecutó (Temprana = F1, Intermedia = F2, Tardía = F3) y se le ajustó una curva de calibración mediante la regresión entre el NDVI derivado



del dron y la biomasa al ras del suelo estimada indirectamente con un plato medidor de pasto calibrado en cada parcela experimental. Para la calibración del plato se realizaron cortes con cuchillo al ras del suelo del material contenido en 0.25 m² para luego secar la muestra, pesarla y estimar los kg MS/ha.

Para una correcta evaluación del efecto de la dosis de fertilizante sobre la curva de calibración se utilizó el Índice de Nutrición Nitrogenada (INN, Lemaire y Gastal, 1997), el cual relaciona la concentración actual de N de la pastura con la concentración crítica de N (%Ncrítico) para el valor actual de biomasa disponible medido mediante corte directo. Mediante este índice INN se categorizó a cada parcela en niveles de nutrición nitrogenada Bajo (INN < 0,6), Medio (0,6 ≥ INN ≤ 0,8) y Alto (INN > 0,8).

Planificación de vuelos y procesamiento de imágenes

Se utilizó una cámara multiespectral Sentera Double 4K NDVI-NDRE (Sentera, Saint Paul, MN, USA) montada sobre un dron DJI Phantom 4 multirrotores (DJI Technology Co., Shenzhen, China). Todos los vuelos se planificaron con la aplicación FieldAgent Mobile (Sentera, Saint Paul, MN, USA) a una altura de 100 m con un solapamiento lateral y frontal de 80%. El procesamiento de imágenes, georrectificación y ortomosaicos se llevaron a cabo con el software de fotogrametría Pix4Dmapper (Pix4D S.A, Prilly, Switzerland) y se almacenaron como archivos TIFF georeferenciados. Los valores de NDVI se calcularon para cada parcela experimental con el software QGIS (QGIS Geographic Information System, Open Source Geospatial Foundation Project) de la siguiente manera:

$$\text{NDVI} = (\text{NIR} - \text{R}) / (\text{NIR} + \text{R}) \text{ (Rouse, 1973)}$$

donde R y NIR corresponden a la reflectancia espectral en el rojo e infrarrojo cercano, respectivamente.

Análisis estadístico

Se ajustaron ecuaciones de regresión lineal y no lineal para cada vuelo entre el NDVI calculado y la biomasa estimada mediante el plato medidor de pasto. Para cada fecha, se seleccionó la ecuación con mayor coeficiente de correlación (R²) y menor error medio absoluto (MAE). Para evaluar el efecto de la especie, estado de nutrición nitrogenada y momento del año, se compararon los parámetros de la relación NDVI – biomasa mediante el p-valor, considerándose significativas las diferencias entre curvas cuando el p-valor fue ≤ 0,05.



Resultados

Calibración NDVI – biomasa

Los rangos de biomasa y NDVI explorados fueron de 853 – 8515 kg MS ha⁻¹ y 0,19 – 0,74, respectivamente. Los modelos de regresión exponencial que se ajustaron en cada fecha presentaron en promedio un R² de 0,83 (0,69 – 0,9) y un MAE de 160 kg MS ha⁻¹ (94 – 257) (Gráfico 1; Tabla 1).

Estación	Año	Fecha	Ecuación	
			Agropiro	Festuca
Primavera	2021	F1		$y = 441,63e^{3,12x}$
		F2	$y = 390,46e^{3,81x}$	$y = 328,4e^{3,53x}$
		F3	$y = 853,92e^{3,22x}$	
	2022	F2	$y = 967,71e^{2,04x}$	$y = 854,4e^{1,99x}$
		F3	$y = 1656,84e^{1,87x}$	
Otoño	2022	F1	$y = 238,38e^{3,57x}$	$y = 682,77e^{1,87x}$
		F2	$y = 618,19e^{2,34x}$	$y = 597,3e^{2,17x}$
	2023	F1	$y = 201,62e^{3,70x}$	$y = 246,32e^{3,59x}$
		F2	$y = 192,48e^{4,43x}$	$y = 567,41e^{2,72x}$

Tabla 1. Curvas de calibración ajustadas para cada fecha de vuelo en ambas especies.

Curva de calibración NDVI – biomasa en distintos momentos del año

El análisis comparativo entre estaciones del año mostró diferencias significativas para ambas especies forrajeras en ambos años (p -valor $\leq 0,05$). A igual NDVI, los rebrotes de primavera mostraron mayor acumulación de pasto que los de otoño (Gráfico 1). El Gráfico 1 muestra como además de ese efecto estacional también se observó un efecto de rebrote con marcadas diferencias entre fechas sucesivas. Dentro de cada rebrote, cinco de las siete comparaciones posibles entre fechas sucesivas de vuelo, mostraron diferencias significativas (p -valor $\leq 0,05$), mientras que las dos restantes presentaron similar tendencia (p -valor $< 0,1$, Gráfico 1). A medida que avanzó el tiempo de rebrote, las pasturas mostraron menor acumulación de biomasa para un mismo valor de NDVI (la curva de calibración se corre hacia la izquierda en fechas avanzadas, Gráfico 1). Por otro lado, al agrupar similares fechas (7) de distintos años, los datos se ajustaron en una misma curva exponencial (datos no mostrados) con estadísticos similares ($R^2 = 0,78$ y MAE = 236 kg MS ha⁻¹) a los obtenidos en fechas individuales (Gráfico 1).

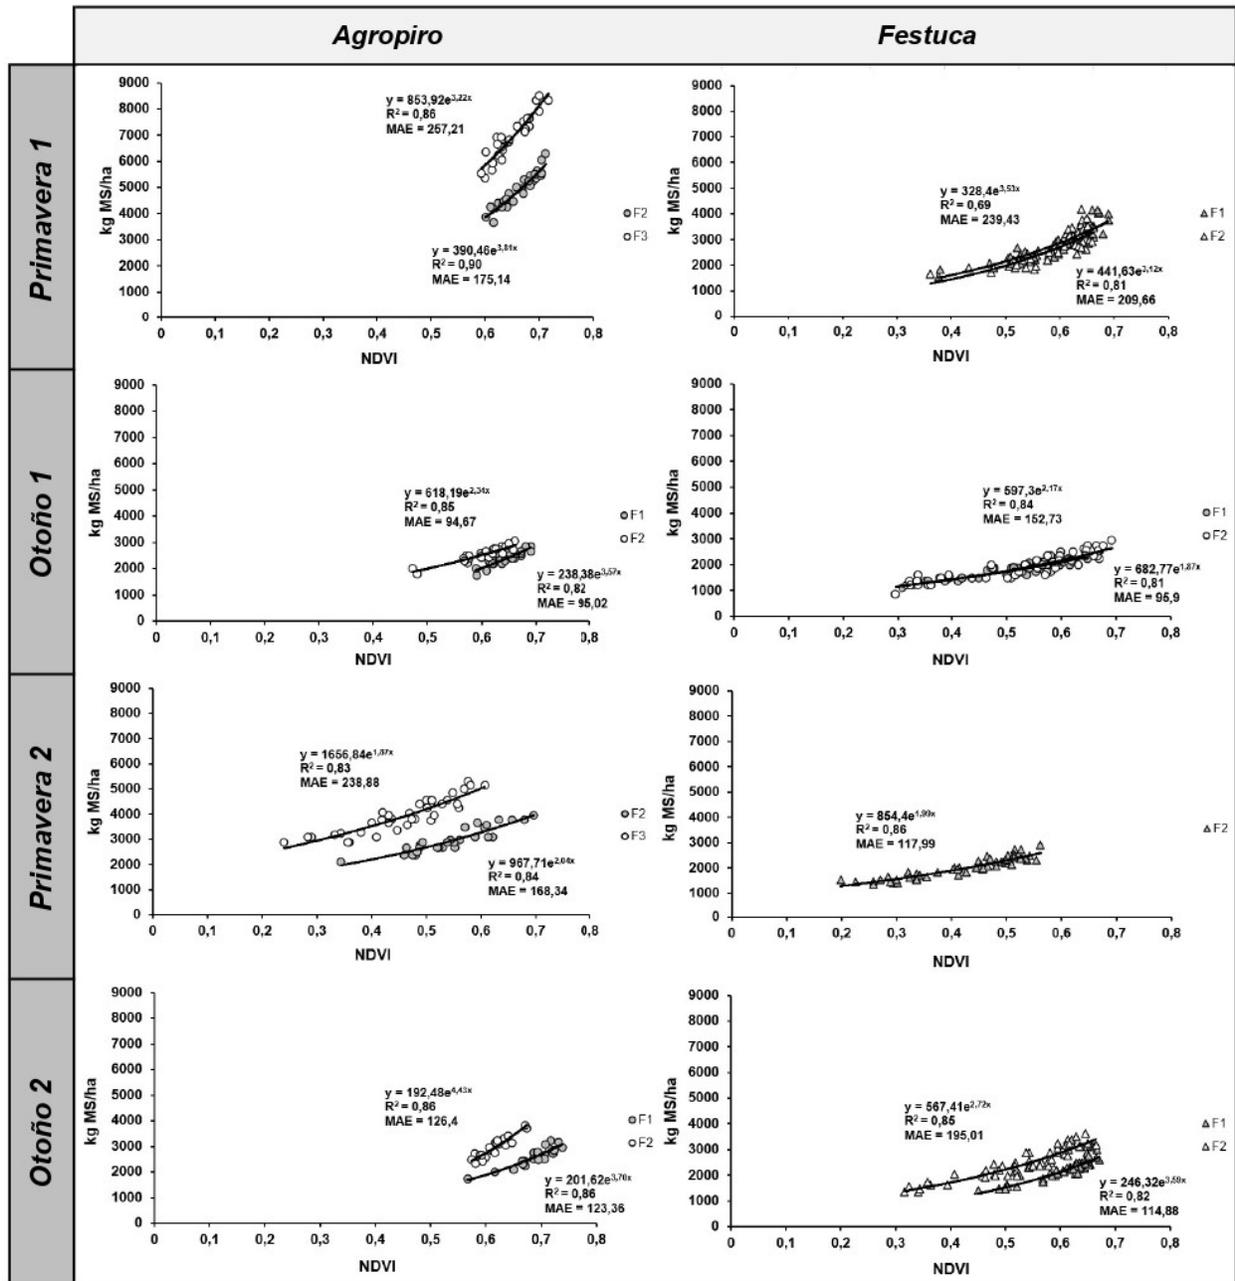


Gráfico 1. Efecto de la fecha de vuelo sobre las curvas de calibración NDVI – biomasa para agropiro y festuca.



Calibración NDVI – biomasa en distintas especies

En todas las fechas evaluadas se encontraron diferencias entre especies en los parámetros de la curva de calibración de NDVI y biomasa (p -valor $\leq 0,05$). El Gráfico 2 muestra, para dos fechas tomadas de ejemplo, que a igual NDVI, agropiro mostró mayor biomasa acumulada que festuca.

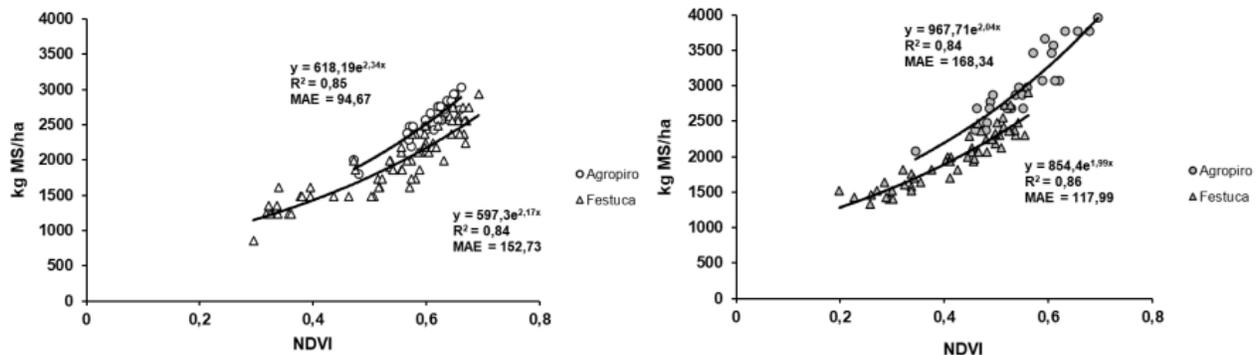


Gráfico 2. Efecto de la especie sobre las curvas de calibración NDVI – biomasa. Ejemplo de dos curvas de calibración NDVI – biomasa para agropiro y festuca en la segunda fecha de vuelo de otoño Año 1 (izquierda) y primavera Año 2 (derecha).

Calibración NDVI – biomasa con pasturas de diferente estado nutricional

Los tratamientos de dosis de N permitieron generar parcelas con un amplio rango de INN (0,30 – 1,39). Esto permitió una evaluación del efecto del estado nutricional de la pastura en un extenso rango de estados nutricionales, abarcando desde insuficiencia de N ($INN < 1$) hasta consumo de lujo ($INN > 1$). Bajo este análisis, las curvas de calibración de NDVI y biomasa de pasturas con INN bajo, medio y alto no se diferenciaron (p -valor $\leq 0,05$) entre sí para ninguna de las fechas evaluadas. A modo de ejemplo, el Gráfico 3 muestra cómo esta falta de efecto de la dosis de N sobre la curva de calibración fue consistente para ambas especies agrupándose en una sola curva de regresión exponencial.

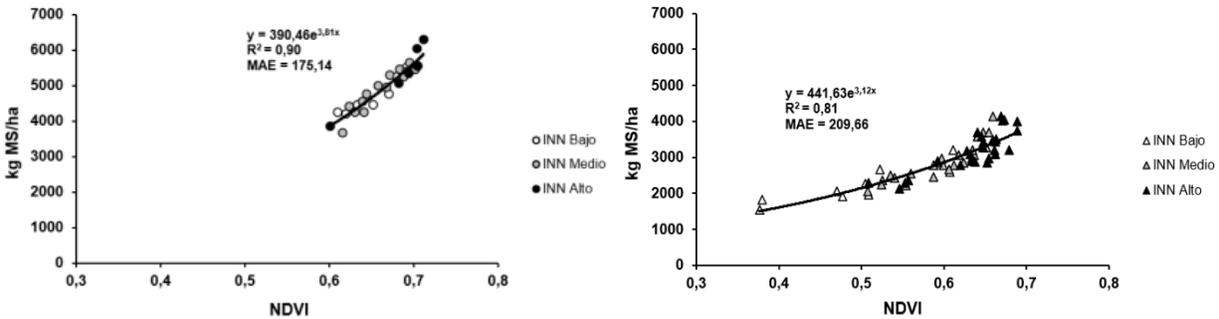


Gráfico 3: Efecto de la fertilización sobre las curvas de calibración NDVI – biomasa. Ejemplo de dos curvas de calibración NDVI – biomasa para agropiro (izquierda) y festuca (derecha) con distintos niveles de INN (bajo, medio y alto) para una misma fecha de medición.

Discusión

En el contexto práctico de toma de decisiones para el manejo del pastoreo mediante el empleo de drones, una pregunta clave es si la ecuación que permite transformar el valor de NDVI en kg de MS de pasto varía en un grado que compromete su aplicabilidad para los productores. En este trabajo, esto fue evaluado en parcelas experimentales mediante el análisis del efecto de especies forrajeras, momento del año y estado de nutrición nitrogenada de la pastura sobre la curva de calibración del NDVI colectado mediante el dron y la biomasa disponible a campo. El principal aporte de este trabajo es la identificación y cuantificación de los principales factores que agregan (o no) dispersión a las curvas de calibración afectando la precisión con la cual el monitoreo de pasturas por drones es implementado. Los resultados indican claramente las situaciones en las que un dron debe ser recalibrado para mantener una precisión similar o superior a la de un método convencional como el plato medidor de pasto.

Calibración indirecta NDVI – biomasa

Los resultados obtenidos en el presente trabajo muestran que es posible relacionar el NDVI medido por un dron y la biomasa de pastura ($\text{error} < 200 \text{ kg MS ha}^{-1}$), y que se puede utilizar esa información para el monitoreo de pasturas a campo (Gráfico 1). Cabe destacar que los ajustes de las curvas de calibración del dron mostraron valores similares, o incluso ampliamente mayores ($R^2=0,83$ y MAE de $160 \text{ kg MS ha}^{-1}$), que los comúnmente reportados para métodos indirectos convencionales como el plato medidor de pasto (Dillard et al., 2016; Gargiulo et al., 2020; Hernández, 2023; Klootwijk et al., 2019). Si bien trabajos previos en pasturas de raigrás y festuca (Insua et al., 2019; Gargiulo et al., 2023) también muestran una relación estrecha entre el NDVI capturado con el dron y la biomasa estimada para momentos y condiciones experimentales



puntuales ($R^2 > 0.54$), los tratamientos y fechas evaluados en este estudio permitieron analizar las curvas de calibración para un mayor rango de condiciones.

Al igual que en los trabajos previamente citados, la relación del NDVI y la biomasa mostró para todas las situaciones evaluadas un comportamiento exponencial, debido a la bien conocida respuesta de saturación que empieza a mostrar el índice NDVI ante aumentos en biomasa (Bazzo et al., 2023; Gebremedhin et al., 2020; Huang et al., 2021). A pesar de este fenómeno de saturación observado por encima de los 3000 kg MS ha⁻¹, en este trabajo no se registró una marcada pérdida de precisión por aumento de dispersión de datos como lo observado en trabajos previos (Insua et al., 2019). Estos resultados sugieren que las estimaciones indirectas de disponibilidad de pasto con drones por encima de los 3000 kg MS ha⁻¹ serían más sensibles a las variaciones de NDVI pero sin implicar necesariamente una pérdida importante en la precisión de la estimación.

Efecto de la especie en las curvas de calibración

El Gráfico 2 muestra claramente la necesidad de utilizar curvas de calibración diferentes para las dos especies forrajeras en estudio. Este trabajo indica de manera consistente que utilizar una curva de calibración desarrollada para otra especie puede llevar a errores significativos (421 ± 293 kg MS ha⁻¹) en la estimación de biomasa (Gráfico 2). Aunque existen algunos pocos trabajos en los que no se observaron diferencias en las curvas de calibración ajustadas para distintas especies (Insua et al., 2019; Lee et al., 2015), nuestros resultados coinciden con otros estudios previos en los que se demostró que el NDVI sí se ve afectado por la especie (Gargiulo et al., 2023; Wang et al., 2016). Los factores que pueden estar explicando estas diferencias entre especies pueden ser todos aquellos que modifiquen la reflectancia de la canopia, y por ende el NDVI medido, como la estructura del canopeo, el contenido de material muerto, la relación hoja/tallo, la pigmentación de las hojas y el estado fenológico de la pastura, entre otros (Lopez Díaz et al., 2011; Wang et al., 2016).

Efecto del momento del año

Las repeticiones temporales de los experimentos permiten concluir que se requieren diferentes curvas de calibración para monitorear pasturas en diferentes estaciones del año (Gráfico 1). Más precisamente, el Gráfico 1 muestra claramente para los dos años analizados en ambas especies que no solo las curvas cambian entre estaciones del año, sino que también cambian consistentemente entre semanas o fechas sucesivas de un mismo rebrote. Estos resultados explican las diferencias reportadas en otros trabajos que exploraron este efecto de manera más acotada en el tiempo sobre distintos tipos de coberturas vegetales (Gargiulo et al. 2020; 2023; Lussem et al. 2019; Liu et al., 2019).



Este estudio muestra que para una misma acumulación de biomasa el valor de NDVI disminuye con el correr de los días (Gráfico 1). El mismo efecto fue observado al analizar las curvas presentadas en estudios similares con pasturas en estado vegetativo (Gargiulo et al., 2020; 2023). Una posible explicación de que el valor de NDVI para una determinada cantidad de biomasa acumulada disminuya con el tiempo de rebrote podría basarse en el hecho de que el NDVI puede disminuir con la edad del tejido de planta y senescencia (Paruelo 2008; Todd et al., 1998). En otras palabras, se esperaría que para un mismo NDVI haya más biomasa acumulada en pasturas que se encuentran en un estado de rebrote avanzado dado que la proporción de tejido fotosintéticamente activo asociado al índice verde sería inferior. A pesar de esta posible explicación basada en el conocido efecto del material senescente sobre la disminución del NDVI, el hecho de que en este trabajo la evaluación se realizó en rebrotes vegetativos y durante la vida media foliar de las especies, sugiere que la disminución del NDVI entre fechas sucesivas para una misma cantidad de pasto está afectada por otros factores que cambian con el correr de los días. Posibles factores que pueden estar incidiendo sobre la variación temporal del NDVI y la biomasa podrían ser el ángulo solar, la radiación incidente o la inclinación de las hojas (Heilman et al., 1986; Lopez Díaz et al., 2011; Ponzoni et al., 2004; Valencia-Ortíz et al., 2021). En consecuencia, futuros trabajos que analicen la dinámica temporal de estos y otros factores sobre la relación entre el NDVI y la biomasa son necesarios para mejorar la aplicación del NDVI en el monitoreo de pasturas. Más allá de estas posibles explicaciones a los cambios de relaciones entre NDVI – biomasa, los resultados de este estudio resaltan la necesidad de trabajos futuros sobre el desarrollo de un algoritmo o metodología experimental que permita estimar de forma precisa la biomasa en función del NDVI para distintas fechas de vuelo.

Estado de nutrición nitrogenada

A partir de los datos de este estudio, pudo observarse como parcelas con distinto nivel de INN muestran una misma relación entre el NDVI y la biomasa (Gráfico 3). En otras palabras, el NDVI demostró ser un buen estimador de la biomasa disponible sin verse alterado por el estado nutricional nitrogenado de la pastura. A pesar de que el nivel de N en planta afectaría la relación entre el NDVI y la biomasa (Islam et al., 2011; Wang et al., 2019), nuestro estudio indica que ese efecto no es lo suficientemente importante como para que en la práctica amerite una recalibración del dron luego de fertilizaciones nitrogenadas (N). En términos prácticos, lo anterior implica que sería posible utilizar una misma curva de calibración para una determinada especie forrajera independientemente de la dosis de fertilizante aplicada o fertilidad del suelo.



Conclusiones y recomendaciones

El monitoreo de pasturas a partir de sensores multiespectrales montados en drones permite una estimación ágil y no destructiva de la biomasa disponible. El proyecto fue exitoso en calibrar el uso de drones para la estimación de biomasa de pasturas altamente utilizadas en la región. Sin embargo, la utilidad práctica de esta herramienta y, en última instancia, su potencial adopción por parte del productor dependerá de la robustez de la curva de calibración para la estimación de biomasa. Para ello, este estudio demostró que la predicción de la biomasa en función del NDVI cambia con la especie forrajera y con la fecha de vuelo sin verse afectada por la dosis de fertilizante nitrogenado. Esto implicaría que no sería preciso usar una única curva de calibración del dron, y ésta debería ser desarrollada para cada especie contemplando recalibraciones en diferentes momentos del año. El trabajo marca la necesidad de futuros trabajos orientados al desarrollo de protocolos de recalibraciones temporales del uso de drones con el fin de mantener la precisión de las estimaciones de pasto a lo largo del año.



CALIBRACIONES ESPECIES RELEVANTES COSTA RICA

Hipótesis y justificación general de la metodología de trabajo

La importancia del manejo apropiado de las pasturas es un componente esencial para asegurar la producción de forraje en los sistemas de ganadería; comprender la dinámica espacio-temporal de las pasturas es fundamental para la gestión y la toma de decisiones, especialmente en zonas con alta variabilidad edáfica y con pastoreo intensivo (Andersson *et al.* 2017). Sin embargo, es conocido que el monitoreo de pastos a escala fina basado en muchas mediciones de campo requiere de una inversión de tiempo alta, y a menudo limitado espacialmente (Legg y Bradley 2019).

Los avances tecnológicos han permitido que los drones puedan transportar sensores espectrales con los que pueden registrar además del espectro visible (380-780 nm), otras longitudes de onda como el infrarrojo cercano, que es de gran utilidad en el monitoreo del estado fenológico de los cultivos, biomasa de las especies, mapeo de terrenos agrícolas, detección temprana de enfermedades, plagas y déficit hídrico (Ali y Jassem 2014; Asen *et al.* 2015; Pajares 2015). Específicamente en el ámbito de ganadería, estas tecnologías se han convertido en una herramienta importante en la estimación de parámetros fisiológicos y de crecimiento mediante la respuesta espectral de los pastos en áreas medianamente extensas (Cáceres, 2014).

La base de la espectroscopía radica en que la radiación se modifica y cuantifica al interactuar con las coberturas, lo cual depende de su composición química. Lo anterior causa vibración en las moléculas, las cuales absorben y reflejan energía asociada a distintas longitudes de onda, lo que permite estimar la cantidad de unas y otras moléculas (Martínez y Solís 2018). En el caso de la estimación de biomasa, se deduce del contraste en la reflectividad espectral especialmente del rojo e infrarrojo cercano (IR); a mayor contraste entre dichas bandas mayor será el vigor de la masa vegetal analizada (Chuvieco-Salineró, 2010). Asimismo, la alta reflectancia del IR está relacionada con la reflectancia difusa de la celulosa y bandas de agua (Cordon 2009).

Para el análisis de esta información se utilizan diferentes combinaciones de bandas espectrales o también llamados índices de vegetación (IV) como indicadores de cambios estructurales o químicos en las plantas, mediante las variaciones del espectro de reflectancia (Peña *et al.* 2019). Numerosos estudios han demostrado estos cambios en las plantas y su respuesta espectral; (Brocks y Bareth, 2018; Stavrakoudis *et al.*, 2019; Yue et al., 2017)

Específicamente en pastos, se han logrado correlaciones de 0,98 (RMSE=12,70%) en rendimientos de materia seca y 0,98 (RMSE=11,05%) para rendimiento biomasa verde con el uso de métodos de aprendizaje automático que superó el método de regresiones lineales simples, lo que mostró la posibilidad de proporcionar estimaciones precisas y poder generar herramientas digitales para el monitoreo de los sistemas productivos (Viljanen 2018).

Objetivo

Estimar la biomasa disponible del pasto Bermuda (*Cynodon sp*) y Marandú (*Brachiaria brizantha*), mediante imágenes multiespectrales con el uso de drones.

Metodología de trabajo

Área de estudio y diseño experimental

El estudio se efectuó en dos Centros de Innovación Agropecuaria (CIA) del Instituto Nacional de Innovación y Transferencia en Tecnología Agropecuaria (INTA) de Costa Rica. Para el pasto Bermuda (*Cynodon sp*) las evaluaciones se realizaron en el CIA-Enrique Jiménez Núñez (CIA-EJN) ubicado en la región Chorotega (Figura 1); este sitio posee promedios de temperatura y precipitación de 28 °C y 1600 mm/año, respectivamente, y se encuentra ubicada a 14 m.s.n.m., dentro de la zona de vida Bosque húmedo premontano. En el caso del pasto Marandú (*Brachiaria brizantha*) las evaluaciones se efectuaron en el CIA-Los Diamantes (CIA-ELD) ubicado en la región Huetar Caribe de Costa Rica (Figura 1), dentro de la zona de vida bosque muy húmedo tropical, a una altitud 140 m.s.n.m., con promedios anuales de precipitación de 3000 mm y temperaturas de 24°C (Ministerio de Ambiente y Energía, 2022).

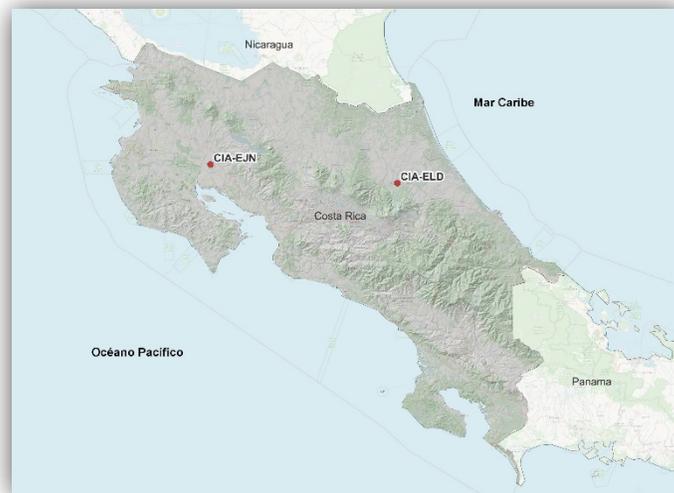


Figura 1. Ubicación de los sitios experimentales para la calibración de sensor multiespectral en la estimación de biomasa.



Manejo de las pasturas

En cada sitio se mantuvo el manejo que la pastura estaba recibiendo durante el periodo de evaluación, respetando los días de ocupación y descanso, así como la carga animal. Para realizar los vuelos y los muestreos reales de biomasa, se seleccionó un aparcamiento representativo en cada CIA (Figura 2), sobre el cual se aleatorizaron y marcaron 12 parcelas de 1 m² cada una en tres estratos (bajo, mediano y alto) según la disponibilidad de biomasa.



Figura 2. Sistemas de pastoreo donde se ubicaron los experimentos, (A) Sitio CIA-EJN, (B) Sitio CIA-ELD.

Planificación de vuelos y procesamiento de imágenes

Planificación de vuelos

Para planificar los vuelos, se utilizó una plataforma RPAS multirrotor DJI Matrice 210 RTK (Figura 3). El RPAS operó de forma autónoma con parámetros de vuelo establecidos mediante la aplicación DJI Pilot que cubrió toda el área experimental (aparcamiento). Los vuelos se realizaron cada dos rotaciones al igual que los muestreos reales, a una altura de 80 metros con una velocidad de 5 m/s, solapamiento lateral y frontal de 80% y por debajo del límite de almacenamiento según obturación del sensor. Los datos fueron adquiridos con un sensor multiespectral Micasense Altum (Tabla 2) con resolución radiométrica de 12 bit y 6 bandas espectrales: Rojo, verde, azul, borde rojo, infrarrojo y termal.



Figura 3. A: Levantamiento fotogramétrico con dron para la estimación de biomasa en pasturas; B: cuadros de muestreo distribuidos previo al vuelo.

Las imágenes se tomaron en condiciones de cielo nublado y despejado según las condiciones meteorológicas del día; además se tomaron imágenes del panel de calibración radiométrica, el cual tiene una curva de calibración asociada a través del espectro visible e infrarrojo cercano. Los datos de calibración se proporcionan como reflectancia absoluta, entre 0 y 1 o de 0 a 100 % de reflectividad, en el rango de 400 nm a 850 nm, con incrementos de 1 nm; lo anterior permite realizar comparaciones en el tiempo al asignar los valores de reflectancia conocidos de los píxeles.

Nombre	Longitud de onda central	Ancho de banda
Azul	475 nm	32 nm
Verde	560 nm	27 nm
Rojo	668 nm	14 nm
Borde rojo	717 nm	12 nm
IR cercano	842 nm	57 nm
LWIR	11 μ m	6 μ m

Tabla 2. Bandas espectrales de la cámara Micasense Altum serie AL05. Fuente: (MicaSense, 2020).



Muestreo de pastura

Posterior al vuelo sobre el aparcamiento seleccionado, se determinó la biomasa verde en cada una de las parcelas previamente marcadas; cortando y pesando la totalidad de forraje disponible en 1 m² a 10 cm sobre la superficie del suelo (Figura 4). Posteriormente se tomaron muestras de 500 gramos y se colocaron en bolsas de papel identificadas; se secaron en estufa con circulación forzada de aire a 60 °C durante 72 horas y se cuantificó la materia seca. Las muestras fueron analizadas en el Laboratorio de Nutrición Animal del Instituto Nacional de Innovación y Transferencia en Tecnología Agropecuaria (INTA). Finalmente, los rendimientos de biomasa verde y biomasa seca por hectárea se estimaron a partir de los muestreos realizados.



Figura 4. Muestreo de pastura en los dos sitios experimentales, izq (CIA-EJN), der (CIA-ELD), Costa Rica.

Procesamiento de imágenes

La rectificación y ensamblado de las imágenes (ortomosaico), y la generación de diferentes índices espectrales se realizó con el software Pix4D mapper. Con base en resultados de investigaciones anteriores, se seleccionaron distintos índices (tabla 3) que fueron generados mediante la calculadora de Pix4D mapper. En el caso de la delimitación y recortes de subparcelas de muestreo, se realizaron con el uso del software QGIS versión 3.22.11, y la extracción de valores espectrales por parcela y por vuelo se realizó con un código mediante un bucle con el software R versión 3.6.3.



Abreviación	Definición	Formula	Referencia
CARI	Índice de carotenoides	$RE/G-1$	Zhou et al., 2019.
CIRE	Índice de clorofila de borde rojo	$(NIR / RE) - 1$	Ye et al., 2020
GCI	Índice de clorofila verde	$(NIR/G)-1$	Ye et al., 2020
GNDVI	Índice de vegetación de diferencia normalizada verde	$(NIR - G)/(NIR + G)$	Ramos et al 2020
NDRE	Índice diferencia normalizada de borde rojo	$(NIR - RE)/(NIR + RE)$	Ramos et al 2020
NDVI	Índice de vegetación de diferencia normalizada	$(NIR - R)/(NIR + R)$	Ramos et al 2020
NGRDI	Índice de diferencia normalizada verde-rojo	$(G - R)/(G + R)$	Hassan et al., 2018
SAVI	Índice de vegetación ajustado del suelo	$1.5(NIR - R)/(NIR + R + 0.5)$	Da Silva et al 2020
SR	Índice de relación simple	NIR / R	Alves et al 2013
CVI	Índice de vegetación de clorofila	$CVI = NIR(R/G^2)$	Venancio et al 2020
MCARI	Índice modificado de absorción de clorofila	$((RE-R) - 0.2 * (RE-G)) * (RE + R)$	Babashi et al., 2024
IKAW	Índice de Kawashima	$(R-B)/(R+B)$	Jiang et al., 2019
RGRI	Índice de relación rojo-verde	R/G	Jiang et al., 2019
RGBVI	Índice de vegetación Rojo-verde-azul	$(G) - (R * B) / (G * G) + (R+B)$	Bendig et al. 2015
GBDI	Índice de diferencia verde-azul	$G-B$	Kawashima y Nakatani, 1998

R: rojo; G: verde; B: azul; RE: Borde rojo; NIR: infrarrojo; expresados como reflectancia

Tabla 3 Índices espectrales utilizados en la investigación para la predicción de biomasa en dos pasturas de Costa Rica.



Análisis estadístico

Debido a que las mediciones reales de pastura funcionan como un predictor de la cantidad de forraje disponible, en un primer análisis, se realizó la correlación entre los índices de vegetación y la biomasa obtenida en las mediciones. Posteriormente se construyeron modelos de regresión para comparar las relaciones y la significancia entre las bandas individuales y los índices de vegetación (regresoras) y las variables dependientes (biomasa verde o seca). Los análisis se realizarán con el uso del software R.

Por otra parte, con el propósito de explorar otros métodos para la predicción de biomasa de pasturas, se utilizaron y compararon diversos algoritmos de aprendizaje automático como: Vecinos más Cercanos (KNN), Máquinas de soporte de vectores Radiales (R-SVM), Árboles de Decisión (DT), Random Forest (RF) y regresión penalizada-Lasso (RPL).

Resultados y discusión

Calibración del pasto Bermuda (*Cynodon sp*)

Se encontraron correlaciones significativas entre los índices de vegetación y la biomasa seca ($p < 0,05$), a excepción de los índices de vegetación RGBVI, RGRI, CVI y NGDRI ($p > 0,05$). En particular, la biomasa (Kg MS.ha^{-1}) mostró una fuerte correlación positiva con el NDRE, $r = 0,80$, CIRE = 0,79, SR = 0,75 y negativa con IKAW $r = -0,70$ (Gráfico 4).

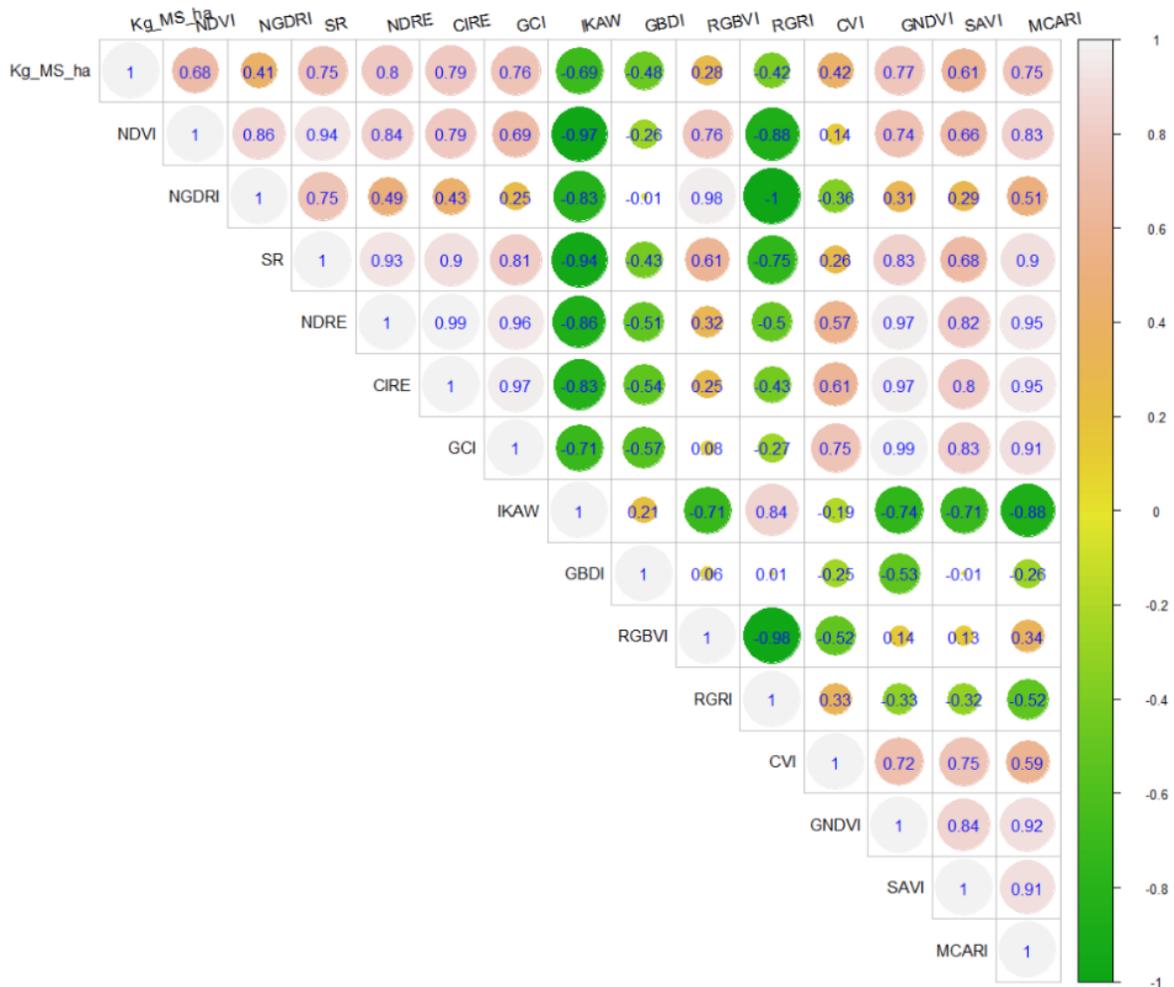


Gráfico 4. Matriz de correlación entre índices de vegetación y biomasa fresca para el pasto Bermuda.



Por otra parte, los índices de vegetación (NDRE y CIRE) como variables predictoras de biomasa seca, al usar modelos de regresión simple han demostrado una precisión intermedia, con R^2 de 0,62, 0,60 y un RMSE de 400 y 408 kg MS.ha⁻¹, respectivamente, (Gráfico 5).

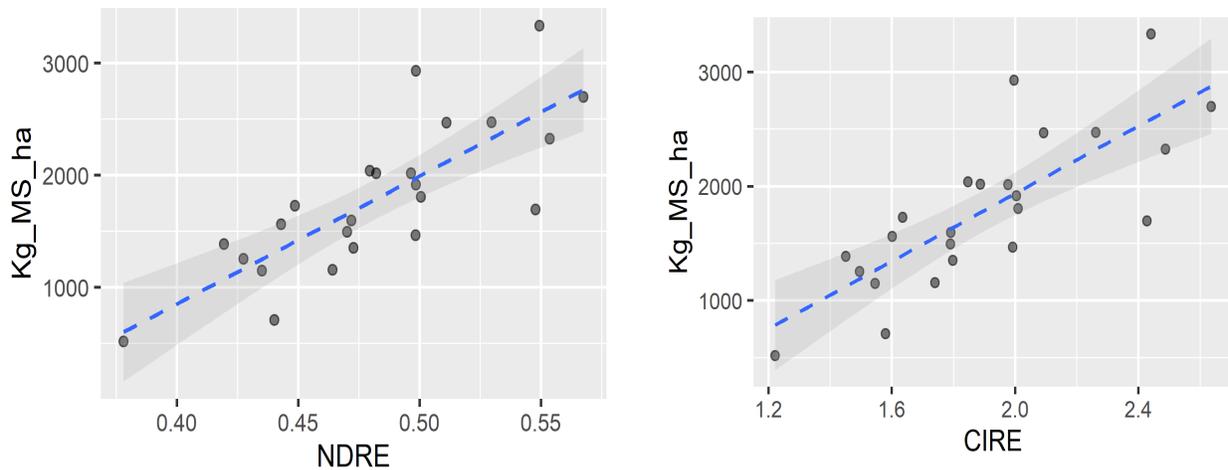


Gráfico 5. Relación entre los índices de vegetación NDRE, CIRE y la biomasa seca pasto *Cynodon* obtenidos con sensor multiespectral acoplado a un dron, Cañas, Costa Rica.

En cuanto a los algoritmos de aprendizaje automático, el mejor rendimiento de predicción de biomasa seca de pastura *Cynodon* se logró con el algoritmo Random Forest (RF) bajo el criterio de maximización del R^2 y minimización del RMSE, Gráfico 6. Los índices más importantes seleccionados para la construcción del modelo fueron en orden de importancia CIRE, NDRE, GNDVI, IKAW y SR. Al utilizar la totalidad de índices generados, el modelo puede explicar >85% (RMSE = 408 kg MS.ha⁻¹ aproximadamente), mientras que la eliminación de alguno de estos índices puede generar un $R^2 < 65\%$ (RMSE por encima de 700 kg MS.ha⁻¹). Los resultados respecto a la relevancia de los índices son consistentes al utilizar diferentes algoritmos.

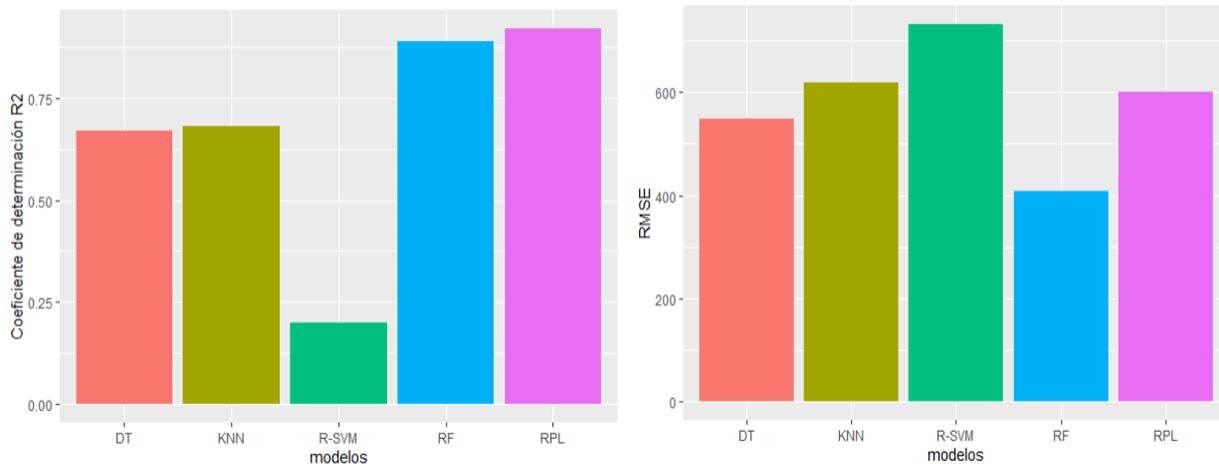


Gráfico 6. Algoritmos de aprendizaje automático evaluados para la predicción de biomasa fresca en pasturas; DT: Árboles de Decisión; KNN: Vecinos más Cercanos; R-SVM: Máquinas de soporte de vectores Radiales; RF: Random Forest; RPL: Regresión penalizada-Lasso.

Calibración del Pasto Marandú (*Brachiaria brizantha*)

Para la pastura Marandú (*Brachiaria brizantha*), se encontraron correlaciones significativas entre los índices de vegetación y la biomasa seca ($p < 0,01$). Los índices de vegetación, clorofila de borde rojo (CIRE) clorofila verde (GCI) y diferencia normalizada de borde rojo (NDRE) mostraron las correlaciones más altas ($r \geq 0,55$), mientras que los demás índices espectrales no tuvieron correlación ($p > 0,05$) (Gráfico 7). Los datos de biomasa seca oscilaron entre 500 y 3000 $\text{kg} \cdot \text{ha}^{-1}$

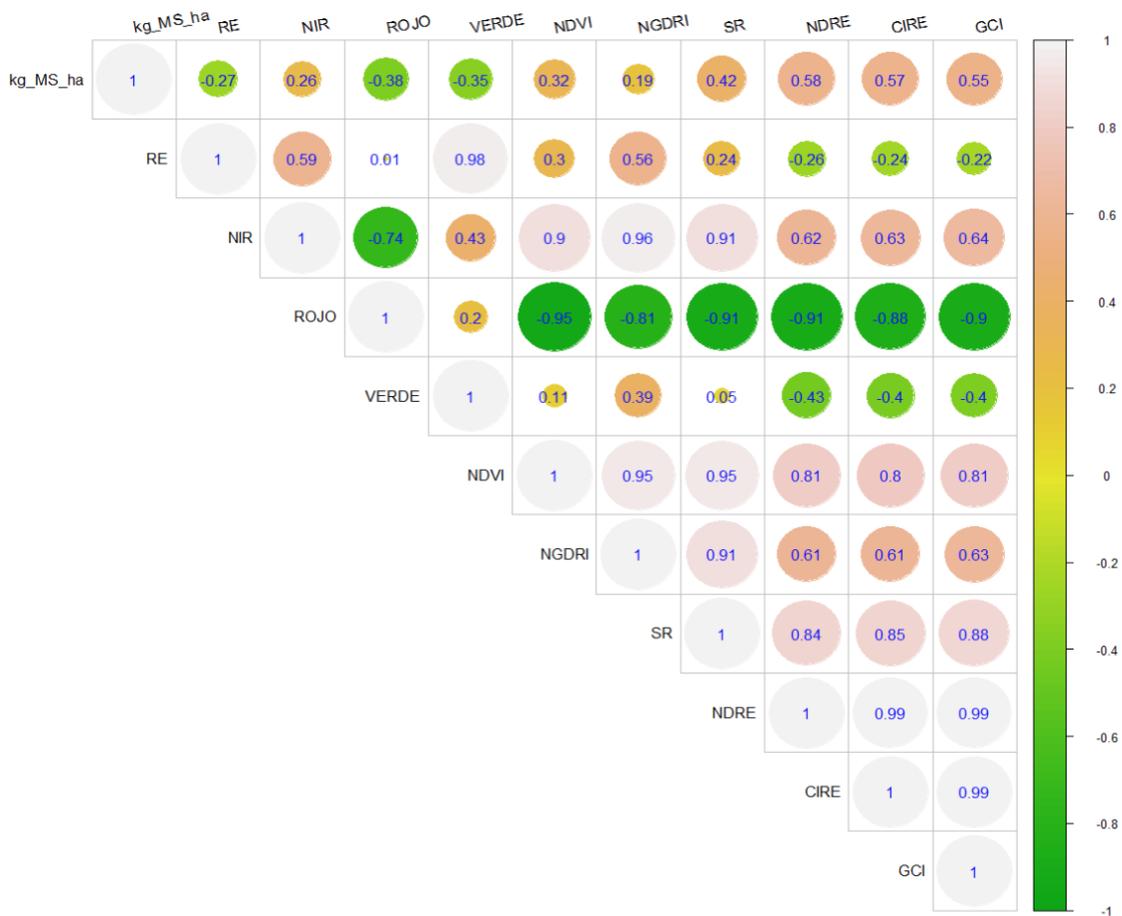


Gráfico 7. Matriz de correlación entre índices de vegetación, biomasa fresca y seca para el pasto *Brachiaria*, Guápiles, Costa Rica.

Al modelar los datos con Random Forest, el modelo obtuvo un R^2 de 0,62 (RMSE = 752 kg.MS.ha⁻¹ aproximadamente). Es importante destacar que las condiciones meteorológicas en la zona donde se encuentra establecida esta pastura se caracteriza por cambios abruptos entre alta radiación y alta nubosidad que puedan afectar los valores de reflectancia al momento del vuelo. Asimismo, esta pastura posee un tipo de crecimiento distinto, menos uniforme; en este sentido el sensor puede penetrar entre el follaje y capturar valores de reflectancia distintos al de la especie que puede alterar la relación entre los índices generados y la cantidad de biomasa estimada.

Esta primera fase del estudio demuestra que el algoritmo de RF es más preciso que los modelos simples para predecir la biomasa de pasturas. Consistente con estos resultados, Mutanga et al. (2012) que también compararon el desempeño de RF en la predicción del pasto y encontraron una mayor precisión con este mismo algoritmo.



Conclusiones y recomendaciones

Los índices NDRE, CIRE y GNDVI se correlacionan fuertemente con la biomasa seca del pasto Bermuda, mientras que los índices de clorofila de borde rojo (CIRE) clorofila verde (GCI) y diferencia normalizada de borde rojo (NDRE) mostraron mayor correlación con la biomasa seca del pasto *Brachiaria*. Se debe dar seguimiento en la investigación a estos índices de vegetación como herramienta promisorio de monitoreo remoto de pasturas con drones en Costa Rica.

Es necesario realizar una calibración a cada pastura en específico, para generar los índices que están más relacionados según especie, con el objetivo de predecir con mayor precisión la cantidad de biomasa seca disponible en los sistemas productivos.

Es importante considerar la variabilidad edafoclimática de cada zona, es decir tratar de capturar otras variables de clima o suelo que puedan ser incorporadas en el análisis para mejorar la predicción de los modelos.

CONCLUSIONES GENERALES

El monitoreo de pasturas mediante sensores multiespectrales montados en drones ha demostrado ser una herramienta eficaz para la estimación ágil y no destructiva de la biomasa disponible. Este proyecto ha sido exitoso en calibrar el uso de drones para la estimación de biomasa en pasturas comúnmente usadas en Argentina, Uruguay y Costa Rica. Sin embargo, la utilidad práctica de esta herramienta y su potencial adopción por parte de los productores dependerá de la robustez de la curva de calibración para la estimación de biomasa.

Este estudio demostró que la predicción de la biomasa basada en índices de vegetación varía según la especie forrajera y la época del año, y no se ve afectada significativamente por la dosificación de fertilizante nitrogenado. Esto sugiere que no sería adecuado utilizar una única curva de calibración para todas las especies y condiciones, sino que cada especie requiere una calibración específica que podría necesitar recalibraciones en diferentes momentos del año. El producto de conocimiento número 7 de este proyecto aborda un protocolo sobre el uso de drones para estimación de biomasa que puede ser utilizado con este fin.

Este trabajo subraya la necesidad de futuros esfuerzos enfocados en el desarrollo de calibraciones temporales del uso de drones, con el fin de mantener la precisión en las estimaciones de pasto a lo largo del año para las distintas especies forrajeras de la región.



REFERENCIAS BIBLIOGRÁFICAS

- Ali, S y Jassem, D. (2014). Monitoring Vegetation Areas by using Remote Sensing Techniques. *International Journal of Computer and Information Technology*, 3(02), 1-10.
- Ali, I.; Cawkwell, F.; Dwyer, E.; Barrett, B.; Green, S. 2016. Satellite remote sensing of grasslands: from observation to management. *J. Plant Ecol.*, 9 (6), pp. 649-671, 10.1093/jpe/rtw005
- Andersson, K; Trotter, M; Robson, A; Schneider, D; Frizell, L; Saint, A; Lamb, D; Blore, C. (2017). Estimating pasture biomass with active optical sensors. *Advances in Animal Biosciences*. 8(2): 754–757. <https://doi.org/10.1017/S2040470017000838>
- Alves, E.G.; Harley, P.; Gonçalves, J.F.C.; da Silva Moura, C.E.; Jardine, K. (2013). Effects of light and temperature on isoprene emission at different leaf developmental stages of *Eschweilera coriacea* in central Amazon. *Acta Amaz*, 44, 9–18.
- Babashli, B., Badalova, A., Shukurov, R., & Ahmadov, A. (2024). Cotton yield estimation using several vegetation indices. *Turkish Journal of Engineering*, 8(1). <https://doi.org/10.31127/tuje.1346353>
- Baeza S.; Paruelo J.; Ayala W. 2011. Eficiencia en el uso de la radiación y productividad primaria en recursos forrajeros del este de Uruguay. *Agrociencia Uruguay*. Volumen 15 (2): 48-59
- Baret F., Guyot G. 1991. Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote sensing of Environment* 35:161-173.
- Bareth, G. & Schellberg, J. 2018. Replacing Manual Rising Plate Meter Measurements with Low-cost UAV-Derived Sward Height Data in Grasslands for Spatial Monitoring. *Journal of Photogrammetry, Remote Sensing and Geoinformation Science*. 86. 10.1007/s41064-018-0055-2.
- Bazzo, C.O.G.; Kamali, B.; Hütt, C.; Bareth, G.; Gaiser, T. 2023. A Review of Estimation Methods for Aboveground Biomass in Grasslands Using UAV. *Remote Sens*. 15, 639. <https://doi.org/10.3390/rs15030639>
- Bendig, J., Yu, K., Aasen, H., Bolten, A., Bennertz, S., Broscheit, J., Gnyp, M.L., and Bareth, G., 2015. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation*, 39, pp. 79-87.
- Brocks, S; Bareth, G. (2018). Estimating barley biomass with crop surface models from oblique RGB imagery. *Remote Sensing*, 10 (2), 268. <https://doi.org/10.3390/rs10020268>
- Biomass estimation on grazed and ungrazed rangelands using spectral indices. *International Journal of Remote Sensing*. 19:3, 427-438, DOI: 10.1080/014311698216071



- Cáceres, J. (2014). Análisis del Comportamiento Temporal de la Biomasa en Pastos del Departamento de Olancho en el Contexto del Cambio Global – fase II. *Revista Ciencias Espaciales*, 7(1):97-114.
- Carlson T.N., Ripley D.A. 1997. On the relation between NDVI, fractional vegetation cover, and leaf area index. *Remote Sens Environ.* 62(3):241–52.
- Chapman, D.F. 2016. Using ecophysiology to improve farm efficiency: Application in temperate dairy grazing systems. *Agriculture* 6(2): 17. doi: 10.3390/agriculture6020017
- Chuvienco-Salineró, E. (2010). Teledetección ambiental: La observación de la Tierra desde el espacio. Editorial Ariel.
- Cicore P.L., Franco M. Castro, Peralta N. R., Marques da Silva J. R., Costa J. L. 2019. Relationship between soil apparent electrical conductivity and forage yield in temperate pastures according to nitrogen availability and growing season. *Crop and Pasture Science* 70, 908-916.
- Cicore, P.L., Serrano J., Shahidian S., Sousa A., Costa J., Da Silva J. 2016. Assessment of the spatial variability in tall wheatgrass forage using LANDSAT 8 satellite imagery to delineate potential management zones. *Environmental Monitoring and Assessment*. 188, 513.
- Cordon, G. (2009). *Metodos ópticos no destructivos para monitoreo de salud vegetal* [Tesis doctoral, Universidad de Buenos Aires] Biblioteca Central UBAEXACTAS. http://hdl.handle.net/20.500.12110/tesis_n4575_Cordon
- Da Silva, E.E.; Baio, F.H.R.; Teodoro, L.P.R.; da Silva Junior, C.A.; Borges, R.S.; Teodoro, P.E. UAV-multispectral and vegetation indices in soybean grain yield prediction based on in situ observation. *Remote Sens. Appl. Soc. Environ.* 2020, 18, 100318
- Dillard, S.; Hafila, A.; Rubano, M.; Stout, R.; Brito, A.; Soder, Ka. 2016. Evaluation of a Rising Plate Meter for Use in Multispecies Swards. *ael.* 1. 10.2134/ael2016.08.0032.
- Errecart P.M., Agnusdei M.G., Lattanzi F.A., Marino M.A. 2012 Leaf nitrogen concentration and chlorophyll meter readings as predictors of tall fescue nitrogen nutrition status. *Field Crops Research* 129, 46-58.
- Fariña S.R., Alford A., Garcia S.C. y Fulkerson W.J. 2013. An integrated assessment of business risk for pasture-based dairy farm systems intensification. *Agricultural Systems*. 115, 10-20.
- Fariña S.R., Garcia S.C., Fulkerson W., Barchia I. 2011. Pasture-based dairy farm systems increasing milk production through stocking rate or milk yield per cow: Pasture and animal responses. *Grass and Forage Science*. 66, 316-332.
- Fitzgerald G., Rodriguez D., O'Leary G. 2010. Measuring and predicting canopy nitrogen nutrition in wheat using a spectral index—The canopy chlorophyll content index



- (CCCI). *Field Crop Res.* 116:318-324.
- Flynn E.S., Dougherty C.T., Wendroth O. 2008. Assessment of pasture biomass with the Normalized Difference Vegetation Index from active ground-based sensors. *Agronomy Journal*. 100(1):114–21.
- Ganguli, A.C., Vermeire I., Mitchell R.B., Wallace M. 2000. Comparison of four nondestructive techniques for estimating standing crop in shortgrass plains. *Agronomy Journal*, 92, 1211-1215.
- García S.C., Islam M., Clark C., Martin P. 2014. Kikuyu-based pasture for dairy production: a review. *Crop & Pasture Science* 65, 787-797.
- Gargiulo J., Clark C., Lyons N., de Veyrac G., Beale P., Garcia S.C. 2020. Spatial and Temporal Pasture Biomass Estimation Integrating Electronic Plate Meter, Planet CubeSats and Sentinel-2 Satellite Data. *Remote Sensing* 12:3222.
- Gargiulo, J.I.; Lyons, N.A.; Masia, F.; Beale, P.; Insua, J.R.; Correa-Luna, M.; Garcia, S.C. 2023. Comparison of Ground-Based, Unmanned Aerial Vehicles and Satellite Remote Sensing Technologies for Monitoring Pasture Biomass on Dairy Farms. *Remote Sens.* 15, 2752. <https://doi.org/10.3390/rs15112752>
- Gebremedhin A., Badenhorst P., Wang J., Giri K., Spangenberg G., Smith K. 2019. Development and validation of a model to combine NDVI and plant height for high-throughput phenotyping of herbage yield in a perennial ryegrass breeding program. *Remote Sensing*. 11, 2494.
- Grigera G., Oesterheld M., Pacín F. 2007. Monitoring forage production for farmers' decision making. *Agric. Sys.* 94:637-648.
- Hassan, M.A.; Yang, M.; Rasheed, A.; Jin, X.; Xia, X.; Xiao, Y.; He, Z. Time-series multispectral indices from unmanned aerial vehicle imagery reveal senescence rate in bread wheat. *Remote Sens.* 2018, 10, 809.
- Heilman, J.L.; Boyd, W.E. 1986. Soil background effects on the spectral response of a three component rangeland scene. *Remote Sensing of Environment*, 19: 127-137.
- Hernández, V. 2023. Calibración y uso de métodos indirectos para estimar la biomasa en alfalfa, festuca y raigras anual. Tesis de grado. Facultad de Ciencias Agrarias, Universidad Nacional de Mar del Plata. Balcarce, Argentina. 40 p.
- Huang, S.; Tang, L.; Hupy, J.P. 2021. A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. *J. For. Res.* 32, 1–6. <https://doi.org/10.1007/s11676-020-01155-1>
- Insua, J.R.; Utsumi, S.A.; Basso, B. 2019. Estimation of spatial and temporal variability of pasture growth and digestibility in grazing rotations coupling unmanned aerial vehicle (UAV) with crop simulation models. *PloSone*. 14(3): e0212773. DOI: 10.1371/journal.pone.0212773



- Islam M.R., Garcia S.C., Henry D. 2011. Use of normalised difference vegetation index, nitrogen concentration, and total nitrogen content of whole maize plant and plant fractions to estimate yield and nutritive value of hybrid forage maize. *Crop Past. Sci.* 62:374-382.
- Jiang, J., Cai, W., Zheng, H., Cheng, T., Tian, Y., Zhu, Y., Ehsani, R., Hu, Y., Niu, Q., Gui, L., & Yao, X. (2019). Using digital cameras on an unmanned aerial vehicle to derive optimum color vegetation indices for leaf nitrogen concentration monitoring in winter wheat. *Remote Sensing*, 11(22). <https://doi.org/10.3390/rs11222667>
- Kawashima, S., Nakatani, M., 1998. An algorithm for estimating chlorophyll content in leaves using a video camera. *Ann. Bot.* 81, 49–54
- King, W., Rennie G., Dalley D., Dynes R., Upsdell M. 2010. Pasture mass estimation by the C-DAX Pasture meter: Regional calibrations for New Zealand. *Proceedings of the Proceedings 4th Australasian Dairy Science Symposium*, pp. 233-238.
- Klootwijk, C.W.; Holshof, G.; van den Pol-van Dasselaar, A.; van Helvoort, K.L.M.; Engel, B.; de Boer, I.J.M.; van Middelaar, C.E. 2019. The effect of intensive grazing systems on the rising plate meter calibration for perennial ryegrass pastures. *Journal of Dairy Science*, Volume 102, Issue 11, 10439-10450, ISSN 0022-0302. <https://doi.org/10.3168/jds.2018-16118>
- Lee, H.; Lee, H; Jung, J; Ko, H. 2015. Mapping herbage biomass on a hill pasture using a digital camera with an unmanned aerial vehicle system. *Journal of the Korean Society of Grassland and Forage Science* 35(3) : 225~231. <http://dx.doi.org/10.5333/KGFS.2015.35.3.225>
- Legg, M & Bradley, S. (2019). Ultrasonic Arrays for Remote Sensing of Pasture Biomass. *Remote Sensing*.12 (1): 111. <https://doi.org/10.3390/rs12010111>
- Lemaire G., Gastal F. 1997. N uptake and distribution in plant canopies, *Diagnosis of the nitrogen status in crops*, Springer. pp. 3-43.
- Liu, H.; Dahlgren, R.A.; Larsen, R.E.; Devine, S.M.; Roche, L.M.; O' Geen, A.T.; Wong, A.J.Y.; Covello, S.; Jin, Y. 2019. Estimating Rangeland Forage Production Using Remote Sensing Data from a Small Unmanned Aerial System (sUAS) and PlanetScope Satellite. *Remote Sens.* 11, 595. <https://doi.org/10.3390/rs11050595>
- López-díaz, J., Roca-Fernández A., González-Rodríguez A. 2011. Measuring herbage mass by non-destructive methods: a review. *Journal of Agricultural Science and Technology.* 1, 303-314.
- Lussem, U.; Bolten, A.; Menne, J.; Gnyp, M.L.; Schellberg, J.; Bareth, G. 2019. Estimating biomass in temperate grassland with high resolution canopy surface models from UAV-based RGB images and vegetation indices. *J. Appl. Remote Sens.* 13(3), 034525 (2019), doi: 10.1117/1.JRS.13.034525.
- Martin, R.C.; Astatkie, T.; Cooper, J.M.; Fredeen, A.H. 2005. A Comparison of Methods Used



- to Determine Biomass on Naturalized Swards. *Journal of Agronomy and Crop Science*, 191: 152-160. <https://doi.org/10.1111/j.1439-037X.2004.00145.x>
- Micasense. (01 de junio de 2020). Altum Integration Guide. <https://support.micasense.com/hc/en-us/articles/360010025413-Altum-Integration-Guide>
- Michez A., Lejeune S., Bauwens A., Herinaina Y., Blaise, Castro Muñoz. 2019. Mapping and Monitoring of Biomass and Grazing in Pasture with an Unmanned Aerial System. *Remote Sensing* 11: 473.
- Ministerio de Ambiente y Energía. (2022, octubre 10). Mapa de zonas de vida de Costa Rica. Sistema Nacional de Información Territorial, Instituto Geográfico Nacional. <https://bit.ly/3Zrn65p>
- Mutanga, O., Adam, E., & Cho, M. A. (2012). High density biomass estimation for wetland vegetation using WorldView-2 imagery and random forest regression algorithm. *International Journal of Applied Earth Observation and Geoinformation*, 18, 399–406. <https://doi.org/10.1016/j.jag.2012.03.012>
- Nguyen, P.T.; Shi, F.; Wang, J.; Badenhorst, P.E.; Spangenberg, G.C.; Smith, K.F.; Daetwyler, H.D. 2022. Within and combined season prediction models for perennial ryegrass biomass yield using ground- and air-based sensor data. *Front. Plant Sci.* 13:950720. doi: 10.3389/fpls.2022.950720
- Oliveira R.A., Näsi R., Niemeläinen O., Nyholm L., Alhonoja K., Kaivosoja J., Jauhainen L., Viljanen N., Nezami S., Markelin L., Hakala T., Honkavaara E. 2020. Machine learning estimators for the quantity and quality of grass swards used for silage production using drone-based imaging spectrometry and photogrammetry. *Remote sensing of Environment* 246:111830.
- Paruelo, J.M. 2008. La caracterización funcional de ecosistemas mediante sensores remotos. *Ecosistemas* 17(3):4-22. Recuperado de: <http://www.revistaecosistemas.net/articulo.asp?Id=575>
- Pellegrini P., Cossani C.M., Bella C.M.D., Piñeiro G., Sadras V.O., Oesterheld M. 2020. Simple regression models to estimate light interception in wheat crops with Sentinel-2 and a handheld sensor. *Crop Sci.* 60:1607-1616.
- Peña, L; Rentería, V; Velásquez, C; Ojeda, M; Barrera, E. (2019). Absorbancia y reflectancia de hojas de Ficus contaminadas con nanopartículas de plata. *Revista Mexicana de Física*, 65(1): 95-105. <https://doi.org/10.31349/RevMexFis.65.95>
- Piñeiro G., Oesterheld M., Paruelo J.M. 2006. Seasonal variation in aboveground production and radiation use efficiency of temperate rangelands estimated through remote sensing. *Ecosystems*. 9: 357-373.



- Ponzoni, F.; Rezende, A. 2004. Vegetation successional stages spectral characterization in altamira (pa), brazil by orbital radiometric data. *Revista Árvore*. 28. 10.1590/S0100-67622004000400007.
- Ramos, A.P.M.; Osco, L.P.; Furuya, D.E.G.; Gonçalves, W.N.; Santana, D.C.; Teodoro, L.P.T.; Junior, C.A.S.; Capristo-Silva, G.F.; Li, J.; Baio, F.H.R.; et al. A random forest ranking approach to predict yield in maize with uav-based vegetation spectral indices. *Comput. Electron. Agric.* 2020, 178, 105791.
- Rouse, J.W.; Haas, Jr. R.H.; Schell, J.A.; Deering, D.W. 1973. Monitoring the vernal advancement and retrogradation (greenwave effect) of natural vegetation. *Prog. Rep. RSC 1978-1, Remote Sensing Center, Texas A&M Univ., College Station*. 93p. (NTIS No. E73-106393).
- Sanderson, M.A.; Rotz, C.A.; Fultz, S.W.; Rayburn, E.B. 2001. Estimating Forage Mass with a Commercial Capacitance Meter, Rising Plate Meter, and Pasture Ruler. *Agronomy Journal* 93:1281-1286.
- Schlemmer, M.; Gitelson, A.; Schepers, J.; Ferguson, R.; Peng, Y.; Shanahan, J.; Rundquist, D. 2013. Remote estimation of nitrogen and chlorophyll contents in maize at leaf and canopy levels. *International Journal of Applied Earth Observation and Geoinformation*, Volume 25, 2013, Pages 47-54, ISSN 1569-8432, <https://doi.org/10.1016/j.jag.2013.04.003>.
- Stavrakoudis, D; Katsantonis, D; Kadoglidou, K; Kalaitzidis, A; Gitas, I. (2019). Estimating rice agronomic traits using drone collected multispectral imagery. *Remote Sensing*. 11(5):545. <https://doi.org/10.3390/rs11050545>
- Todd, S.W.; Hoffer, R.M.; Milchunas, D.G. 1998. Biomass estimation on grazed and ungrazed rangelands using spectral indices. *International Journal of Remote Sensing*. 19:3, 427-438, DOI: 10.1080/014311698216071
- Valencia-Ortiz, M.; Sangjan, W.; Selvaraj, M.G.; McGee, R.J.; Sankaran, S. 2021. Effect of the solar zenith angles at different latitudes on estimated crop vegetation indices. *Drones*, 5, 80. <https://doi.org/10.3390/drones503008>
- Venancio, L.P.; Mantovani, E.C.; do Amaral, C.H.; Neale, C.M.U.; Gonçalves, I.Z.; Filgueiras, R.; Eugenio, F.C. Potential of using spectral vegetation indices for corn green biomass estimation based on their relationship with the photosynthetic vegetation sub-pixel fraction. *Agric. Water Manag.* 2020, 236, 106155.
- Viljanen, N; Honkavaara, E; Näsi, R; Hakala, T; Niemeläinen, O; Kaivosoja, J. A. (2018). Novel Machine Learning Method for Estimating Biomass of Grass Swards Using a Photogrammetric Canopy Height Model, Images and Vegetation Indices Captured by a Drone. *Agriculture* 8(5), 70. <https://doi.org/10.3390/agriculture8050070>
- Wang, R.; Gamon, J.A.; Montgomery, R.A.; Townsend, P.A.; Zyguelbaum, A.I.; Bitan, K.; Tilman, D.; Cavender-Bares, J. 2016. Seasonal Variation in the NDVI–Species Richness



- Relationship in a Prairie Grassland Experiment (Cedar Creek). *Remote Sens.* 8, 128. <https://doi.org/10.3390/rs8020128>
- Wang H., Mortensen A.K., Mao P., Boelt B., Gislum R. 2019. Estimating the nitrogen nutrition index in grass seed crops using a UAV-mounted multispectral camera. *International Journal of Remote Sensing* 40:2467-2482.
- Wang, Z.; Ma, Y.; Zhang, Y; Shang, J. 2022. Review of Remote Sensing Applications in Grassland Monitoring. *Remote Sensing.* 14(12):2903. <https://doi.org/10.3390/rs14122903>
- Ye, H., Huang, W., Huang, S., Cui, B., Dong, Y., Guo, A., Ren, Y., & Jin, Y. (2020). Recognition of banana Fusarium wilt based on UAV remote sensing. *Remote Sensing*, 12(6). <https://doi.org/10.3390/rs12060938>
- Yue, J; Yang, G; Li, C; Li, Z; Wang, Y; Feng, H; Xu, B. (2017). Estimation of Winter Wheat Above-Ground Biomass Using Unmanned Aerial Vehicle-Based Snapshot Hyperspectral Sensor and Crop Height Improved Models. *Remote Sens*, 9 (7), 708. <https://doi.org/10.3390/rs9070708>
- Zhou, X.; Huang, W.; Zhang, J.; Kong, W.; Casa, R.; Huang, Y. A novel combined spectral index for estimating the ratio of carotenoid to chlorophyll content to monitor crop physiological and phenological status. *Int. J. Appl. Earth. Obs. Geoinf.* 2019, 76, 128–142.



INSTITUCIONES PARTICIPANTES



Instituto Nacional de Innovación y Transferencia en Tecnología Agropecuaria



Secretaría Técnica Administrativa



Con el apoyo de:



www.fontagro.org

Correo electrónico: fontagro@fontagro.org