



Estimación de la calidad y cantidad de pasto kikuyo [*Cenchrus clandestinum* (Hochst. ex Chiov.) Morrone] usando imágenes multiespectrales

Estimation of the quality and quantity of Kikuyo grass [*Cenchrus clandestinum* (Hochst. Ex Chiov.) Morrone] using multispectral images

William Posada-Asprilla¹; Marisol Medina-Sierra²; Mario Cerón-Muñoz³

¹Ing. Agrícola, M.Sc. Universidad de Antioquia, Facultad de Ciencias Agrarias, Grupo de Investigación GaMMA, Calle 70 No. 52-21, Medellín, Antioquia, Colombia, e-mail: wpaguardian@hotmail.com, <http://orcid.org/0000-0002-7663-1592>

²Ing. Agrónoma, M.Sc., Dr. Universidad de Antioquia, Facultad de Ciencias Agrarias, Grupo de investigación Grica, Calle 70 No. 52-21, Medellín, Antioquia, Colombia, e-mail: marisol.medina@udea.edu.co, <https://orcid.org/0000-0003-1929-8305>

³Zootecnista, M.Sc., Dr. Universidad de Antioquia, Facultad de Ciencias Agrarias, Grupo Investigación en GaMMA, Calle 70 No. 52-21, Medellín, Antioquia, Colombia, e-mail: grupogamma@udea.edu.co, <http://orcid.org/0000-0002-7233-6625>

Cómo citar: Posada-Asprilla, W.; Medina-Sierra, M.; Cerón-Muñoz, M. 2019. Estimación de la calidad y cantidad de pasto kikuyo [*Cenchrus clandestinum* (Hochst. ex Chiov.) Morrone] usando imágenes multiespectrales. Rev. U.D.C.A Act. & Div. Cient. 22(1):e1195. <https://doi.org/10.31910/rudca.v22.n1.2019.1195>

Artículo de acceso abierto publicado por Revista U.D.C.A Actualidad & Divulgación Científica bajo una licencia Creative Commons CC BY-NC 4.0

Recibido: Julio 18 de 2018

Aceptado: Marzo 19 de 2019

RESUMEN

La evaluación de las praderas destinadas a ganadería es esencial para la productividad de los animales. Los datos de sensores multiespectrales remotos aerotransportados (SM) permiten construir índices de vegetación (VI, por sus siglas en idioma inglés) y relacionarlos con características fisiológicas y biofísicas de las pasturas. El objetivo fue evaluar VI para la estimación de la cantidad y calidad de pasto kikuyo en sistemas lecheros, del norte de Antioquia, Colombia. Se calcularon 10 diferentes VI, con 168 muestras de pasto kikuyo. Las muestras fueron pesadas, para estimar la biomasa verde (BV) y analizadas por espectroscopia del infrarrojo cercano, para los contenidos de proteína bruta (PB), fibra en detergente neutro (FDN) y fibra en detergente ácido (FDA). Los datos, se analizaron usando componentes principales (CP) y modelos aditivos generalizados suavizados. Las variables que más contribuyeron a la formación de la primera componente principal

(CP1) fueron el índice de vegetación de diferencia normalizada (NDVI), el índice de vegetación simple (RVI), el índice de vegetación de diferencia normalizada verde (GNDVI), el índice clorofílico verde (C_{lg}) y la BV del pasto kikuyo. Para la segunda componente principal (CP2) fueron el índice de vegetación de diferencia normalizada borde del rojo (RNDVI), el índice borde del rojo de clorofila (C_{lrg}) y PB, FDN y FDA del pasto kikuyo. La BV fue explicada por el NDVI y PB por el RNDVI. La estimación obtenida para FDN y FDA del pasto kikuyo no fueron precisas.

Palabras clave: agricultura de precisión; calidad nutricional; ganadería de leche; índices de vegetación; proteína bruta; sensores remotos.

ABSTRACT

The evaluation of grazing lands is essential to improve livestock productivity. Data from multispectral airborne sensors allow

calculating vegetation indexes (VI) and relating them to physiological and biophysical characteristics of the pastures. The objective of this study was to evaluate the usefulness of VI to estimate the quantity and quality of Kikuyu grass in dairy farms of northern Antioquia, Colombia. We calculated 10 different VI using 168 samples of Kikuyu grass. The samples were weighted to estimate green biomass (BV) and analyzed by near infrared spectroscopy for the contents of crude protein (PB), neutral detergent fiber (FDN) and acid detergent fiber (ADF). Data were analyzed using principal components (CP) and smoothed generalized additive models. The variables that contributed most to the formation of the first principal component (CP1) were the Normalized Difference Vegetation Index (NDVI), the Simple Vegetation Index (RVI), the Normalized Difference Vegetation Green Index (GNDVI), the Green Chlorophyll Index (Clg) and the BV of Kikuyu grass. The mayor contributors to the second principal component (CP2) were the Normalized Red-Edge Vegetation Index (RNDVI), the Red-Edge Chlorophyll Index (Crlg), and the PB, NDF and FDA of Kikuyu. The NDVI explained the BV, and the RNDVI explained the PB. The FDN and FDA estimations in Kikuyu were not precise.

Keywords: precision agriculture; nutritional quality; dairy cattle; vegetation indexes; crude protein; remote sensing.

INTRODUCCIÓN

La oportuna evaluación de las praderas destinadas a ganadería es esencial para estimar la productividad y la calidad de los pastos, donde la cantidad de forraje disponible y su composición tiene influencia en los patrones de distribución del pastoreo y la producción de los animales (Tozer *et al.* 2004).

El uso de sensores remotos (SM), se ha convertido en una herramienta importante en el monitoreo de áreas dedicadas a la producción ganadera, mediante la estimación de parámetros fisiológicos y de crecimiento de las pasturas (Cáceres, 2016).

Los SM a bordo de satélites y aeronaves no tripuladas (UAV, por sus siglas en idioma inglés) captan la radiación electromagnética reflejada por las plantas, para construir índices relacionados con la producción agrícola (Shanahan *et al.* 2001); estos índices, se basan en la separación espectral de la reflectancia entre el suelo y la vegetación (Tucker, 1979).

La respuesta espectral de las plantas, se caracteriza por que la reflectividad de las longitudes de onda, entre 400 a 700nm, está controlada por la concentración de pigmentos en la hoja, principalmente, clorofila y carotenoides. Esta región, se caracteriza por baja reflectancia y transmitancia del espectro visible, debido a la fuerte absorción por los pigmentos foliares, donde la clorofila absorbe fuertemente el espectro visible alrededor de las bandas azules (B) y rojas (R) y su reflectividad en el espectro es baja, mientras que la banda espectral verde (G), se refleja con mayor fuerza (Meer & Jong, 2001).

La mayor reflectancia de la vegetación verde, cerca del 45 al 50%, se da en el infrarrojo cercano (NIR), en un rango de longitudes de

onda entre 700 a 1.300nm, causada por la difusión que resulta de los índices de refracción del líquido intracelular y de los espacios intercelulares del mesófilo de la planta; mientras que para longitudes de ondas entre 1.300 y 2.500nm, la reflectividad de las hojas es controlada por la absorción de agua, dando lugar a valores de reflectancia entre el 10 y 20% (Jacquemoud & Baret, 1990).

En la actualidad, hay un gran número de índices de vegetación (VI, por sus siglas en idioma inglés) publicados en la literatura, que han sido propuestos bajo diferentes argumentos. Aquellos que intentan aproximar relaciones entre los datos espectrales y variables biofísicas, como la biomasa y el área foliar de la vegetación, como el NDVI, índice de vegetación de diferencia normalizada, usado para estimar la cantidad, la calidad y el desarrollo de la vegetación (Rouse *et al.* 1974). El índice de vegetación de diferencia normalizada verde (GNDVI), el cual, es una variante del NDVI, que usa la banda G, en lugar de la R (Gitelson *et al.* 1996). El índice de vegetación simple (RVI) relaciona las altas reflectancias del NIR de la vegetación con las bajas del R (Pearson y Miller, 1972). El índice de vegetación mejorado (EVI) es un índice mejorado, para operar frente a vegetaciones densas y reducción de influencias atmosféricas y posee la característica de ser sensible a variaciones del dosel y del área foliar de la vegetación (Huete *et al.* 1997). El índice de vegetación de suelo ajustado (SAVI) es una mejora del NDVI, que intenta contrarrestar las influencias del brillo del suelo (Huete, 1988).

Otros VI intentan aproximar relaciones entre los datos espectrales con la clorofila, la nutrición y la senescencia de la vegetación, como el índice de vegetación de diferencia normalizada borde del rojo (RNDVI), que tienen en cuenta la diferencia de la banda del borde del rojo (RE) y el NIR (Rouse *et al.* 1974). El índice de la razón normalizado de pigmento clorofílico (NCPI) relaciona bandas dentro del espectro visible R y B (Peñuelas *et al.* 1993). El índice de clorofila verde (Clg) combina bandas del NIR y G (Gitelson *et al.* 2003). El índice Rededge de clorofila (Crlg), dado por el NIR y el RE (Gitelson *et al.* 2003) y el índice de reflectancia senescente de la planta (PSRI), combina bandas del R, G y NIR (Peñuelas *et al.* 1995).

El uso de imágenes multiespectrales son una de las herramientas tecnológicas útiles para mejorar la planificación de las actividades agrícolas (Berrío *et al.* 2015) y, entre otras aplicaciones, sirven para monitorear y estimar los rendimientos de los cultivos en campo (Mulla, 2013; Kharuf-Gutiérrez *et al.* 2018). Estudios como los de Escribano & Hernández Díaz - Ambrona (2013), Barrachina *et al.* (2010) y Cáceres (2016) propusieron una estimación de biomasa verde (BV), a través de índices de vegetación. Kawamura *et al.* (2008) y Pullanagari *et al.* (2012) evaluaron diferentes índices para dar una aproximación en los contenidos de proteína bruta (PB), fibra en detergente neutra (FDN) y ácida (FDA) de praderas de pastos.

Para Xue & Su (2017), no existe una expresión matemática única que defina todos los IV, debido a la complejidad de las diferentes combinaciones de espectros de luz, instrumentación, plataformas y resoluciones utilizadas. Por lo tanto, se han desarrollado y probado algoritmos personalizados para una variedad de aplicaciones, de acuerdo con expresiones matemáticas específicas, que combinan

radiación de luz visible, principalmente, región de espectros verdes y espectros no visibles, para obtener cuantificaciones de la superficie de la vegetación. La elección de un IV específico, se debe hacer con precaución, al analizar exhaustivamente las ventajas y las limitaciones de los IV existentes y luego combinarlos, para aplicarlos en un entorno específico o especie, como es el caso del pasto kikuyo [*Cenchrus clandestinum* (Hochst. ex Chiov.) Morrone], en condiciones de producción de leche intensivo, en trópico de altura.

El kikuyo es un pasto perenne de hábito de crecimiento estolonífero y rizomatoso, que le permite expandirse fácilmente y competir con otras especies; sin embargo, su tasa de crecimiento se ve afectada por las condiciones climáticas. Crece naturalmente en suelos profundos de origen volcánico; crece muy bien en suelos fértiles con altos niveles de nitrógeno y bien drenados, aunque tolera el encharcamiento moderado, la alta salinidad y la acidez y su nivel nutricional decrece, rápidamente, con la madurez de la planta (Marais, 2001).

El objetivo de este trabajo fue evaluar índices de vegetación en la estimación de la cantidad y la calidad de pasto kikuyo usando imágenes multiespectrales UAV, en los sistemas lecheros, del norte del departamento de Antioquia, Colombia.

MATERIALES Y MÉTODOS

El estudio, se llevó a cabo en la finca la Montaña de la Universidad de Antioquia (N6°27'094", W75°3'678"), a una altitud de 2.500m s.n.m. La especie de pasto predominante en el sitio de estudio es la poácea [*Cenchrus clandestinum* (Hochst. ex Chiov.) Morrone]. El suelo es un andisol (con base a estudios previos en el predio), con una profundidad media de 25cm.

Se distribuyeron 168 puntos de muestreo en las praderas de pasto kikuyo, usando un marco circular de 1m², con una tarjeta rotulada. En estos puntos, se cortó a 10 cm del suelo la BV, se pesó y se tomaron sub-muestras, con un peso máximo de 500g por sitio, para determinar calidad nutricional.

Las muestras fueron secadas en un horno asistido por ventilador, durante 16 horas, a 70°C. Se pesaron en una balanza antes y después del secado y luego se molieron. La materia seca resultó de la prueba gravimétrica por diferencia de peso húmedo y seco (AOAC, 1990) y los contenidos de PB, FDN y FDA, se determinaron mediante espectroscopía del infrarrojo cercano (Norris *et al.* 1976), utilizando un equipo NIRS DS 2500 FOSS®, en el laboratorio de nutrición, pastos y forrajes, de la Facultad de Ciencias Agrarias de la Universidad de Antioquia.

Los datos fueron adquiridos con un sensor multiespectral Micasense RedEdge®, con resolución radiométrica de 12 bit y 5 bandas espectrales (B, G, R, RE y NIR). Todas las imágenes, se tomaron entre las 12:00 y 13:00, en condiciones de cielo despejado. Antes del vuelo, se tomó una imagen del panel reflectante de calibración. Las misiones de vuelos fueron programadas usando Pix4D capture®. La altura de vuelo fijada fue de 50m, con una velocidad de 6m/s

y un solapamiento de frente y lateral del 80%. Se tomaron puntos de referencia (GCP), con una estación de referencia TOPCON modelo GR3, para realizar el posicionamiento del ortomosaico y corrección geométrica.

La orto rectificación y ensamblado de las imágenes en un mosaico, se realizó con el software Pix4D mapper pro®. La corrección geométrica, se efectuó posicionando los CGP en las imágenes. Los números digitales fueron convertidos en valores de reflectancia, empleando las imágenes del panel reflectante de calibración, según la tabla de Micasense®.

Los recortes de imágenes de los puntos de muestreo y los índices de vegetación, se realizaron usando las librerías rgdal (Bivand *et al.* 2016) y raster (Hijmans, 2016), del proyecto R-Software (R Core Time, 2017). Los índices de vegetación se calcularon mediante la combinación de bandas espectrales (Tabla 1).

Se realizó un análisis de componentes principales (ACP) para observar las relaciones entre los índices de vegetación y las variables BV, PB, FDN y FDA, usando la librería FactorMinerR (Sebastien *et al.* 2008), del proyecto R-Software (R Core Time, 2017). Se construyeron 8 modelos aditivos generalizado (gam), para relacionar los VI con BV, PB, FDA y FDN del pasto, usando la librería mgcv (Wood, 2018), del proyecto R-Software (R Core Time, 2017).

RESULTADOS Y DISCUSIÓN

Reflectancia de las bandas: Los valores de reflectancia (%) promedio de las muestras de pasto de kikuyo para las bandas B, G, R, RE y NIR fueron de 0,03 ± 0,01, 0,07 ± 0,02, 0,04 ± 0,01, 0,15 ± 0,05 y 0,43 ± 0,12, respectivamente (Tabla 2). Estos valores, se encuentran en los rangos reportados por Corrales *et al.* (2016), en pastos secos y verdes de Honduras y quienes destacan una fuerte absorción en las regiones del espectro visible (B, G y R) y diferencias considerables con la región NIR.

Índices de vegetación: La tabla 2 muestra los valores promedios, medianas, mínimos y máximos de los VI evaluados en el estudio. El valor del intervalo del NDVI osciló entre 0,66 y 0,89 en las muestras evaluadas y, así, el índice de vegetación, se encontró cerca de los rangos reportados por otros autores. Bastidas *et al.* (2016) evaluaron la variabilidad temporal del NDVI en fincas lecheras en el norte de Antioquia, Colombia y encontraron valores del NDVI, entre 0,40 y 0,80, mientras que, para pasturas en Dehesas, España, los valores de NDVI fueron de 0,20 y 0,68 (Escribano & Hernández Díaz - Ambrona, 2013).

Rendimiento y calidad del pasto: El intervalo de BV de los puntos muestreado osciló entre 150 a 2,710g/m². Para el caso de la PB, el promedio fue 215 ± 31,2g/kg, valor más alto al reportado por Correa *et al.* (2008), en Antioquia (205g/kg) y más bajo al reportado por León *et al.* (2007), en Cundinamarca (229g/kg). La FDN y FDA promedio en las muestras fue 562 ± 40,4g/kg y 268 ± 23,8g/kg, los cuales, son menores a los reportados por Correa *et al.* (2008), quienes reportaron 581g/kg, para FDN y 303g/kg, para FDA.

Tabla 1. Fórmulas y bandas de los índices de vegetación obtenidos con imágenes espectrales, reportados en la bibliografía.

Índices de Vegetación	Fórmula y Bandas	Autor
1. Índice de vegetación de la razón del infrarrojo cercano y el rojo (RVI)	NIR/R	Pearson & Miller (1972)
2. Índice de vegetación de diferencia normalizada (NDVI)	$(NIR-R)/(NIR+R)$	Rouse <i>et al.</i> (1974)
3. Índice de vegetación de diferencia normalizada verde (GNDVI)	$(NIR-G)/(NIR+G)$	Gitelson <i>et al.</i> (1996)
4. Índice de vegetación de diferencia normalizada borde del rojo (RNDVI)	$(NIR-RE)/(NIR+RE)$	Rouse <i>et al.</i> (1974)
5. Índice de vegetación de suelo ajustado (SAVI)	$(NIR-R)(1+L)/(NIR+R+L)$	Huete (1988)
6. Índice de vegetación mejorado (EVI)	$2,5*(NIR-R)/(NIR+6*R-7,5B+1)$	Huete & Liu (1997)
7. Índice verde de clorofila (Clg)	$(NIR/G)-1$	Gitelson <i>et al.</i> (2003)
8. Índice borde del rojo de clorofila (Clrg)	$(NIR/RE)-1$	Gitelson <i>et al.</i> (2003)
9. Índice reflectante de planta senescente (PSRI)	$(R-G)/NIR$	Peñuelas <i>et al.</i> (1995)
10. Índice de la razón de clorofila normalizado (NCPI)	$(R-B)/(R+B)$	Peñuelas <i>et al.</i> (1993)

Donde, NIR=banda infrarrojo cercano; R=banda del rojo; G=banda del verde; B=banda del azul; RE=banda del borde del rojo y L es igual a 0,5.

Tabla 2. Valores de reflectancia de las imágenes multispectrales, índices de vegetación calculados, biomasa y composición de las muestras de pasto kikuyo estudiadas.

Variable	Promedio	Mediana	Mínimo	Máximo
NDVI	0,81±0,04	0,82	0,66	0,89
RVI	11,4±2,92	11,3	5,16	20,3
GNDVI	0,71±0,03	0,71	0,59	0,78
RNDVI	0,46±0,03	0,46	0,33	0,53
SAVI	0,58±0,11	0,61	0,29	0,80
EVI	0,65±0,15	0,69	0,27	0,99
NCPI	0,16±0,04	0,15	0,05	0,28
Clg	5,11±0,82	5,01	2,92	7,52
Clrg	1,72±0,23	1,72	1,02	2,15
PSRI	-0,06±0,02	-0,06	-0,10	-0,03
BV (g/m ²)	1044±543	950	150	2710
PB (g/kg)	215±31,2	220	139	284
FDN (g/kg)	562±40,4	565	456	650
FDA (g/kg)	268±23,8	266	220	343

Donde, B=banda azul; G=banda verde; R=banda roja; RE=banda del borde del rojo; NIR=banda infrarrojo cercano; NDVI=índice de vegetación de diferencia normalizada; GNDVI=índice de vegetación de diferencia normalizada verde; Ratio=índice de vegetación simple; EVI=índice de vegetación mejorado; SAVI=índice de vegetación de suelo ajustado; RNDVI=índice de vegetación de diferencia normalizada borde del rojo; NCPI=índice ratio normalizado de pigmento clorofílico; Clg=índice de clorofila verde; Clrg=índice borde del rojo de clorofila; PSRI=índice de reflectancia senescente de la planta; BV=biomasa verde; PB=proteína bruta; FDA=fibra en detergente neutra y FDN=fibra en detergente ácida.

Análisis de componentes principales: Los dos primeros componentes principales (CP) explicaron el 70,3% de la variabilidad total observada (Figura 1). El CP1 explica el 46,2% de la variabilidad, se caracterizó por agrupar variables relacionados con características de cantidad del pasto kikuyo y VI, que emplean las bandas del visible G y R y del NIR. Para el CP1, las variables más importantes fueron la BV, NDVI, RVI, el GNDVI y el Clg, donde el NDVI es la variable que más contribuyó a la formación del eje (19,9).

El CP2 explica el 24,1% de la variabilidad, relaciona componentes de calidad del pasto y VI, que emplean la banda RE y NIR. Para

la CP2, las variables más importantes fueron la PB, FDN y FDA, RNDVI y Clrg, donde FDA y FDN presenta correlación negativa con la componente; la variable que más contribuye a la formación del segundo eje es el índice RNDVI (21,2).

Estas relaciones encontradas coinciden bien con lo que se conoce de la relación de los índices con las características fisiológicas y de crecimiento del pasto. En primera instancia, el NDVI, Clg, RVI y GNDVI son índices relacionados con características biofísicas de las plantas como área foliar y biomasa (Velasco *et al.* 2010), mientras que índices, como RNDVI, PSRI y Clrg, son relacionados

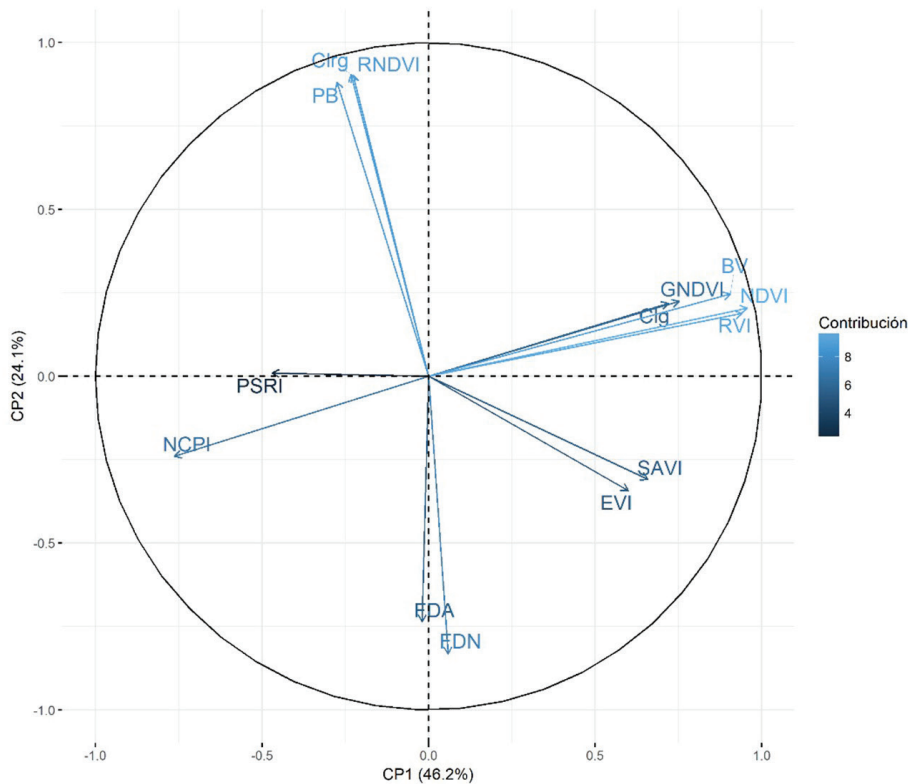


Figura 1. Análisis de componentes principales entre la producción y las características nutritivas de pasto kikuyo y los índices de vegetación, calculados a partir de imágenes multispectrales.

con características fisiológicas, como contenidos de clorofila foliar, altamente relacionada con la proteína vegetal (Richardson *et al.* 2002).

Los modelos aditivos gaussianos generalizados utilizados para relacionar las características fisiológicas y de crecimiento de las muestras de pasto kikuyo con los VI, calculados a partir de imágenes multispectrales, presentaron la siguiente estructura:

$$Y_{ij} = \beta_0 + s(N_i) + e_{ij} \tag{ecuación 1}$$

$$Y_{ij} = \beta_0 + s(R_i) + e_{ij} \tag{ecuación 2}$$

$$Y_{ij} = \beta_0 + s(G_i) + e_{ij} \tag{ecuación 3}$$

$$Y_{ij} = \beta_0 + s(C_i) + e_{ij} \tag{ecuación 4}$$

$$Z_{ij} = \beta_0 + s(RI_i) + e_{ij} \tag{ecuación 5}$$

$$Z_{ij} = \beta_0 + s(Cl_i) + e_{ij} \tag{ecuación 6}$$

$$W_{ij} = \beta_0 + s(RI_i) + e_{ij} \tag{ecuación 7}$$

$$V_{ij} = \beta_0 + s(RI_i) + e_{ij} \tag{ecuación 8}$$

Donde, Y_{ij} es la biomasa verde en g/m^2 ; Z_{ij} es la PB en g/kg ; W_{ij} es la FDN en g/kg ; V_{ij} es la FDA en g/kg ; β_0 es el intercepto; s es la función suavizada de una variable; N es el NDVI; R es el RVI;

G es el GNDVI; C es el Clg; RI es el RNDVI; Cl es el Clrg y ϵ es el efecto residual.

$$Y_{ij} = \beta_0 + s(N_i) + e_{ij}$$

Relación entre biomasa verde del pasto y los índices de vegetación: Los índices NDVI y RVI utilizados para la estimación de la BV mostraron altas correlaciones con la variable dependiente, con valores superiores de R^2 de 0,95 y desviaciones explicada mayores a 0,95, y con un valor de $p < 0,0001$, mientras que índices, como GNDVI y Clg, solo presentaron R^2 de 0,53 y 0,54, respectivamente (Figura 2).

El modelo que mejor explicó la BV con $R^2 = 0,993$, desviación explicada = 0,99 y BIC inferior fue el que consideró el NDVI como una función suavizada, con el siguiente modelo:

Donde, Y_{ij} es la biomasa verde en g/m^2 ; β_0 es el intercepto; s es la función suavizada de una variable; N_i es el NDVI y e_{ij} es el efecto residual.

Los resultados obtenidos en este estudio fueron similares a los reportados por Cáceres (2016), para la estimación de biomasa de diversos tipos de pasturas, en el departamento de Olancho (Honduras). El autor obtuvo R^2 de 0,78 y 0,82, para el RVI y NDVI; sin embargo, el EVI fue el índice que mejor relación presentó con R^2 , de 0,87. De igual manera, Edirisinghe *et al.* (2012), en estudios

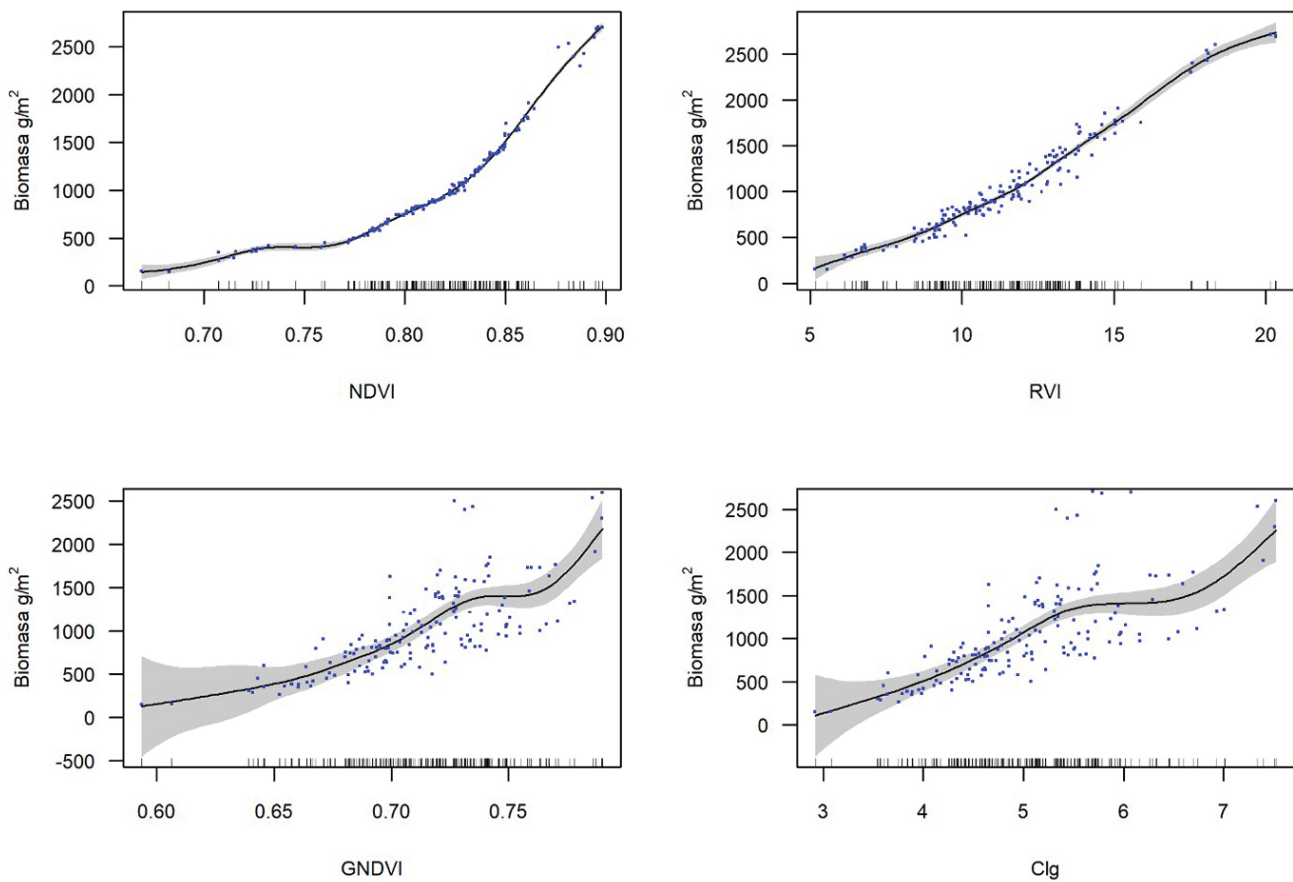


Figura 2. Relación entre diferentes índices de vegetación y la biomasa verde (BV) del pasto kikuyo.

de pasturas en los sistemas lecheros de Nueva Zelanda, encontraron correlaciones positivas (81%), entre la variable NDVI y biomasa de pastos, con un coeficiente de determinación de 0,71. Escribano *et al.* (2014), en un estudio de selección de índices de vegetación para la estimación de la producción de biomasa de pastos herbáceos en dehesas (bosque con estrato inferior de pastizales), de tres regiones de España, encontraron que el NDVI fue el índice que mejor coeficiente de determinación mostró, 0,85 y 0,89, para pasto fresco y seco, respectivamente.

Relación entre proteína cruda del pasto y los índices de vegetación: El índice RNDVI y Crg utilizados para la estimación de la proteína bruta mostraron efectos significativos con la variable dependiente, con valores superiores de R^2 , de 0,97 y con un valor de $p < 0,0001$ (Figura 3). El modelo que mejor explicó la proteína cruda con $R^2 =$

0,97, desviación explicada = 0,97 y BIC inferior fue el que consideró el RNDVI, como una función suavizada, con el siguiente modelo:

$$Z_{ij} = \beta_0 + s(RI_i) + e_{ij}$$

Donde, Z_{ij} es la proteína bruta en g/kg; β_0 es el intercepto; s es la función suavizada de una variable; RI es el RNDVI y e_{ij} es el efecto residual.

La relación entre la PB y el RNDVI fue un resultado similar a lo reportado por Richardson *et al.* (2002), quienes encontraron una alta relación entre el RNDVI y el contenido de clorofila en hojas de abedul de papel (*Betula papyrifera* Marsh), con R^2 , de 0,97. Los resultados obtenidos en este estudio concuerdan con varios autores, quienes encontraron una mejor sensibilidad en las concentraciones




Figura 3. Relación entre diferentes índices de vegetación y la proteína bruta (PB) del pasto kikuyo.

de clorofila de la vegetación y su relación con la proteína, utilizando longitudes de onda, entre 690 y 740nm, como es el caso del RNDVI y Crg, que incorporan la banda RE al análisis. Esto es debido, a que se sabe que el contenido total de clorofila está correlacionado con la posición del borde del rojo, que es la longitud de onda de la pendiente máxima del espectro de reflectancia visible. Algunas investigaciones han sugerido que puede ser algo sensible a la variación en la estructura de la hoja (Gitelson *et al.* 1996).

En un estudio en Argentina, de Castro & Garbulsky (2018), quienes evaluaron tres tipos de pasto, encontraron que los índices que explicaron mejor las variaciones de concentración de nitrógeno fueron los que combinaron la reflectancia en el borde rojo. En sistemas silvopastoriles, Serrano *et al.* (2018) encontraron una relación entre el NDVI y la proteína cruda.

Relación entre los contenidos fibrosos del pasto y los índices de vegetación: El índice RNDVI utilizado para la estimación de la FDN presentó correlación baja con la variable dependiente, con valores

de R^2 , de 0,43. Asimismo, para la estimación de la FDA, con valores de R^2 , de 0,28 (Figura 4).

En trabajos realizados por Pullanagari *et al.* (2012), utilizando un índice diferente a los estudiados denominado índice de vegetación de diferencia renormalizado RDVI, dado por $NIR - R / \sqrt{NIR + R}$ (Roujean & Breon, 1995), encontraron R^2 menor a los encontrados para FDN=0,40 y superior, para FDA =0,58. Para Castro & Garbulsky (2018), los índices de vegetación de diferencia normalizada fueron los mejores predictores para FDA y FDN y digestibilidad de la materia seca.

En general, este trabajo determinó que, entre los índices estudiados para la estimación de cantidad y de calidad en pasto kikuyo, el NDVI (índice de vegetación de diferencia normalizada) es el que mejor estima la cantidad de biomasa verde (BV) y el RNDVI (índice de vegetación de diferencia normalizada borde del rojo) es el que mejor estima la proteína bruta (PB); sin embargo, el modelo puede ser mejorado al incorporar datos, como elevación, ángulo de la

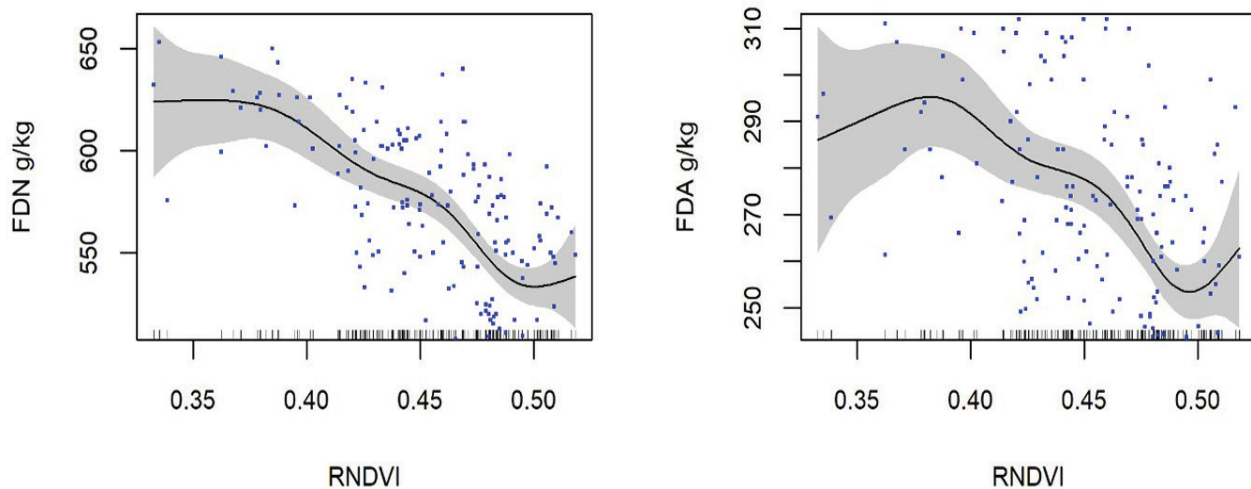


Figura 4. Relación entre el índice de vegetación borde del rojo (RNDVI) con la fibra en detergente neutra (FDN) y ácida (FDA) del pasto kikuyo.

pendiente y tipo de suelo, como lo indicaron Pullanagari *et al.* (2018), en un estudio en Nueva Zelanda, que incluyó diversos pastos, entre ellos el kikuyo, al evaluar la proteína y la energía metabolizable.

Agradecimientos: Al proyecto “Fortalecimiento de la producción de la cadena láctea del distrito Norte Antioqueño”, convenio N° 2012AS180031, firmado entre la Secretaría de Agricultura y Desarrollo Rural del Departamento de Antioquia, la Universidad Nacional de Colombia, sede Medellín y la Universidad de Antioquia. **Conflicto de intereses:** El manuscrito fue ejecutado, preparado y revisado con la participación de todos los autores, quienes declaramos que no existe conflicto de intereses que ponga en riesgo la validez de los resultados presentados. **Financiación:** Se recibió el apoyo del Sistema General de Regalías SGR y del Comité para el desarrollo de la investigación –CODI- (Estrategia para la Sostenibilidad del grupo GaMMA).

REFERENCIAS

- ASSOCIATION OF OFFICIAL ANALYTICAL CHEMISTS-AOAC. 1990. Official Methods of Analysis of the AOAC. 15th Edition. Arlington, Virginia, USA. 1008p.
- BARRACHINA, J.; CRISTOBAL, R.; TULLA, P.; ANTONI, F. 2010. Los Recursos Ganaderos en los Sistemas Extensivos de la Montaña Pirenaica Catalana: aproximación al cálculo de la producción de biomasa herbácea mediante el uso de la teledetección. *Ser. Geogr.* 16:35-49.
- BASTIDAS, A.; BARAHONA, R.; CERÓN, M. 2016. Variation in the normalized difference vegetation index (NDVI) in dairy farms in Northern Antioquia. *Livestock Research for Rural Development.* 28(3).
- BERRÍO, V.; MOSQUERA, J.; ALZATE, D. 2015. Uso de drones para el análisis de imágenes multispectrales en agricultura de precisión. *@Limentech, ciencia y tecnología alimentary.* 13(1):28-40.
- BIVAND, R.; ROWLINGSON, B. 2016. rgdal: Bindings for the Geospatial Data Abstraction Library. R package version 1.2-5
- CÁCERES, J.D. 2016. Análisis del Comportamiento Temporal de la Biomasa en Pastos del Departamento de Olancho en el Contexto del Cambio Global – fase II. *Ciencias Espaciales.* 7(1):97-114. <https://doi.org/10.5377/ce.v7i1.2528>
- CASTRO, P.A.; GARBULSKY, M.F. 2018. Spectral normalized indices related with forage quality in temperate grasses: scaling up from leaves to canopies. *Int. J Remote Sens.* 39(10):3138-3163. <https://doi.org/10.1080/01431161.2018.1430394>
- CORRALES, A.; ENRIQUE, R.; LÓPEZ, O.; VILMA, L. 2016. Firmas Espectrales de la Cobertura de la Tierra, Aplicando Radiometría de Campo. Fase 1: Región 03 occidente de Honduras. *Ciencias Espaciales.* 7:76-96. <https://doi.org/10.5377/ce.v7i1.2527>
- CORREA, C.H.; PABÓN, R.M.; CARULLA, F.J. 2008. Valor nutricional del pasto Kikuyo (*Pennisetum clandestinum* Hochst

- Ex Chiov.) para la producción de leche en Colombia (una revisión): I - Composición química y digestibilidad ruminal y posruminal. *Livestock Research for Rural Development*. 20(4):59.
10. EDIRISINGHE, A.; CLARK, D.; WAUGH, D. 2012. Spatio-temporal modelling of biomass of intensively grazed perennial dairy pastures using multispectral remote sensing. *Int. J. Appl. Earth Obs. Geoinf.* 16:5-16. <https://doi.org/10.1016/j.jag.2011.11.006>
 11. ESCRIBANO, J.; HERNÁNDEZ DÍAZ-AMBRONA, C.G. 2013. Estimación de la Producción de Pastos en Dehesas por Índices de Vegetación. *Los Pastos: Nuevos Retos, Nuevas Oportunidades. Sociedad Española para el Estudio de los Pastos.* p.465-472.
 12. ESCRIBANO, R.; DÍAZ-AMBRONA, H.; TARQUIS, A. 2014. Selección de índices de vegetación para la estimación de la producción herbácea en dehesas. *Rev. Pastos.* 44(2):6-18.
 13. GITELSON, A.A.; MERZLYAK, M.N. 1996. Signature analysis of leaf reflectance spectra: algorithm development for remote sensing of chlorophyll. *J. Plant Physiol.* 148:494-500. [https://doi.org/10.1016/S0176-1617\(96\)80284-7](https://doi.org/10.1016/S0176-1617(96)80284-7)
 14. GITELSON, A.; GRITZ, Y.; MERZLYAK, M.N. 2003. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *J. Plant Physiol.* 160:271-282. <https://doi.org/10.1078/0176-1617-00887>
 15. HIJMANS, R.J. 2016. raster: Geographic Data Analysis and Modeling. R package versión 2.5-8
 16. HUETE, A.R. 1988. A Soil-Adjusted Vegetation Index (SAVI). Department of soil and water science. University of Arizona, Tucson, Arizona 85721. *Remote Sens. Environ.* 25:295-309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
 17. HUETE, A.R.; LIU, H.Q.; BATCHILY, K.; LEEUWEN, W. 1997. A Comparison of vegetation indices over a global set of TM images for EOS-MODIS. *Remote Sens. Environ.* 59:440-451. [https://doi.org/10.1016/S0034-4257\(96\)00112-5](https://doi.org/10.1016/S0034-4257(96)00112-5)
 18. JACQUEMOUD, S.; BARET, F. 1990. PROSPECT: A model of leaf optical properties spectra. *Remote Sens. Environ.* 34:75-91. [https://doi.org/10.1016/0034-4257\(90\)90100-Z](https://doi.org/10.1016/0034-4257(90)90100-Z)
 19. KAWAMURA, K.; WATANABE, N.; SAKANOUÉ, S.; INOUE, Y. 2008. Estimating forage biomass and quality in a mixed sown pasture based on partial least squares regression with waveband selection. *Grassland Science.* 54:131-145. <https://doi.org/10.1111/j.1744-697X.2008.00116.x>
 20. KHARUF-GUTIERREZ, S.; SANTANA, L.H.; MORALES, R.O.; DÍAZ, O.A.; MORA, I.D. 2018. Análisis de imágenes multiespectrales adquiridas con vehículos aéreos no tripulados en agricultura de precisión. *RIELAC.* 39(2):79-91.
 21. LEÓN, J.; MOJICA, J.E.; CASTRO, E.; CÁRDENAS, E.; PABÓN, M.L.; CARULLA, J.E. 2007. Balance de nitrógeno y fósforo de vacas lecheras en pastoreo con diferentes ofertas de Kikuyo (*Pennisetum clandestinum*) y suplementadas con ensilaje de Avena (*Avena sativa*). *Rev. Col. Ciencias Pecuarias.* 20(4):559-570.
 22. MARAIS, J. 2001. Factors affecting the nutritive value of kikuyo grass (*Pennisetum clandestinum*)-A review. *Tropical Grasslands.* 35:65-84.
 23. MEER VAN DER, F.; JONG, S. 2001. Imaging spectrometry: basic principles and prospective applications. Dordrecht etc.: Kluwer Academic, 2001. (Remote sensing and digital image processing). Dordrecht Kluwer Academic. Vol. 4. 403p.
 24. MULLA, D.J. 2013. Twenty-five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosyst Eng.* 114(4):358-371. <http://dx.doi.org/10.1016/j.biosystemseng.2012.08.009>
 25. NORRIS, K.H.; BARNES, R.F.; MOORE, J.E.; SHENK, J.S. 1976. Predicting forage quality by infrared reflectance spectroscopy. *J. Anim. Sci.* 43(4):889-897. <https://doi.org/10.2527/jas1976.434889x>
 26. PEARSON, R.L.; MILLER, L.D. 1972. Remote Mapping of Standing Crop Biomass for Estimation of the Productivity of the Shortgrass Prairie, in Proceedings of the Eighth International Symposium on Remote Sensing of Environment, Environmental Research Institute of Michigan, Ann Arbor, MI. p.1357-1381.
 27. PEÑUELAS, J.; BARET, F.; FILELLA, I. 1995. Semi-empirical indices to assess carotenoids/chlorophyll a ratio from leaf spectral reflectance. *Photosynthetica.* 31:221-230
 28. PEÑUELAS, J.; FILELLA, I.; BIEL, C.; SERRANO, L.; SAVÉ, R. 1993. The reflectance at the 950–970 region as an indicator of plant water status. *Int. J. Remote Sens.* 14(10):1887-1905. <https://doi.org/10.1080/01431169308954010>
 29. PULLANAGARI, R.; YULE, I.; HEDLEY, M.; TUOHY, M.; DYNES, R.; KING, W. 2012. Multispectral radiometry to estimate pasture quality components. *Precision Agriculture.* 13(4):442-456.

30. PULLANAGARI, R.R.; KERESZTURI, G.; YULE, I. 2018. Integrating airborne hyperspectral, topographic, and soil data for estimating pasture quality using recursive feature elimination with random forest regression. *J. Remote Sens.* 10(7):1117. <https://doi.org/10.3390/rs10071117>
31. R CORE TEAM. 2017. R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing. Vienna, Austria
32. RICHARDSON, A.D.; DUIGAN, S.P.; BERLYN, G.P. 2002. An evaluation of noninvasive methods to estimate foliar chlorophyll content. *New Phytol.* 153:185-194. <https://doi.org/10.1046/j.0028-646X.2001.00289.x>
33. ROUJEAN, J.; BREON, F. 1995. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote Sens. Environ.* 51(3):375-384. [https://doi.org/10.1016/0034-4257\(94\)00114-3](https://doi.org/10.1016/0034-4257(94)00114-3)
34. ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W. 1974. Monitoring Vegetation Systems in the Great Plains with ERTS, Third ERTS Symposium (Washington, DC: NASA), p.309-317
35. ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W.; HARLAN, J.C. 1974. Monitoring the Vernal Advancements and Retrogradation (Greenwave Effect) of Nature Vegetation. NASA/GSFC Final Report. NASA, Greenbelt, MD, USA, p.1-137.
36. SHANAHAN, J.F.; SCHEPERS, J.S.; FRANCIS, D.D.; VARVEL, G.E.; WILHELM, W.W.; TRINGE, J.M.; MAJOR, D.J. 2001. Use of remote-sensing imagery to estimate corn grain yield. *Agron J.* 93(3):583-589. <https://doi.org/10.2134/agronj2001.933583x>
37. SEBASTIEN, L.; JULIE, J.; HUSSON, F. 2008. FactoMineR: An R Package for Multivariate Analysis. *J. Stat. Softw.* 25(1):1-18. <https://doi.org/10.18637/jss.v025.i01>
38. SERRANO, J.; SHAHIDIAN, S.; DA SILVA, J.M.; SALES-BAPTISTA, E.; DE OLIVEIRA, I.F.; DE CASTRO, J.L.; PEREIRA, A.; DE ABREU, M.C.; MACHADO, E.; DE CARVALHO, M. 2018. Tree influence on soil and pasture: contribution of proximal sensing to pasture productivity and quality estimation in montado ecosystems. *Journal of Remote Sens.* 39(14):4801-482. <https://doi.org/10.1080/01431161.2017.1404166>
39. TOZER, P.R.; BARGO, F.; MULLER, L.D. 2004. The effect of pasture allowance and supplementation on feed efficiency and profitability of dairy systems. *J. Anim. Sci.* 87:2902-2911. [https://doi.org/10.3168/jds.S0022-0302\(04\)73421-9](https://doi.org/10.3168/jds.S0022-0302(04)73421-9)
40. TUCKER, C.J. 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sens. Environ.* 8(2):127-150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)
41. VELASCO, L.S.; CHAMPO, J.O.; ESPAÑA, B.M.; BARET, F. 2010. Estimación del índice de área foliar en la reserva de la biósfera mariposa monarca. *Rev. Fitotec. Mex.* 33(2):169-174.
42. WOOD, S. 2018. "mgcv" Mixed GAM Computation with Automatic Smoothness Estimation. Version 1.8-24. Disponible desde Internet en: <https://cran.r-project.org/web/packages/mgcv/mgcv.pdf> (con acceso 23/06/2018)
43. XUE, J.; SU, B. 2017. Significant remote sensing vegetation indices: a review of developments and applications. *J. of Sensors.* 2017:1353691. <https://doi.org/10.1155/2017/1353691>