









Imágenes digitales obtenidas por dron para estimar el rendimiento de la biomasa en un sitio de pastizal del estado de Durango

Digital images obtained by drone to estimate biomass yield in a grassland site in the state of Durango

Amaury Esquivel Romo ^{1,2}  - Ulises Noel Gutiérrez Guzmán ²  ✉ - Alejandro Moreno Reséndez ¹  - Francisco Gerardo Veliz Deras ¹  - Fernando Arellano Rodríguez ¹  - Jorge Arturo Bustamante Andrade ^{1,2}  María Esther Ríos Vega ²  - Apolinar González Mancilla ² 

¹ Universidad Autónoma Agraria Antonio Narro, Unidad Laguna. Torreón, Coahuila, México

² Universidad Juárez del Estado de Durango, Facultad de Agricultura y Zootecnia. Gómez Palacio, Durango, México

✉ Autor de correspondencia: ulises.gutierrez@ujed.mx

Recepción: 03-05-2022 / Aceptación: 08-07-2022

© Nova Scientia, bajo licencia Creative Commons / ISSN 2007-0705

Resumen

La adquisición de imágenes de alta resolución mediante drones y su posterior procesamiento proporcionan información valiosa sobre variables biofísicas de vegetación de pastizales. El objetivo de este estudio fue generar un modelo de predicción de la dinámica de la productividad anual de un pastizal semiárido del norte de México mediante la cobertura vegetal estimada en fotografías digitales obtenidas por dron. Se diseñó un sistema de muestreo permanente en el predio ganadero La Cieneguilla. Las variables de estudio medidas fueron la producción de biomasa de corte directo como variable dependiente y la cobertura vegetal estimada en imágenes digitales adquiridas por dron como variable independiente. El número de muestras recogidas de ambas variables fue de 640 durante el año 2020. Con el 50% de los datos se generó el modelo de predicción y con el otro 50% de los datos el modelo de validación, los modelos de regresión ajustados fueron de la forma $Y = \beta_0 + \beta_1X + \beta_2X^2$ con R^2 ajustado = 71.64% y 69.90% respectivamente. Esta metodología propuesta ofrece un medio no destructivo y preciso para el monitoreo y evaluación anual de pastizales en áreas secas.

Palabras clave: modelo de predicción; cobertura vegetal; clasificación supervisada; CobCal; pastizales; ganado; biomasa; evaluación anual; productividad; vegetales

Abstract

The acquisition of high-resolution images by drones and their subsequent processing provides valuable information on biophysical variables of grassland vegetation. The objective of this study was to generate a prediction model of the annual productivity dynamics of a semi-arid grassland in northern Mexico through the estimated vegetation cover in digital photographs obtained by drone. A permanent sampling system was designed in the La Cieneguilla cattle ranch. The study variables measured were the direct cut biomass production as the dependent variable and the vegetation cover estimated in digital images acquired by drone as the independent variable. The number of samples collected for both variables was 640 during the year 2020. With 50% of the data, the prediction model was generated and with the other 50% of the data, the validation model, the adjusted regression models were the form $Y = \beta_0 + \beta_1X + \beta_2X^2$ with adjusted $R^2 = 71.64\%$ and 69.90% respectively. This proposed methodology offers a non-destructive and accurate means for annual monitoring and evaluation of grasslands in dry areas.

Keywords: prediction model; vegetal cover; supervised classification; CobCal; grassland; cattle; biomass; annual evaluation; productivity; vegetables

1. Introducción

Los pastizales son uno de los principales ecosistemas del mundo y cubren cerca de un tercio de la superficie terrestre (Lemaire *et al.*, 2011). En México, los pastizales de zonas áridas se encuentran ampliamente distribuidos en el norte y centro del país, se les considera ecosistemas muy importantes desde el punto de vista ecológico y económico (Espinoza *et al.*, 2000). Son reconocidos por brindar importantes servicios ecosistémicos más allá del forraje para el ganado, incluidos el mantenimiento de suelos estables y productivos, suministro de agua limpia y alta biodiversidad (Habel *et al.*, 2013, Teague *et al.*, 2013). Sin embargo, la degradación de la vegetación y los suelos es común en la mayoría de los pastizales semiáridos de México y del mundo (Moreno *et al.*, 2014, Parr *et al.*, 2014).

La evaluación de la vegetación de las tierras de pastoreo es esencial para determinar la capacidad de carga y evitar el exceso de ganado y/o el sobrepastoreo de los pastizales de una granja, rancho o unidad de tierra pública, además el tener conocimiento de la capacidad de pastoreo actual o la capacidad de carga a largo plazo. Una alternativa es a través del monitoreo del rendimiento de forraje lo cual es de suma importancia para respaldar las decisiones de manejo en pastizales (Lussem *et al.*, 2018, Viljanen *et al.*, 2018). La biomasa de los pastizales es un indicador importante de la productividad de dichos ecosistemas y el método comúnmente aceptado para su medición es cosechar y pesar plantas directamente en un área determinada (Everson *et al.*, 1990, Sorensen *et al.*, 2012).

En la actualidad las nuevas tecnologías aplicadas para la obtención de información sobre variables biofísicas de la vegetación como es la percepción remota pueden tener un rol decisivo en el desarrollo de soluciones de monitoreo de ecosistemas de pastizal (Hernández *et al.*, 2019), además, los sensores remotos representan una fuente de datos clave en la estimación de la biomasa y con el desarrollo de esta tecnología es posible obtener imágenes de mayor precisión y escala (Viljanen *et al.*, 2018, Lussem *et al.*, 2019).

Generalmente, los trabajos de investigación para predecir el rendimiento de la biomasa de pastizales basados en imágenes de satélite y cálculo de índices de vegetación se basan en la época de crecimiento cuando la vegetación esta verde o vigorosa y es cuando los sensores tienen la habilidad de detectar mejor esta característica (Butt *et al.*, 2011, Cong *et al.*, 2012, Chen *et al.*, 2013). Sin embargo, esta temporada es corta en relación con el año (tres a cuatro meses) pero ¿qué pasa cuando la vegetación esta seca o senescente y los índices disminuyen la habilidad de predicción? Es necesario implementar otras metodologías para contar con modelos robustos de predicción de la producción de biomasa independientemente de la época del año para la gestión adecuada de los pastizales.

El surgimiento de UAV permite la obtención de imágenes de muy alta resolución espacial y en tiempo real (Bending *et al.*, 2014). Grüner *et al.*, (2019) comentan que una estimación adecuada y precisa del rendimiento en pastizales es obligatoria para las decisiones de manejo del pastoreo y una opción viable para esto es el uso de cámaras RGB (rojo, verde, azul) instaladas en un vehículo aéreo no tripulado (UAV), las cuales representan una tecnología no destructiva prometedora para la evaluación especialmente en áreas grandes y remotas. La portabilidad de cámaras ópticas por los UAV que cubren las regiones del espectro visible (Wang *et al.*, 2017). Los beneficios de la técnica de estimación fotográfica incluyen la reducción del tiempo de campo, la minimización del muestreo destructivo y la estimación subjetiva del observador al estimar la biomasa en el campo (Morgan *et al.*, 2017).

Medir la cobertura vegetal es una de las formas más comunes de describir cuantitativamente la vegetación, debido a su velocidad y bajo impacto en el área muestreada (Symstad *et al.*, 2008). Los métodos principales para medir la cobertura son intersección de la línea, frecuencia puntual, estimación visual y métodos fotográficos. Se estudiaron las correlaciones entre las estimaciones del porcentaje de cobertura vegetal basadas en imágenes y dieron como resultado valores de R² superiores al 92 % (Booth *et al.*, 2006).

El método de clasificación supervisada de imágenes digitales por medio de aplicaciones automatizadas es una alternativa viable para determinar la cobertura vegetal independientemente del estado fisiológico de la planta (Byrne *et al.*, 2011). Diferentes estudios realizados con el propósito de estimar la biomasa aérea herbácea

han sido realizados con variables de fácil medición como la altura o la cobertura aérea o basal, esto se efectuado a través de modelos de regresión (Nafus *et al.*, 2009, MacDonald *et al.*, 2012).

Por lo tanto, el propósito de este estudio es encontrar la relación entre el rendimiento de la biomasa de pastizales anual y la cobertura vegetal estimada en fotografías RGB obtenidas con dron a través de modelos de regresión sin importar el estado fisiológico de la vegetación a nivel de una unidad productiva ganadera.

2. Métodos, técnicas e instrumentos

Este presente estudio se realizó en un pastizal privado ubicado dentro de la colonia agrícola y ganadera La Cieneguilla, Durango, México, en las coordenadas geográficas 25° 39' N, 104° 39' O, la altura promedio del sitio es de 1910 m (figura 1). El clima predominante en el sitio es estepario, presenta dos periodos típicos de zonas áridas: el periodo de lluvias (agosto-noviembre) y el periodo de secas (diciembre-julio), el promedio de precipitación anual es de 450 mm y la temperatura promedio anual es de 20 °C. El suelo es de tipo migajón arcillo-arenoso, con pendientes suave del 1 al 8 %. El tipo de vegetación está clasificado como pastizal natural con dominancia de *Bouteloua gracilis*. El sitio se ubica en una región ganadera prioritaria de estado, el sistema de producción predominante es el sistema vaca-becerro de condiciones extensivas, el mercado principal del sistema es la venta de becerros para engorda en corrales a Estados Unidos de América.




Figura 1. Ubicación geográfica del área de estudio.

Figure 1. Geographic location of the study area.

Área experimental

El predio ganadero utilizado tiene una extensión de 980 has, dividido en ocho potreros, se seleccionó al azar un potrero con 150 has. Para la obtención de las variables de estudio se diseñó un sistema de muestreo permanente (SMP), se establecieron 16 puntos en el terreno distribuidos en cuadrícula tratando de cubrir el área del potrero, en cada punto se fijó al suelo un poste metálico y se referencio geográficamente. Cada punto se tomó como centro de una parcela de una hectárea de superficie (100 m por 100 m), cada hectárea se subdividió en cuatro subparcelas de 25 m por 25 m, esta se denominó estación de muestreo (EM) (figura 2).




Figura 2. Ubicación de sitio de muestreo permanente dentro del predio ganadero La Cieneguilla.

Figure 2. Location of the permanent sampling site within the La Cieneguilla cattle ranch.

Medición de variables

Las variables del estudio fueron el rendimiento de la biomasa (variable dependiente) y la cobertura vegetal (variable independiente). Para obtener los datos de rendimiento la unidad experimental consistió en un aro de poliducto color naranja con un diámetro de 1.6 m y un área efectiva de 2.01 m², en cada parcela a partir del centro se lanzaron al azar cuatro aros, uno por cada subparcela tomando como referencia el norte y a favor de las manecillas del reloj. Una vez realizado esto, se inició un vuelo controlado manualmente usando un dron marca DJI Phantom 4 Pro con una cámara digital integrada de 20 megapíxeles, este fue posado encima del aro a una altura promedio de 3 m suficiente para cubrir la superficie de la unidad experimental, con la cámara posicionada de manera vertical al suelo se tomó una fotografía con una resolución menor de 1 cm, esto se realizó para los otros tres aros.

Posterior a la toma de las imágenes se procedió a cosechar la biomasa en pie que estaba contenida en cada unidad de muestreo, todo el material recolectado se depositó en bolsa de papel identificada y georreferenciada las cuales fueron enviadas al laboratorio de nutrición para determinar el contenido de materia seca en horno a 65°C por 48 horas, el resultado obtenido se consideró como rendimiento y se expresó g/m². Las imágenes obtenidas con el dron fueron resguardadas en la memoria interna, posteriormente fueron descargadas y renombradas con los datos de identificación correspondientes a cada punto y subparcela para su análisis. Después de esto las imágenes fueron clasificadas de acuerdo con los atributos de dos clases principales de píxeles (1) vegetación verde o seca y (2) suelo desnudo usando el programa CobCal V 2.1 (Ferrari *et al.*, 2009), que emplea técnicas de colorimetría para calcular el porcentaje y la superficie de la cobertura vegetal en un espacio muestral, este programa es de versión gratuita, solo requiere un poco de adiestramiento por el usuario.

Finalmente, los datos de salida proporcionan la imagen clasificada y el porcentaje de cobertura de la vegetación que se encuentra dentro de la delimitación (mascara) que es puesta por el usuario considerado la superficie de la unidad de muestreo del aro de poliducto color naranja (figura 3).

E3M3

Porcentaje de cobertura: 21.73%
 Superficie cubierta: 4,368.78cm²
 Fecha de proceso: 02/03/2022 11:48:02 a. m.

Imagen original



Imagen resultado



CobCal v2.1.0.63

Figura 3. Clasificación de imagen usando el programa CobCal 2.1.

Figure 3. Image classification using the CobCal 2.1 program.

El periodo de estudio comprendió de enero a diciembre de 2020, originalmente se planeó realizar muestreos una vez por mes, sin embargo, por cuestión de la pandemia de Covid-19 no fue posible realizar los muestreos de los meses de marzo y abril por restricciones de movilidad impuestos por la autoridad competente. Las muestras obtenidas por fecha de muestreo fueron 64 y en total para todo el estudio se recabaron 640.

Análisis estadístico

Para el análisis de la información obtenida se utilizó el programa estadístico Minitab 18. Se realizaron pruebas de rutina para corroborar la distribución normal a la variable de rendimiento, no se cumplieron los supuestos por lo cual se procedió a hacer transformaciones de la variable, el mejor ajuste a la normalidad fue con transformación Johnson. Se parearon los datos de rendimiento transformados con sus respectivos valores de cobertura vegetal para realizar el análisis de regresión lineal entre ambas variables. Del total de 640 datos pareados se dividieron al 50% y se crearon dos grupos, con el primer set se generó el Modelo _{predicción} y con el segundo set se generó el Modelo _{validación}. El modelo con el mejor ajuste fue de la forma $Y = \beta_0 + \beta_1X + \beta_2X^2$.

3. Resultados y discusión

3.1. Cobertura vegetal y producción de biomasa

El resumen estadístico de las variables del estudio se muestra en el (cuadro 1). El rango entre el valor mínimo y máximo con relación al promedio del rendimiento de la biomasa y la cobertura vegetal es cambiante dado que a lo largo del año ambas variables están correlacionadas a la precipitación pluvial y al efecto del pastoreo continuo por ganado.

Tabla 1. Estadística descriptiva de las variables evaluadas en el sitio La Cieneguilla, Durango en el año 2020.

Table 1. Descriptive statistics of the variables evaluated at the La Cieneguilla site, Durango in the year 2020.

Variable	N	Media	Desviación estándar	Coficiente de variación	Mínimo	Máximo	Asimetría	Curtosis
Rendimiento (g/m ²)	640	18.754	11.382	60.69	0.498	61.692	0.87	0.65
Cobertura vegetal (%)	640	24.126	16.213	67.20	0.390	81.570	0.47	-0.40

N = número de observaciones.

N = number of observations.

Las curvas encontradas de rendimiento y cobertura vegetal promedio mensual son muy similares, primeramente, se puede diferenciar la época de secas (enero-junio) y la época de lluvias (julio-diciembre), además se observa una estrecha relación entre ambas variables, aumentan y disminuyen armónicamente lo cual refuerza nuestra hipótesis que es posible estimar el rendimiento de la biomasa de pastizales a través de la medición de la cobertura vegetal (figura 5).

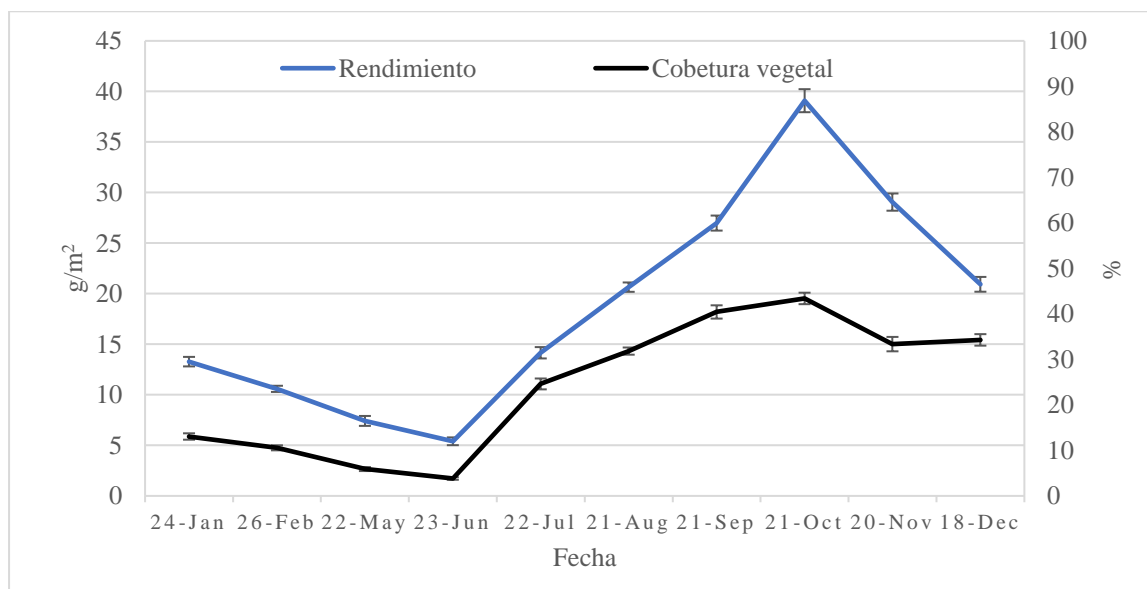


Figura 5. Comportamiento del rendimiento y cobertura vegetal durante el periodo de estudio.

Figure 5. Behavior of yield and vegetal cover during the study period.

3.2. Generación de modelos de regresión

Antes de realizar las pruebas para encontrar el modelo de predicción con el mejor ajuste se analizó la variable de rendimiento de la biomasa para corroborar los supuestos de normalidad mediante la prueba Anderson-Darling, encontrándose un valor de probabilidad <0.005 , por lo cual, se asume que los datos provienen de una población no normal o con desviación significativa de la normalidad. Tsutsumi *et al.*, (2007) mencionaron que la biomasa de pastos generalmente no se ajusta a la distribución normal y al ser analizada mediante una distribución de frecuencias se presenta un sesgo o una “cola larga”.

Para ajustar los datos a la distribución normal se procedió a realizar transformación de la variable mediante la opción de Identificación de la distribución individual en el programa Minitab18, el mejor ajuste fue con la función de transformación SB de la familia de Johnson con la variable limitada (Chou *et al.*, 1998) =

$1.59640 + 1.34320 \times \ln [(X + 2.58471) / (79.3318 - X)]$ con un valor de $p = 0.302$, cumpliendo con los supuestos de normalidad (figura 6).

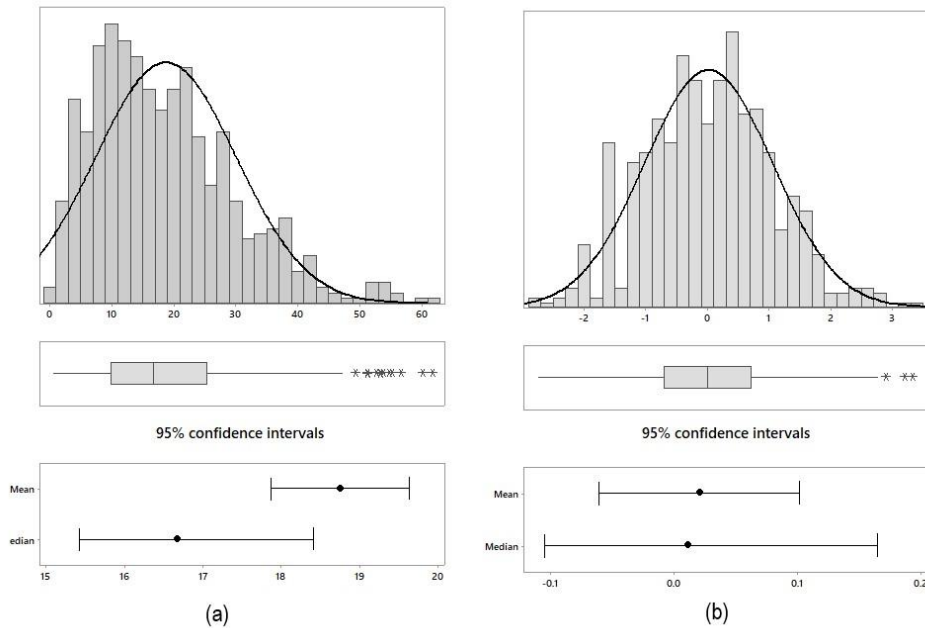


Figura 6. Distribución de frecuencias de la variable peso de la biomasa (a) sin transformación y (b) con transformación Johnson SB.

Figure 6. Frequency distribution of the biomass weight variable (a) without transformation and (b) with Johnson SB transformation.

Según Lagos y Vargas (2003), el sistema Johnson se aplica cuando el supuesto de normalidad de la característica bajo estudio no se cumple, cuando esto sucede es posible transformar los datos no-normales a datos normales, a través de técnicas como el Sistema de Familias de Distribuciones de Johnson. Los datos transformados en nuestro estudio se ajustaron a la distribución Johnson tipo SB “acotada”, cuyo objeto es aplicar los métodos y teoría de la distribución normal a un amplio rango de distribuciones no normales a través de transformaciones a partir de distribuciones exponencial y seno hiperbólico. Debido a su flexibilidad, esta distribución se emplea en varios campos como economía, ingeniería biomédica y análisis forestal (Marrone, 2017).

Los datos de la biomasa transformados fueron pareados con los datos correspondientes de la cobertura vegetal y se les asignó un número del 1 al 640, se crearon dos subgrupos con el 50% de datos cada uno, el criterio de selección de los datos de cada grupo fue de números pares para el primer grupo y números impares para el segundo grupo. El primer grupo se utilizó para generar el Modelo predicción y el segundo grupo para construir el Modelo validación.

Se realizó la primera ronda y se determinó que el Modelo de predicción que se ajusta adecuadamente a los datos es un modelo cuadrático $Y = \beta_0 + \beta_1 X + \beta_2 X^2$ el cual se puede utilizar para predecir el rendimiento de la biomasa con transformación Johnson para un valor de cobertura vegetal, con un valor de R^2 ajustado de 68.52%. En los gráficos de los residuales se detectaron ocho observaciones con residuo grande y poco común, se eliminaron dichas observaciones y se realizó la segunda ronda. Se realizó la tercera ronda eliminando tres observaciones. Finalmente, la ecuación ajustada para el modelo cuadrático que describe la relación es: $Y = -1.4312 + 0.07583 X - 0.000467 X^2$ con un valor de R^2 ajustado de 71.64% (cuadro 2).

Tabla 2. *Parámetros del Modelo predicción con el rendimiento de la biomasa (Y) versus el porcentaje de cobertura aérea (X) en La Cieneguilla, Durango, México.*

Table 2. *Parameters of the prediction model with the biomass yield (Y) versus the percentage of aerial cover (X) in La Cieneguilla, Durango, Mexico.*

Término	Coefficiente	Error estándar del coeficiente	Valor T	Valor p	Gauss Markov (residuales)	
β_0	-1.4312	0.0724	-19.78	0.000	D. Normal	Si
β_1X	0.07583	0.00611	12.41	0.000	Independencia	Si
β_2X^2	-0.000467	0.000109	-4.28	0.000	Homocedasticidad	Si

R² ajustado = 71.64%

Para el Modelo de validación se utilizó el segundo grupo de datos retenidos, se realizó la primera ronda y de manera similar el modelo con el mejor ajuste es de tipo cuadrático con un R² ajustado de 66.86%, además, resultaron 12 observaciones con residuo grande y poco común, estas fueron eliminadas y se obtuvo la ecuación ajustada para el modelo cuadrático $Y = -1.4834 + 0.08073 X - 0.000554 X^2$ con valor de R² ajustado = 69.90% (cuadro 3).

Tabla 3. *Parámetros del Modelo validación del rendimiento de la biomasa (Y) versus el porcentaje de cobertura aérea (X) en La Cieneguilla, Durango.*

Table 3. *Parameters of the biomass yield validation model (Y) versus the percentage of aerial cover (X) in La Cieneguilla, Durango.*

Término	Coefficiente	Error estándar del coeficiente	Valor T	Valor p	Gauss Markov (residuales)	
β_0	-1.4834	0.0732	-20.26	0.000	D. Normal	Si
β_1X	0.08073	0.00576	14.02	0.000	Independencia	Si
β_2X^2	-0.000554	0.000099	-5.62	0.000	Homocedasticidad	Si

R² ajustado = 69.90%

En la figura 7 se observa la distribución de los valores observados vs valores predichos para ambos modelos.




Figura 7. (a) Relación entre los valores predichos del Modelo predicción $Y = - 1.4312 + 0.07583 X - 0.000467 X^2$ y los valores observados. (b) Relación entre los valores predichos del Modelo validación $Y = - 1.4834 + 0.08073 X - 0.000554 X^2$ y los valores observados.

Figure 7. (a) Relationship between the predicted values of the Prediction Model $Y = - 1.4312 + 0.07583 X - 0.000467 X^2$ and the observed values. (b) Relationship between the predicted values of the Validation Model $Y = - 1.4834 + 0.08073 X - 0.000554 X^2$ and the observed values.

3.3. Validación de modelos de regresión

La validación de un modelo está desempeñando un papel cada vez más importante en la evaluación del rendimiento y la confiabilidad de un sistema complejo cuando se trata de modelado y simulación con el fin de tener mayor precisión de validación general de los modelos (Xiaomo *et al.*, 2013). Con ambos modelos generados se realizó una comparación estadística de sus coeficientes mediante la prueba de “t” de Student, estos no difirieron estadísticamente lo cual demuestra que el Modelo predicción fue validado con la información del Modelo validación (cuadro 4).

Tabla 4. Comparación de los coeficientes de los modelos con $t (320+320-11-12-2= 615, p<0,05) = 1.967$.

Table 4. Comparison of the coefficients of the models with $t (320+320-11-12-2= 615, p<0.05) = 1,967$.

Modelo	β_0	β_1	β_2
Predicción	-1.4312	0.07583	-0.000467
Validación	-1.4834	0.08073	-0.000554
t Student	0.070 n. s.	0.006 n. s.	0.0001 n. s.

n. s.: no significativo a $p<0,05$.

n. s.: not significant at $p<0.05$.

La cobertura vegetal y la cantidad de biomasa disponible son características de las plantas herbáceas de zonas áridas y semiáridas que cambian en respuesta a la estacionalidad de precipitación anual y al régimen de uso antrópico. Esto resulta en dificultades para elaborar planes de manejo adecuado en cuanto a la carga animal óptima en un determinado tiempo. En este sentido, es muy necesario tener una medida de la cubierta vegetal del dosel que se correlacione bien con la biomasa seca. Idealmente, si un método tiene una alta correlación positiva con la biomasa aérea, entonces el muestreo destructivo es innecesario (Marsett *et al.*, 2006). En este estudio la biomasa se correlacionó positivamente con la cobertura vegetal, este resultado es similar a lo reportado por Vanamburg *et al.*, (2006) realizaron un experimento con mediciones de biomasa cosechada de pradera de pastos cortos del este de Colorado utilizando la precisión y la eficiencia imágenes de cámaras digitales convencionales (RGB) proporcionando estimaciones razonables de la biomasa de $R^2 = 0.55$. Chávez *et al.* (2017) reportaron correlaciones superiores a las de nuestro estudio de $R^2 = 0.98$, utilizó fotografías digitales

para la estimación de la cobertura aérea usando métodos de clasificación supervisada además de muestreos para la estimación de la producción de biomasa de pastizales en seis estados en México. Sin embargo, los datos procesados corresponden a la fase lineal de la etapa de crecimiento vegetativo y nosotros consideramos la disponibilidad de biomasa anual.

Los resultados comparables de este trabajo con otros estudios se limitan en cuanto a la metodología empleada, existen trabajos diversos con el uso de fotografías obtenidas por dron y la estimación del dosel o la cobertura vegetal, pero incluyen además el cálculo indirecto de la altura de la vegetación que puede generar geometría 3D según los principios de la fotogrametría, lo cual en algunos casos mejora la precisión en la estimación de la biomasa de pastizales (Barrachina, 2015, Possoch, 2016, Lussem *et al.*, 2019, Barnetson *et al.*, 2020). Sin embargo, estos trabajos tienen algunas limitaciones importantes a considerar como es la gran cantidad de imágenes adquiridas con un levantamiento por dron sobre una determinada superficie mediante un plan de vuelo programado y un traslape mínimo del 75%, por consiguiente es muy laborioso su manejo de forma personal y deben ser procesadas en programas comerciales que ofrecen la creación de productos basadas en la nube para obtener orto mosaicos RGB y NDVI de alta resolución, pero es probable que sean costosas en grandes extensiones de pastizales (Gillan *et al.*, 2019). Otras técnicas novedosas incluyen drones con sistemas láser para adquirir información de la vegetación, por ejemplo, los sistemas Lidar se han utilizado para estimar la biomasa de pastizales (Cooper *et al.*, 2017, Wang *et al.*, 2017). Sin embargo, debido al alto costo de adquirir datos Lidar, los estudios se limitaron principalmente a áreas pequeñas y no se aplicaron ampliamente en áreas grandes (Zhang *et al.*, 2018). En nuestro estudio la adquisición de imágenes digitales fue a través de vuelos en modo manual y puntuales del dron, se utilizó un programa de licencia libre para su análisis, sólo fue necesario un entrenamiento previo para la clasificación de las imágenes y se consiguió una predicción del 70% del rendimiento de la biomasa de pastizales, por lo cual esta metodología modesta es una alternativa viable para ser considerada en estudios posteriores.

Por otro lado, la validación de los modelos de regresión es un aspecto muy importante y para realizarla existen distintas maneras. Entre otras, la retención de datos es la metodología más común para validación de modelos (Neter *et al.*, 1996). Oliveras *et al.*, (2013) retuvieron un 20% de sus muestras para validar sus modelos. En un estudio de para determinar el rendimiento de dos pastos nativos en Noruega Ancin-Murguzur *et al.*, (2019) retuvieron un 25% de las muestras para realizar validación. Bendig *et al.*, (2014) probaron cinco modelos para la estimación de biomasa fresca y seca aérea mediante validación cruzada con el 30% de retención de datos. En nuestro estudio utilizamos el 50% de los datos para realizar la validación al igual que Flombaum y Sala (2007) con un set de datos de 50%. Finalmente, Búrquez y Martínez-Yrizar (2011) recomiendan validar los modelos a través de la comparación de la cosecha directa de la biomasa aérea de años subsiguientes.

4. Conclusiones

En este estudio se presenta un método simple para estimar el rendimiento de la biomasa de pastizales basado en la relación que guarda con la cobertura vegetal, se obtuvo un modelo de regresión aplicable independientemente al estado fenológico de la vegetación y temporada del año. El coeficiente de determinación ($R^2 = 0.71$) demuestran que la cobertura vegetal derivada de imágenes RGB basadas en dron es un indicador adecuado para estimar la biomasa. Se probó la calidad del modelo de predicción anual a través de validación cruzada con la retención del 50% de los datos. La variación interanual es una característica inherente a los ecosistemas de pastizal debido a las condiciones climáticas cambiantes, precipitación y uso antrópico, entonces es importante poder validar este modelo encontrado con datos de años posteriores al estudio para para garantizar la solidez y la transferibilidad del modelo encontrado.

5. Información adicional

No.

6. Agradecimientos

Los autores agradecen al Consejo Nacional de Ciencia y Tecnología por el apoyo económico brindado a través del programa Becas Nacionales para la realización de estudios de Doctorado. Los autores agradecen las facilidades otorgadas para la realización de este trabajo de investigación al Sr. Rubén D. Gutiérrez Franco, propietario del rancho ganadero la Cieneguilla. También se agradece a los alumnos de la FAZ-UJED por el apoyo técnico para el trabajo de campo.

Información de los autores

Amaury Esquivel-Romo ^{1,2}  orcid.org/0000-0002-4208-923X
Alejandro Moreno-Reséndez ¹  orcid.org/0000-0001-8858-0190
Ulises Noel Gutiérrez-Guzmán ²  orcid.org/0000-0002-6409-1947
Francisco Gerardo Veliz-Deras ¹  orcid.org/0000-0002-5105-1508
Fernando Arellano-Rodríguez ¹  orcid.org/0000-0002-6110-5338
Jorge Arturo Bustamante-Andrade ^{1,2}  orcid.org/0000-0003-1642-3916
María Esther Rios-Vega ²  orcid.org/0000-0002-7527-9806
Apolinar González-Mancilla ²  orcid.org/0000-0002-1066-1916

Contribución de los autores en el desarrollo del trabajo

Conceptualización, AE-R, UNG-G, Análisis formal, AE-R, UNG-G, AM-R, Adquisición de fondos, AE-R, AM-R, FGV-D, Investigación, AE-R, UNG-G, FA-R, JAB-A, Metodología, AE-R, UNG-G, AM-R, Administración de proyectos, AE-R, AM-R, FGV-D, Recursos, UNG-G, JAB-A, MER-V, AG-M, Supervisión y Redacción, UNG-G, FA-R. MER-V, AG-M. Todos los autores han leído y aceptado la versión publicada del manuscrito.

Conflicto de interés

Los autores declaran que no existe conflicto de interés.

Referencias

- Ancin-Murguzur, F.J., Taff, G., Davids, C., Tømmervik, H., Mølmann, J., Jørgensen, M. (2019). Yield Estimates by a Two-Step Approach Using Hyperspectral Methods in Grasslands at High Latitudes. *Remote Sens.*, 11, 400. <https://doi.org/10.3390/rs11040400>
- Barnetson, J., Phinn, S. y Scarth, P. (2020). Estimación de la biomasa y la calidad de los pastos vegetales a partir de imágenes de UAV en los pastizales de Queensland. *AgriEngineering*, 2 (4),523-543. <https://doi.org/10.3390/agriengineering2040035>
- Barrachina, M., Cristóbal, J. and Tulla, A. F. (2015). Estimating above-ground biomass on mountain meadows and pastures through remote sensing, *Int. J. Appl. Earth Obs. Geoinf.*, 38 184 –192. <http://dx.doi.org/10.1016/j.jag.2014.12.002>
- Bendig, J., Bolten, A., Bennertz, S., Broscheit, J., Eichfuss, S. and Bareth, G. (2014). Biomass estimation of barley using Crop Area Models (CSM) derived from UAV-based RGB images. *Remote Sensing*, 6(11), 10395–1041 <https://doi.org/10.3390/rs61110395>
- Booth, D.T., Cox, S.E., Meikle, T.W. y Fitzgerald, C. (2006). The accuracy of ground-cover measurements. *Rangeland Ecology & Management* 59: 179-188. <https://doi.org/10.2111/05-069R1.1>
- Búrquez, A. y Martínez-Yrizar A. (2011). Accuracy and bias on the estimation of aboveground biomass in the woody vegetation of the Sonoran Desert. *Botany* 89: 625-633. <https://doi.org/10.1139/b11-050>
- Butt, B. M., Turner, D., Singh, A., Brottem, L. (2011). Use of MODIS NDVI to evaluate changing latitudinal gradients of rangeland phenology in Sudano-Sahelian West Africa. *Remote Sensing of Environment* 115(12):3367–3376. <https://doi.org/10.1016/j.rse.2011.08.001>

- Byrne, K.M., Lauenroth, W.K., Adler, P.B. y Byrne, C.M. (2011). Estimating aboveground net primary production in grasslands: a comparison of nondestructive methods. *Rangeland Ecology & Management* 64: 498-505. <https://doi.org/10.2111/REM-D-10-00145.1>
- Chávez, C. E., Paz P. F., y Bolaños G. M. A. (2017). Estimation of biomass and aerial cover using radiometry and digital images at the field level in grasslands and shrublands. *Terra Latinoamericana*, 35(3), 247-257. <https://doi.org/10.28940/terra.v35i3.133>
- Chen, Z., Shao, Q., Liu, J., Wang, J. (2012). Analysis of net primary productivity of terrestrial vegetation on the Qinghai-Tibet Plateau, based on MODIS remote sensing data. *Science China Earth Sciences* 55(8):1306–1312. <https://link.springer.com/article/10.1007/s11430-012-4389-0>
- Chou, Y., Polansky, A.M. y Mason, R.L. (1998). Transforming Nonnormal Data to Normality in Statistical Process Control. *Journal of Quality Technology*, 30, 133–141. <https://doi.org/10.1080/00224065.1998.11979832>
- Cong, N., Piao, S.L., Chen, A.P., Wang, X.H., Lin, S.P., Chen, S.J., Han, G.S., Zhou, X.P, Zhang. (2012). Spring vegetation green-up date in China inferred from SPOT NDVI data: A multiple model analysis. *Agricultural and Forest Meteorology* 165:104–113. <https://doi.org/10.1016/j.agrformet.2012.06.009>
- Cooper, S., Roy, D., Schaaf, C., Paynter, I. (2017). Examination of the potential of terrestrial laser scanning and structure-from-motion photogrammetry for rapid nondestructive field measurement of grass biomass. *Remote Sens.* 9, 531. <https://doi.org/10.3390/rs9060531>
- Espinoza, C., Aguilar, A.L., Martínez, E., Gómez L. y Loa E. (2000). Regiones terrestres prioritarias de México. Comisión Nacional para el Conocimiento y uso de la biodiversidad (CONABIO). México, DF. <http://www.conabio.gob.mx/conocimiento/regionalizacion/doctos/terrestres.html>
- Everson, T.M., Clarke, G.P.Y. & Everson, C.S. (1990). Precision in monitoring plant species composition in montane grasslands. *Vegetation* 88, 135–141 1990. <https://link.springer.com/article/10.1007/BF00044830>
- Ferrari, D.M., Pozzolo, O.R. & Ferrari, H.J. (2009). CobCal, software for vegetation cover estimation. National Institute of Agricultural Technology, EEA Concepción del Uruguay, Entre Ríos, Argentina. https://www.produccion-animal.com.ar/software/02-cobertura_vegetal.pdf
- Flombaum, P. y Sala, O.E. (2007). A non-destructive and rapid method to estimate biomass and aboveground net primary production in arid environments. *Journal of Arid Environments* 69: 352-358. <https://doi.org/10.1016/j.jaridenv.2006.09.008>
- Gillan, J. K., McClaran, M. P. T., Swetnam, L. y Heilman, P. (2019). Estimating Forage Utilization with Drone-Based Photogrammetric Point Clouds. *Rangeland Ecology and Management* 72(4), 575-585. <https://doi.org/10.1016/j.rama.2019.02.009>
- Grüner, E., Astor, T. y Wachendorf, M. (2019). Predicción de biomasa de pastizales templados heterogéneos utilizando un enfoque SfM basado en imágenes de UAV. *Agronomía*, 9 (2), 54. <https://doi.org/10.3390/agronomy9020054>
- Habel, J. C., Dengler, J., Janiřová, M., Török, P., Wellstein, C. y Wiezik, M. (2013). European grassland ecosystems: threatened hotspots of biodiversity. *Biodiversity and Conservation*, 22(10), 2131-2138. <https://link.springer.com/article/10.1007/s10531-013-0537-x>
- Hernández, M. L. A., Medina, C. N., Cabada, T. C. A., Avalos, C. R. (2019). Avances en la aplicación del NDVI para el monitoreo de la biomasa forrajera en un matorral arbocrasicaulescente asociado con pasto buffel. *Campo Experimental Todos Santos, CIRNO, INIFAP.* https://smcsmx.org/files/2022/Si_el_suelo_respira_tu_respiras.pdf
- Lagos, I. J. y Vargas, J. A. (2003). Sistema de familias de distribuciones de Johnson, una alternativa para el manejo de datos no normales en cartas de control. *Revista Colombiana de Estadística*, 26(1), 25-40. <http://dx.doi.org/10.15446/rce>
- Lemaire, G., Hodgson, J. y Chabbi, A. (2011). Grassland productivity and ecosystem services. *Cabi.* <https://www.cabi.org/bookshop/book/9781845938093/>

- Lussem, U., Bolten, A., Gnyp, M.L., Jasper, J. & Bareth, G. (2018). Evaluation of RGB-based vegetation indices from UAV images to estimate forage yield in grasslands. *Remote Sens Spatial Inf Sci*, 42, 1215-1219. <https://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XLII-3/1215/2018/isprs-archives-XLII-3-1215-2018.pdf>
- MacDonald, R.L., Burke, J.M., Chen, H.Y.H. y Prepas, E.E. 2012. Relationship between aboveground biomass and percent cover of ground vegetation in Canadian boreal plain riparian forests. *Forest Science* 58: 47-53. <https://doi.org/10.5849/forsci.10-129>
- Marrone, L. A. 2017. Caracterización de tráfico-distribución de Johnson SB. In XXIII Congreso Argentino de Ciencias de la Computación. La Plata. http://sedici.unlp.edu.ar/bitstream/handle/10915/63947/Documento_completo.pdf?sequence=1&isAllowed=y
- Marsett, R.C., Qi, J., Heilman, P., Sharon, H., Biedenbender, M., Watson, C., Amer S., Weltz, M., Goodrich, D. y Marsett, R. (2006). Remote Sensing for Grassland Management in the Arid Southwest. *Rangeland Ecology and Management* 59: 530–540. <https://doi.org/10.2111/05-201R.1>
- Moreno, G. C. A., Schellberg, J., Ewert, F., Bruser K., Canales-Prati, P., Linstadter, A., Oomen R. J., Ruppert, J. C. & Perelman, S. B. (2014). Response of community-aggregated plant functional traits along grazing gradients: insights from African semi-arid grasslands *Applied Vegetation Science*. 17 470–481. <https://doi.org/10.1111/avsc.12092>
- Morgan, H. R., Reid, N., & Hunter, J. T. (2017). Estimation of aboveground herbaceous biomass using visually ranked digital photographs. *The Rangeland Journal*, 40(1), 9-18. <https://doi.org/10.1071/RJ17033>
- Nafus, A.M., McClaran, M.P., Archer, S.R. y Throop, H.L. (2009). Multispecies allometric models to predict grass biomass in semidesert rangeland. *Rangeland Ecology & Management* 62: 68-72. <https://doi.org/10.2111/08-003>
- Neter, J., Kutner, M.H., Nachtsheim, C.J. y Wasserman, W. (1996). *Applied linear regression models*. 3rd ed. Irwin Inc. Chicago IL.720 p.
- Oliveras, I., Eynden, M.V.D., Malhi, Y., Cahuana, N., Menor, C., Zamora, F. y Haugaasen, T. (2013). Grass allometry and estimation of above-ground biomass in tropical alpine tussock grasslands. *Austral Ecology* 39: 408-415. <https://doi.org/10.1111/aec.12098>
- Parr, C. L., Lehmann, C. E., Bond, W. J., Hoffmann, W. A., & Andersen, A. N. 2014. Tropical grassy biomes: misunderstood, neglected, and under threat. *Trends in ecology & evolution*, 29(4), 205-213. <https://doi.org/10.1016/j.tree.2014.02.004>
- Possoc, M., Bieker, S., Hoffmeister, D., Bolten, A., Schellberg, J., Bareth, G. (2016). Multi-temporal crop surface models combined with the RGB vegetation index from UAV-based images for forage monitoring in grassland. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* 41, 991–998. <https://doi:10.5194/isprsarchives-XLI-B1-991-2016>
- Sorensen, G.E., Wester, D.B. y Rideout-Hanzak, S. (2012). A nondestructive method to estimate standing crop of purple threeawn and blue grama. *Rangeland Ecology & Management* 65: 538-542. <https://doi.org/10.2111/REM-D-11-00227.1>
- Symstad, A. J., Cody L., Wienk, and Andy D. Thorstenson. (2008). Precision, Repeatability, and Efficiency of Two Canopy-Cover Estimate Methods in Northern Great Plains Vegetation, *Rangeland Ecology and Management* 61(4), 419-429. <https://doi.org/10.2111/08-010.1>
- Teague, R., Provenza, F., Kreuter, U., Steffens, T., Barnes, M. (2013). Multi-paddock grazing on rangelands: Why the perceptual dichotomy between research results and rancher experience? *Journal of Environmental Management*. 128: 699-717. <https://doi.org/10.1016/j.jenvman.2013.05.064>
- Tsutsumi, M., Itano, S. and Shiyomi, M. (2007). Number of Samples Required for Estimating Herbaceous Biomass. *Rangeland Ecology and Management* 60: 447-452. [https://doi.org/10.2111/1551-5028\(2007\)60\[447:NOSRFE\]2.0.CO;2](https://doi.org/10.2111/1551-5028(2007)60[447:NOSRFE]2.0.CO;2)

- Vanamburg, L.K., Trlica, M.J., Hoffer, R.M. and Wertz, M.A. (2006). Terrestrial digital images for grassland biomass estimation. *International Journal of Remote Sensing*, 27(05), 939-950. <http://dx.doi.org/10.1080/01431160500114789>
- 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, 70. <https://doi.org/10.3390/agriculture8050070>
- Wang, D., Xin, X., Shao, Q., Brolly, M., Zhu, Z., Chen, J. (2017). Modeling aboveground biomass in hulunber grassland ecosystem by using unmanned aerial vehicle discrete lidar. *Sensors*. 17, 180. <https://doi.org/10.3390/s17010180>
- Xiaoke, Zhang., Xuyang, Lu., Xiaodan, Wang. (2013). Spatial-temporal variation of NDVI of different classes and groups of alpine grasslands in northern Tibet, *Mountain Research and Development*, 35(3), 254-263. <https://doi.org/10.1659/MRD-JOURNAL-D-14-00110.1>
- Zhang, H., Sun, Y., Chang, L., Qin, Y., Chen, J., Qin, Y., Du, J., Yi, S., Wang, Y. (2018). Estimation of Grassland Canopy Height and Aboveground Biomass at the Quadrat Scale Using Unmanned Aerial Vehicle. *Remote Sens.* 10, 851. <https://doi.org/10.3390/rs10060851>