

# Modelos para la estimación del rendimiento de la caña de azúcar en Costa Rica con datos de campo e índices de vegetación

Bryan Alemán-Montes<sup>\*1,2</sup>, Pere Serra<sup>1</sup>, Alaitz Zabala<sup>1</sup>

<sup>1</sup>Departamento de Geografía de la Universidad Autónoma de Barcelona. Grupo de Investigación GRUMETS, 08193-Bellaterra, Cataluña, España.

<sup>2</sup>Centro de Investigaciones Agronómicas de la Universidad de Costa Rica, 11501-Montes de Oca, San José, Costa Rica.

**Resumen:** La teledetección proporciona información de importancia en la estimación de rendimientos de caña de azúcar, ya que su abordaje temporal y espacial permite hacer el seguimiento del cultivo durante su ciclo fenológico. El objetivo de este trabajo era aplicar un método operativo para la estimación del rendimiento agrícola e industrial a través de la combinación de variables de campo con índices de vegetación, calculados con los sensores satelitales a bordo de Sentinel-2 y Landsat-8 en una cooperativa de Costa Rica. Se utilizaron además registros históricos de cosecha y meses de inicio del ciclo fenológico para estimar mediante regresiones lineales múltiples los rendimientos. La integración de registros históricos y el índice de vegetación *Simple Ratio* (SR), calculados en distintas etapas del ciclo fenológico (en los meses de septiembre, diciembre y enero), permitió obtener un modelo de estimación del rendimiento agrícola (toneladas de caña de azúcar por hectárea) con un coeficiente de regresión ( $R^2$ ) de 0,64 y un RMSE de 8,0 ton/ha. Mientras que para el rendimiento industrial (kilogramos de azúcar refinado por tonelada de caña de azúcar) se obtuvo un  $R^2$  de 0,59 integrando variables históricas y los índices de vegetación SR y *Green Normalized Difference Vegetation Index* (GNDVI); en este caso el RMSE fue de 4,9 kg/ton. En definitiva, este modelo operativo de estimación de rendimientos proporciona herramientas para la toma de decisiones antes, durante y después de la etapa de cosecha.

**Palabras clave:** Caña de azúcar, índices de vegetación, regresiones lineales, Sentinel-2, Landsat-8.

## Models for the estimation of sugarcane yield in Costa Rica with field data and vegetation indices

**Abstract:** Remote sensing offers important inputs for sugarcane yield estimation, since its temporal and spatial approaches allow monitoring the phenological cycle of the crop. The objective of this research was to apply an operational method for the estimation of sugarcane yield and sugar content through the combination of field variables with vegetation indices, calculated with the satellite sensors on board Sentinel-2 and Landsat-8 in a cooperative from Costa Rica. In addition, historical harvest data and start months of phenological cycle were used to estimate sugarcane yield and sugar content per ton using multiple linear regressions. The integration of historical data and Simple Ratio (SR) vegetation index, calculated in different steps of the phenological cycle (in the months of September, December and January), allowed us to obtain an estimation model of sugarcane yield (tons of sugarcane per hectare) with a regression coefficient ( $R^2$ ) of 0.64 and a RMSE of 8.0 tons/ha. While for sugar content (kilograms of refined sugar per ton) we obtained a  $R^2$  of 0.59 integrating historical variables and the vegetation indexes SR and Green Normalized Difference Vegetation Index (GNDVI); in this case the RMSE was 4.9 kg/tons. Ultimately, this operational method of yield estimation provides tools for decision making before, during and after the harvest stage.

**Key words:** sugarcane, vegetation indexes, linear regression, Sentinel-2, Landsat-8.

**To cite this article:** Alemán-Montes, B., Serra, P., Zabala, A. 2023. Models for the estimation of sugarcane yield in Costa Rica with field data and vegetation indices. *Revista de Teledetección*, 61, 1-13. <https://doi.org/10.4995/raet.2023.18705>

\* Corresponding author: [bryan.aleman@ucr.ac.cr](mailto:bryan.aleman@ucr.ac.cr)

## 1. Introducción

La producción de caña de azúcar es una actividad de importancia socioeconómica para Costa Rica. En 2019 se contabilizó 64 196 ha cultivadas con caña de azúcar (INEC, 2020), que generaron aproximadamente 25 000 empleos directos y 100 000 indirectos. La actividad produce anualmente entre 200 y 250 millones de dólares entre azúcar y sus derivados (Chaves y Bermúdez, 2015).

Esta gramínea, con alta capacidad de concentración de sacarosa, se desarrolla en las regiones tropicales y subtropicales, y posee cuatro etapas fenológicas, extendiéndose cada una de ellas tres meses aproximadamente. La primera etapa es el establecimiento y germinación, caracterizada por la aparición de rebrotes que permiten la cobertura parcial del suelo con vegetación (Allison et al., 2007). Posteriormente, ocurre la etapa de desarrollo del dosel y macollamiento, en la cual el dosel del cañaveral cubre completamente el suelo; seguidamente inicia el periodo de gran crecimiento donde el cultivo intercepta un alto porcentaje de la radiación y tiene un rápido crecimiento de los tallos (Inman-Bamber, 1994). Finalmente, sucede la maduración caracterizada por un incremento de la concentración de sacarosa en tallos y reducción del área foliar (Cock, 2003; Saez, 2017).

La necesidad constante de aumentar la productividad en el cultivo de caña de azúcar, a la vez que su sostenibilidad, ha fomentado la incorporación de las herramientas geoespaciales en los procesos de toma de decisiones en el manejo de las plantaciones. Las principales líneas de investigación que involucran la caña de azúcar y las técnicas geoespaciales son: la clasificación y el mapeo de áreas de producción, la discriminación varietal, la estimación de rendimientos y el monitoreo del estado de salud de las plantaciones (Abdel-Rahman y Ahmed, 2008).

La estimación de rendimientos en caña de azúcar es quizá el componente más investigado a partir de teledetección, debido a su importancia en la gestión y programación de cosechas e industrialización. Una de las primeras investigaciones identificadas en esta línea abordó la integración

de modelos agrometeorológicos e información espectral para estimar el rendimiento agrícola (Rudorff y Batista, 1990). Por su parte la investigación realizada por Rao et al. (2002) determinó correlaciones positivas entre el índice de vegetación NDVI y rendimiento en plantaciones de caña de azúcar delimitadas mediante técnicas de clasificación supervisada. Además, el aumento en la cantidad y la calidad de información que proveen los sensores satelitales ha permitido abordar la estimación de cosechas en caña de azúcar utilizando series temporales de diversos índices de vegetación (Morel et al., 2014; Dubey et al., 2018; Rahman y Robson, 2020; Abebe et al., 2022).

En síntesis, se han utilizado múltiples fuentes de datos, índices de vegetación y enfoques de procesamiento para ajustar de forma adecuada los modelos de estimación de cosechas. Sin embargo, pese a los avances confirmados aún se carece de soluciones totalmente operacionales para la estimación de rendimientos en caña de azúcar (Abdel-Rahman y Ahmed, 2008; Som-Ard et al., 2021). El caso costarricense no es ajeno a esta realidad, ya que a partir de una revisión bibliográfica se observó un desarrollo incipiente de modelos operacionales para la estimación de rendimientos en caña de azúcar a partir de información geoespacial (Alemán-Montes et al., 2021).

En este trabajo se planteó como objetivo aplicar un método operativo para la estimación del rendimiento agrícola e industrial a través de la combinación de variables de campo con índices de vegetación, calculados con los sensores satelitales a bordo de Sentinel-2 y Landsat-8 en una cooperativa de Costa Rica. Este modelo de estimación fue ajustado a la realidad de los pequeños productores de caña de azúcar que gestionan fincas heterogéneas en términos de tamaño, prácticas de manejo agronómico y condiciones agroecológicas. En consecuencia, se intentó obtener un método operativo que fuera aplicable por los gestores de las plantaciones. La investigación, además, permitió identificar algunos de los problemas que surgen entre el complejo estado fenológico de las plantas y la información que aportan los índices de vegetación.

## 2. Materiales y Métodos

### 2.1. Área de estudio

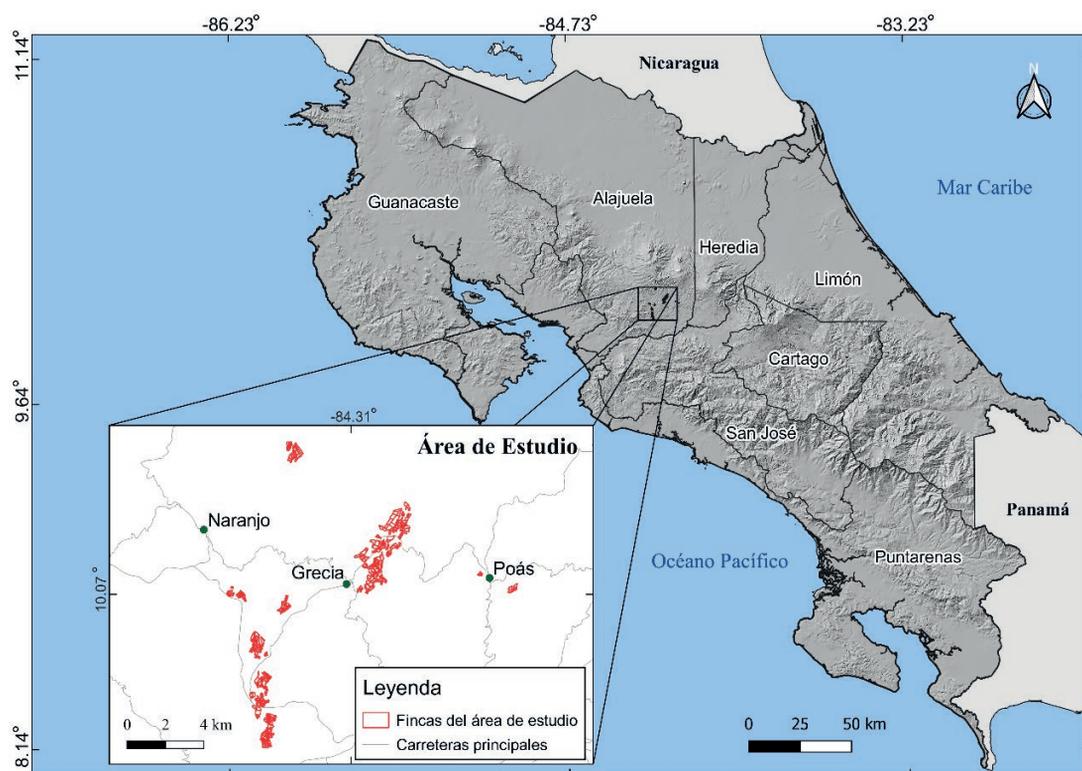
El área de estudio forma parte de las propiedades de la cooperativa CoopeVictoria R.L, localizadas principalmente en el distrito San Isidro del cantón Grecia, en la provincia Alajuela de Costa Rica (Figura 1). Esta cooperativa se dedica al cultivo e industrialización de caña de azúcar y café. Se trabajó con 26 fincas dedicadas al cultivo de la caña de azúcar, que en total suman 511 hectáreas de las cuales el 76,9% corresponde a fincas con un área inferior a 20 ha y con un promedio de 10,5 ha, el 11,5% posee entre 20 y 40 ha y el restante 11,5% tiene más de 40 ha. Las principales variedades de caña de azúcar cultivadas son RB 86-7515, LAICA 07-09 y LAICA 07-20.

El contexto del área de estudio se caracteriza por tener una época seca (diciembre - abril) y una época lluviosa (mayo - noviembre), siendo el promedio anual de lluvias entre 2000 y 3000 mm

y la temperatura promedio anual de 22 °C (IMN, 2008). Según el sistema de clasificación *The Soil Taxonomy* del Departamento de Agricultura de los Estados Unidos (USDA por sus siglas en inglés) las fincas se localizan sobre los siguientes subórdenes de suelo: Ustands y Udands, suelos desarrollados a partir de cenizas volcánicas; Ustepts, suelos con moderado desarrollo pedogenético; Orthents, suelos con muy poco desarrollo pedogenético; y la asociación Humults/Ustepts, mezcla de suelos meteorizados y suelos con moderado desarrollo pedogenético (Mata et al., 2020).

### 2.2. Materiales y Datos

Las imágenes satelitales Sentinel-2A y 2B (sensor MSI), nivel 2, fueron descargadas del portal *Copernicus Open Access Hub* de la *European Space Agency* (ESA) (<https://scihub.copernicus.eu/dhus/#/home>), mientras que las imágenes Landsat-8 (sensor OLI) fueron descargadas de la colección 2, nivel 2, disponibles en el portal *Earth*



**Figura 1.** Ubicación del área de estudio: fincas de CoopeVictoria R.L, localizadas en el cantón Grecia de la provincia Alajuela, Costa Rica. Se muestran también los centros urbanos principales.

*Explorer* del *United States Geological Survey* (USGS) (<https://earthexplorer.usgs.gov/>). El nivel 2 de procesamiento implica la obtención de imágenes con reflectancia en la superficie terrestre; las imágenes Landsat-8 son procesadas con el código de reflectancia en superficie terrestre (LaSRC por sus siglas en inglés) y las imágenes Sentinel-2 se procesan con el algoritmo Sen2Cor (ESA, 2021; USGS, 2022). Se procesó una imagen por mes, entre el mes de mayo y enero del periodo de estudio (2017-2021), obteniendo un total de 34 imágenes libres de nubes, siendo imposible incluir imágenes de junio y julio del año 2020 debido a la presencia constante de nubes. Las imágenes Sentinel-2 que se usaron fueron cuatro del 2017-2018, cinco del 2018-2019, siete del 2019-2020 y cinco del 2020-2021, mientras que de Landsat-8 se usaron cinco, cuatro, dos y dos, respectivamente.

La información de rendimiento fue obtenida en campo por CoopeVictoria R.L, durante los ciclos del cultivo: 2017-2018, 2018-2019, 2019-2020 y 2020-2021 a escala de finca. El ciclo del cultivo de esta región tarda, aproximadamente, 12 meses entre el inicio de la etapa de crecimiento ( $\approx$ abril) y la cosecha ( $\approx$ marzo). Debido al objetivo de aplicar un método operativo para los pequeños productores, se optó por emplear una regresión lineal múltiple, ya que esta técnica estadística, ampliamente utilizada en otras investigaciones, posee algunas ventajas como la aplicación rápida en modelos simples y la interpretación sencilla de los resultados (James et al., 2013; Piekutowska et al., 2021). Se introdujo como variables dependientes el rendimiento agrícola, expresado en toneladas de caña de azúcar por hectárea (ton/ha), y el rendimiento industrial, calculado en kilogramos de azúcar refinado por tonelada de caña cosechada (kg/ton). Como variables independientes se construyeron registros históricos que contemplaban el valor promedio y el máximo de los rendimientos agrícola e industrial calculados a partir de las cosechas anteriores al año de evaluación.

El periodo de cosecha se extiende entre febrero y abril de cada año, marcando el fin de un ciclo del cultivo y el inicio del siguiente, lo cual provoca una alta heterogeneidad al inicio del ciclo fenológico y en el desarrollo del cultivo. Para compensar esta variabilidad se construyó otra variable independiente: “inicio del ciclo fenológico”

( $In_{CF}$ ), la cual indica de forma ordinal el número del mes, empezando por enero, que establece el inicio de una tendencia creciente en la mediana de uno de los índices más usados en otros trabajos, el *Green Normalized Difference Vegetation Index* (GNDVI). El valor umbral aplicado fue superior a 0,2 y fue definido considerando la influencia del suelo y la escasez de vegetación de las etapas iniciales del ciclo fenológico.

### 2.3. Métodos

En este trabajo se utilizaron los siguientes índices de vegetación: el DVI (*Difference Vegetation Index*), el EVI (*Enhanced Vegetation Index*), el GNDVI (*Green Normalized Difference Vegetation Index*), el NDVI (*Normalized Difference Vegetation Index*), el RI (*Redness Index*), el RVI (*Ratio Vegetation Index*), el SAVI (*Soil Adjusted Vegetation Index*) y el SR (*Simple Ratio*) (Tabla 1). Estos índices de vegetación fueron seleccionados por su frecuente aplicación en investigaciones agrícolas (Jiménez-Jiménez et al., 2022).

Debido a las diferencias en la resolución espacial, espectral y radiométrica de las plataformas Sentinel-2 y Landsat-8 fue necesario realizar una armonización de los índices de vegetación calculados con ambos sensores. La calibración se realizó utilizando imágenes (de ambos sensores) con coincidencia en el día de captura, siendo los días seleccionados: 07-11-2016, 26-01-2017, 02-03-2018, 16-01-2019, 02-12-2019 y 05-01-2021. Se calcularon los índices de vegetación con todas las imágenes y posteriormente se extrajo la mediana de 36.570 polígonos circulares que tenían un radio de 40 metros; estos polígonos se situaban en los alrededores del área de estudio. Dicha información se utilizó para construir las regresiones lineales de armonización.

Para la estimación de los rendimientos agrícola e industrial, se calcularon los índices de vegetación de las 34 imágenes correspondientes a los años 2017 a 2021. A continuación, se extrajo la mediana de cada índice de vegetación para cada finca y, finalmente, se construyeron regresiones lineales múltiples, utilizando como variables independientes los índices de vegetación, los registros históricos y el inicio del ciclo fenológico. Estos cálculos se realizaron en el entorno de RStudio, utilizando la función `lm()`. La selección de

**Tabla 1.** Índices de vegetación utilizados como variables independientes para la estimación del rendimiento agrícola e industrial en CoopeVictoria R.L.

Índice de vegetación	Fórmula	Fuente
DVI	$\frac{NIR - Red}{NIR + Red}$	Richardson y Wiegand (1977)
EVI	$2.5 \times \frac{NIR - Red}{(NIR + C_1 Red - C_2 Blue + L)}$ $C_1 = 6, C_2 = 7.5, L = 1$	Huete et al. (2002)
GNDVI	$\frac{Green - Red}{Green + Red}$	Gitelson et al. (1996)
NDVI	$\frac{NIR - Red}{NIR + Red}$	Rouse et al. (1973)
RI	$\frac{Red - Green}{Red + Green}$	Escadafal y Huete (1991)
RVI	$\frac{Red}{NIR}$	Pearson y Miller (1972)
SAVI	$\frac{NIR - Red}{(NIR + Red + 0.5) \times (1 + 0.5)}$	Huete (1988)
SR*	$\frac{NIR}{Red}$	Jordan (1969)

\*También definido en la literatura como VIN (*Vegetation Index Number*) o RVI (*Ratio Vegetation Index*).

covariables, para cada modelo, se realizó utilizando la función `stepwise()` y el criterio de selección *bidirection* del paquete `StepReg` de RStudio desarrollado por Li et al. (2020). Los mejores modelos fueron validados mediante una validación cruzada utilizando la función `trainControl()` y el método de validación LOOCV (*Leave-one-out cross-validation*) del paquete `caret` desarrollado por Max et al. (2020), en la cual se excluye una observación de forma progresiva y se valida. Con esta validación

**Tabla 2.** Regresiones de armonización de los índices de vegetación DVI, EVI, GNDVI, NDVI, RI, RVI, SAVI y SR calculados con los sensores a bordo de los satélites Sentinel-2 (S2) y Landsat-8 (L8).

Índice de vegetación	Modelo	RMSE	R <sup>2</sup>
DVI	$y_{(S2)} = 0,96x_{(L8)} + 0$	0,025	0,84
EVI	$y_{(S2)} = 0,98x_{(L8)} - 0,02$	0,039	0,89
GNDVI	$y_{(S2)} = 1,11x_{(L8)} - 0,11$	0,031	0,93
NDVI	$y_{(S2)} = 1,13x_{(L8)} - 0,13$	0,037	0,95
RI	$y_{(S2)} = 0,99x_{(L8)} + 0$	0,033	0,94
RVI	$y_{(S2)} = 1,21x_{(L8)} - 0,01$	0,033	0,95
SAVI	$y_{(S2)} = 1,04x_{(L8)} - 0,04$	0,034	0,90
SR	$y_{(S2)} = 0,87x_{(L8)} + 0,17$	1,226	0,90

se obtuvo el RMSE (*Root Mean Square Error*) y el MAE (*Mean Absolute Error*).

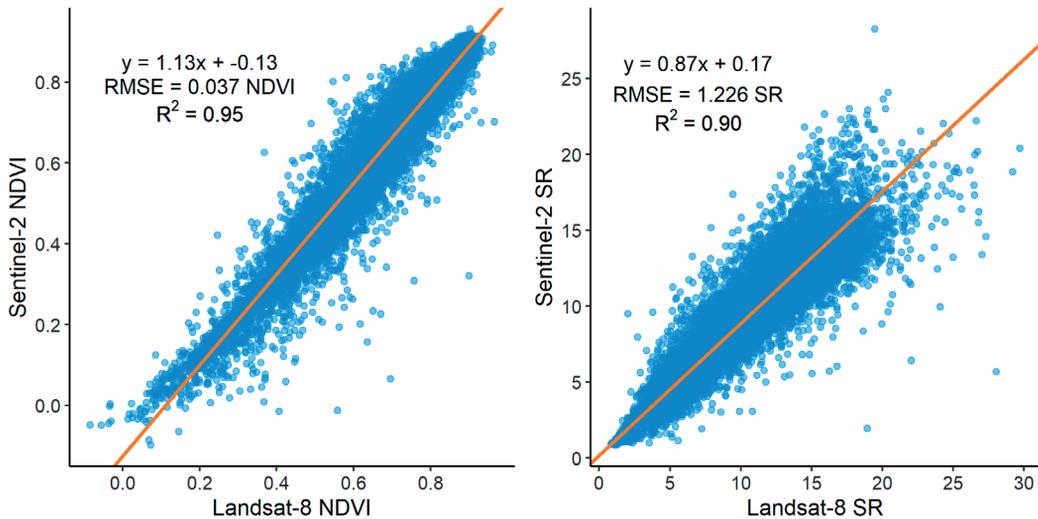
### 3. Resultados

#### 3.1. Armonización de los índices utilizados

La tabla 2 muestra los resultados de las regresiones de armonización, mientras que en la figura 2 se presentan como ejemplos los gráficos de dispersión de los índices de vegetación NDVI y SR calculados con ambos sensores. Como se observa los resultados mostraron unos R<sup>2</sup> elevados, validando el uso combinado de ambos sensores.

#### 3.2. Características del ciclo fenológico de las fincas

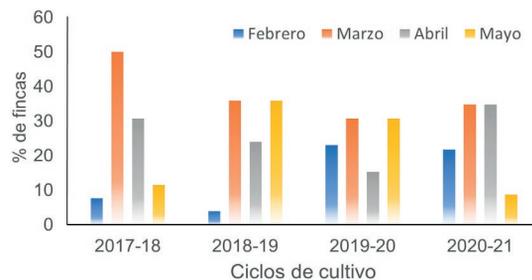
El mes de inicio del ciclo fenológico presentó una alta heterogeneidad durante el periodo de estudio debido al calendario de cosecha que en esta cooperativa se extiende de febrero a abril de cada año. Según la figura 3, durante los cuatro ciclos del cultivo analizados el porcentaje de fincas que inició el ciclo fenológico en los meses de febrero a abril varió: en el ciclo 2017-18 el 88% de las



**Figura 2.** Armonización de los índices de vegetación NDVI y SR calculados con los sensores satelitales Sentinel-2 y Landsat-8.

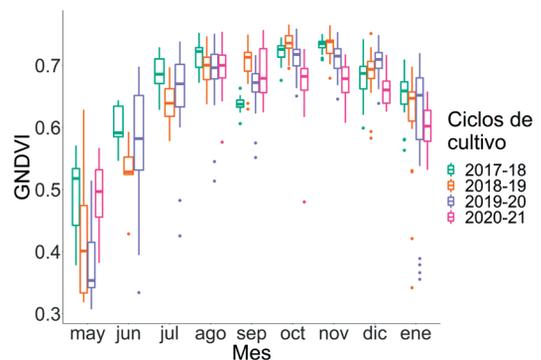
fincas inició el ciclo del cultivo entre los meses señalados, mientras que en el ciclo 2018-19 fue solo del 64%, siendo un porcentaje similar en el ciclo 2019-20, un 69%, y, finalmente, en el ciclo 2020-21 fue del 91%. Una posible causa de la alta variabilidad en el inicio de ciclo fenológico podría deberse a la gestión agronómica según la disponibilidad de mano de obra o a las diversas condiciones meteorológicas.

En consecuencia, el ciclo fenológico de las fincas presentó una gran variabilidad en las etapas iniciales y parcialmente en las posteriores durante los cuatro ciclos evaluados. Según la figura 4, en los meses de mayo, junio y julio el cultivo presentó alta variabilidad acompañada de un fuerte aumento en el valor del GNDVI, uno de los índices más usados en investigaciones con caña



**Figura 3.** Inicio del ciclo fenológico de las plantaciones según mes y ciclo de cultivo. Fuente: Alemán et al. (2022).

de azúcar como se ha comentado anteriormente. Este periodo coincide con el establecimiento de la plantación y la germinación donde el cultivo cubre parcialmente el suelo con hojas. Posteriormente, se observa una reducción en la variabilidad del índice acompañada de una relativa estacionalidad entre agosto y diciembre; durante este periodo suceden las etapas fenológicas de macollamiento y de gran crecimiento donde la cobertura del suelo es total. Finalmente, en enero se presenta una reducción en el índice acompañada del aumento en la variabilidad; estas variaciones están asociadas a la etapa final del ciclo fenológico, la maduración, donde se muestra una reducción de la cobertura



**Figura 4.** Evolución temporal de la mediana del GNDVI en las fincas de CoopeVictoria R.L, para los cuatro ciclos de cultivo evaluados. Fuente: Alemán et al. (2022).

foliar producto de la traslocación de asimilados al tallo (Cock, 2003).

### 3.3. Estimación del rendimiento agrícola

El R<sup>2</sup> en todos los índices de vegetación presentó una tendencia creciente que se inicia en junio y tiene su máximo en diciembre, con la excepción del valor R<sup>2</sup> de 0,52 obtenido por el RI en septiembre, ya que los otros índices fueron considerablemente inferiores en ese mes (Tabla 3). Los índices de vegetación SR y RI alternaron como los más adecuados para estimar el rendimiento agrícola entre los meses de julio y enero, ya que en los meses de mayo y junio los resultados fueron muy reducidos debido a la elevada heterogeneidad en las etapas iniciales de la plantación mostrada en las figuras 3 y 4. Sin embargo, se lograron mejores resultados analizando en conjunto los índices SR de agosto a enero; en concreto los meses de septiembre, diciembre y enero fueron los más explicativos tal como se observa en la ecuación 1. De igual manera, se analizaron en conjunto todos los índices de vegetación de agosto a enero con la intención de obtener mejores resultados, sin embargo, los resultados fueron inferiores a los obtenidos utilizando sólo el índice SR en distintos meses.

En la ecuación 1 se describe el modelo de regresión que presentó los mejores resultados para la estimación del rendimiento agrícola, obteniéndose un modelo que explicaba el 64% de la variación (R<sup>2</sup> de 0,64) con un error residual estándar (ERE) de 7,70 ton/ha.

$$\hat{y}=39,71+0,74\times P_{R\_AG}-5,5\times In_{CF}+3,63\times SR_{Sep}+2,21\times SR_{Dic}+1,93\times SR_{Ene}-0,5\times M_{R\_AG} \quad (1)$$

donde P<sub>R<sub>AG</sub></sub> es el promedio histórico del rendimiento agrícola, In<sub>CF</sub> indica el mes de inicio del ciclo fenológico, SR<sub>Sep</sub>, SR<sub>Dic</sub> y SR<sub>Ene</sub> son los índices SR de los meses septiembre, diciembre y enero, respectivamente, y M<sub>R<sub>AG</sub></sub> indica el máximo histórico del rendimiento agrícola obtenido por la finca. Se debe indicar que al ajustar la regresión con los índices RI (la segunda con mejores resultados) el mejor ajuste se logró considerando las mismas variables independientes en la regresión (P<sub>R<sub>AG</sub></sub>, In<sub>CF</sub>, RI<sub>Sep</sub>, RI<sub>Dic</sub>, RI<sub>Ene</sub> y M<sub>R<sub>AG</sub></sub>).

Por tanto, se extrajo del modelo que el promedio histórico de cada finca es una variable de importancia para la estimación, porque cada finca tiene un potencial máximo que se ve reflejado por su promedio histórico. Además, la fecha de inicio del ciclo fenológico (In<sub>CF</sub>) condicionó el desarrollo del

**Tabla 3.** Parámetros de ajuste de las regresiones lineales para estimar el rendimiento agrícola, en toneladas por hectárea, a partir de índices de vegetación en CoopeVictoria R.L., 2017-2020.

	Mes	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	Ene	Ago-Ene
	N	82	44	57	84	80	79	79	87	87	70
DVI	ERE <sup>+</sup>	10,13	10,69	10,37	9,84	9,53	10,13	9,55*	9,44	9,78	8,67*
	R <sup>2</sup>	0,42	0,35	0,36	0,43	0,42	0,41	0,48	0,5	0,46	0,54
EVI	ERE <sup>+</sup>	10,36	10,69	10,37	9,75	9,44	9,94	9,33*	9,30*	9,85	8,36
	R <sup>2</sup>	0,38	0,35	0,36	0,43	0,43	0,44	0,51	0,51	0,45	0,57
GNDVI	ERE <sup>+</sup>	10,36	10,69	10,37	9,97*	9,86	10,32*	9,94*	9,32*	9,84	8,74
	R <sup>2</sup>	0,38	0,35	0,36	0,4	0,38	0,39	0,44	0,51	0,45	0,53
NDVI	ERE <sup>+</sup>	10,36	10,69	10,16	9,89*	9,49*	10,08*	9,66*	9,43*	9,95	8,35
	R <sup>2</sup>	0,38	0,35	0,39	0,41	0,43	0,42	0,47	0,5	0,44	0,58
RI	ERE <sup>+</sup>	10,36	10,69	9,82	9,62	8,74	9,64	9,22	9,57	9,89	7,82
	R <sup>2</sup>	0,38	0,35	0,43	0,45	0,52	0,47	0,52	0,48	0,45	0,63
RVI	ERE <sup>+</sup>	10,36	10,69	10,37	10,09	9,51	10,12	9,73	9,46	10,04	8,45
	R <sup>2</sup>	0,38	0,35	0,36	0,38	0,43	0,42	0,46	0,49	0,43	0,56
SAVI	ERE <sup>+</sup>	10,36	10,69	10,37	9,8	9,5	10,13	9,52*	9,26*	9,86	8,42
	R <sup>2</sup>	0,38	0,35	0,36	0,42	0,43	0,41	0,49	0,52	0,45	0,57
SR	ERE <sup>+</sup>	10,36	10,69	9,84	9,68	9,22	9,82	9,5	9,23	9,51	7,7
	R <sup>2</sup>	0,38	0,35	0,43	0,44	<b>0,47</b>	0,45	0,49	<b>0,52</b>	<b>0,49</b>	<b>0,64</b>

\* Error residual estándar. \* Intercepto sin significancia estadística (p-valor > 0,05). N=número de observaciones. En la columna Ago-Ene se resalta el valor R<sup>2</sup> máximo de 0,64 que se obtiene al incluir con las variables independientes los índices SR de septiembre, diciembre y enero (en negrita).

cultivo y el tiempo que se mantuvo la plantación en el campo antes ser cosechada. Por su parte, el SR presentó un aporte aditivo cuando se incorporó en los meses de septiembre, diciembre y enero. Finalmente, la influencia negativa del máximo histórico de producción se conceptualiza como un ajuste final a la estimación. A través de los parámetros de validación cruzada del modelo, se obtuvo un RMSE de 8,0 ton/ha (un 8,6% del promedio de rendimiento agrícola de la Cooperativa durante los ciclos de cultivo analizados) y un MAE de 6,6 ton/ha.

### 3.4. Estimación del rendimiento industrial

En la estimación del rendimiento industrial, los índices de vegetación mostraron mayor variación en los meses evaluados. A diferencia del rendimiento agrícola, el rendimiento industrial no presentó tendencias crecientes en el coeficiente de regresión. El R<sup>2</sup> entre agosto y enero fue inferior a 0,4; sin embargo, se lograron mejores resultados cuando se analizaron en conjunto los índices de agosto a enero, siendo la integración de índices GNDVI la que presentó el modelo más ajustado con un R<sup>2</sup> de 0,47 (Tabla 4).

Pese a lo anterior, y con el objetivo de mejorar los resultados de esta estimación, se analizaron en conjunto todos los índices de vegetación de agosto a enero, seleccionándose los meses más explicativos, lo cual permitió alcanzar un coeficiente de regresión de 0,59 y un error residual estándar de 4,7 kg/ton. Estos resultados fueron posibles con la inclusión del promedio histórico del rendimiento industrial y los índices SR de agosto y los GNDVI de septiembre y noviembre (Ecuación 2).

$$\hat{y} = -61,93 + 0,53 \times P_{R\_IN} - 1,25 \times SR_{Ago} + 81,07 \times GNDVI_{Sep} + 106,57 \times GNDVI_{Nov} \quad (2)$$

donde P<sub>R\_IN</sub> es el promedio histórico del rendimiento industrial, SR<sub>Ago</sub> es el valor del índice SR en agosto y los índices de vegetación GNDVI<sub>Sep</sub> y GNDVI<sub>Nov</sub> representan el índice de vegetación GNDVI en los meses septiembre y noviembre respectivamente. La ecuación 2 confirma la importancia que tienen las variables históricas en las estimaciones de rendimiento. El índice SR en agosto representó un aporte decreciente, mientras los índices GNDVI de septiembre y noviembre tuvieron aportes aditivos en la estimación.

Mediante la validación cruzada del rendimiento industrial se obtuvo un RMSE de 4,9 kg/ton y un

**Tabla 4.** Parámetros de ajuste de las regresiones lineales para estimar el rendimiento industrial, en kilogramos de azúcar por tonelada, a partir de índices de vegetación en CoopeVictoria R.L, 2017-2020.

	Mes	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	Ene	Ago-Ene
	N	88	47	62	90	84	85	84	93	93	70
DVI	ERE <sup>+</sup>	7,35	6,88	7,25	7,20	6,85	6,72	7,26*	6,74	7,18	6,37*
	R <sup>2</sup>	0,23	0,37	0,37	0,25	0,25	0,33	0,27	0,33	0,24	0,39
EVI	ERE <sup>+</sup>	7,35	6,88	7,32	7,32	6,67	6,88	7,46	6,97*	7,16	5,83
	R <sup>2</sup>	0,23	0,37	0,36	0,22	0,29	0,30	0,23	0,29	0,24	0,41
GNDVI	ERE <sup>+</sup>	7,35	6,88	7,49	7,14	6,57	6,43*	6,76*	7,09*	7,05	5,53
	R <sup>2</sup>	0,23	0,37	0,32	0,27	<b>0,31</b>	0,39	<b>0,37</b>	0,26	0,28	0,47
NDVI	ERE <sup>+</sup>	7,35	6,88	7,49	7,17	6,47*	6,61*	6,9*	7,17*	7,14	6,13*
	R <sup>2</sup>	0,23	0,37	0,32	0,26	0,33	0,36	0,34	0,25	0,26	0,43
RI	ERE <sup>+</sup>	7,35	6,88	7,36	7,32	6,59	7,06	7,40	7,24	7,18	6,33
	R <sup>2</sup>	0,23	0,37	0,35	0,22	0,31	0,25	0,24	0,23	0,25	0,41
RVI	ERE <sup>+</sup>	7,35	6,88	7,36	7,06	6,49	6,75	6,79	7,19	7,25	6,09
	R <sup>2</sup>	0,23	0,37	0,35	0,28	0,33	0,33	0,36	0,24	0,23	0,44
SAVI	ERE <sup>+</sup>	7,35	6,88	7,47	7,32	6,76	6,64	7,13	6,8	7,19	6,52*
	R <sup>2</sup>	0,23	0,37	0,32	0,22	0,27	0,35	0,29	0,32	0,24	0,35
SR	ERE <sup>+</sup>	7,35	6,88	7,49	7,32	6,64	6,48	6,77	7,07	7,02	6,21
	R <sup>2</sup>	0,23	0,37	0,32	<b>0,22</b>	0,30	0,39	0,36	0,27	0,29	0,42

\* Error residual estándar. \* Intercepto sin significancia estadística (p-valor > 0,05). N=número de observaciones. Los valores resaltados, en negrita, indican la mejor combinación de índices de vegetación con el promedio histórico del rendimiento industrial, con un R<sup>2</sup> de 0,59.

MAE de 4,1 kg/ton, lo cual corresponde aproximadamente a 0,4 ton de azúcar/ha y 0,3 ton de azúcar/ha, respectivamente. Estos valores de validación representan aproximadamente un 4% del promedio del rendimiento industrial en la Cooperativa (119,8 kg/ton y 10,7 ton de azúcar/ha).

#### 4. Discusión

En Costa Rica, como en otros países del mundo, es difícil obtener imágenes satelitales libres de nubes, acentuándose el problema en época lluviosa, siendo necesario establecer estrategias que maximicen las posibilidades de obtener información de calidad. Una posible solución es la combinación de diferentes sensores, táctica empleada y validada en múltiples estudios (Panigrahy y Sharma, 1997; Bégué et al., 2010; Zhao et al., 2016; Chaves et al., 2020). En esta investigación, la combinación de los sensores Sentinel-2 y Landsat-8, después de aplicar regresiones de armonización, permitió completar con garantías una serie temporal que cubre el ciclo fenológico del cultivo en intervalos mensuales.

En la estimación del rendimiento agrícola, los índices de vegetación que presentaron los mejores resultados (SR y RI) coinciden en la necesidad de utilizar información en distintos momentos del ciclo fenológico para obtener mejores resultados (Rahman y Robson, 2016). En este estudio los índices de vegetación calculados en los meses de septiembre, diciembre y enero permitieron obtener los mejores modelos de estimación del rendimiento agrícola, confirmando que utilizar datos de un único momento fenológico no es suficiente para realizar estimaciones acertadas (Som-Ard et al., 2021). Durante estos meses el cultivo atraviesa las etapas de gran crecimiento e inicio de la maduración, resaltando la necesidad de disponer de información en la etapa de máxima cantidad de biomasa y en el punto donde sucede el descenso del área foliar por la maduración (Abebe et al., 2022).

En investigaciones de estimación del rendimiento agrícola a partir de índices de vegetación existen diversos ejemplos del uso del índice SR como un predictor debido a su elevada correlación positiva con el contenido de clorofila (Simões et al., 2005; Sishodia et al., 2020; Abebe et al., 2022). En el caso específico de las plantaciones de caña de

azúcar, al estar la clorofila foliar estrechamente relacionada con el contenido de nitrógeno y este con la producción de biomasa, se esperaría que las variaciones en clorofila ocasionen cambios en la productividad, lo cual sería fácilmente identificado por los índices SR (Haboudane et al., 2002; Narmilan et al., 2022). Un ejemplo de la utilidad del índice SR se muestra en el trabajo de Zumo y Hashim (2020) en el cual aparece como el mejor predictor para estimar la biomasa aérea en gramíneas.

Existen diversas investigaciones similares en las que se aplicaron regresiones lineales para estimar el rendimiento agrícola a partir de información satelital, obteniéndose diferentes valores de RMSE. En la isla Reunión, Morel et al. (2014) utilizando regresiones lineales y el índice de vegetación NDVI obtuvieron un RMSE de 10,4 ton/ha. En el artículo de revisión de Som-Ard et al. (2021) se calculó un RMSE promedio de 12,9 ton/ha, considerando todos los trabajos revisados que usaban información satelital y regresiones. Por su parte, Dubey et al. (2018) alcanzaron un RMSE entre 7,0 y 17,0 ton/ha al estimar el rendimiento agrícola a partir de índices de vegetación en tres regiones de India. En consecuencia, los resultados aportados en este trabajo, con un RMSE de 8,0 ton/ha, muestran, conjuntamente con los citados anteriormente, que a través de un método operativo simple ajustado a partir de parámetros de campo se pueden obtener modelos robustos. Además, estos modelos operativos también pueden lograr buenos resultados en comparación a técnicas más complejas, como en el caso del *machine learning*. Por ejemplo, en Brasil dos Santos Luciano et al. (2021) obtuvieron un RMSE de 9,4 ton/ha al estimar el rendimiento agrícola utilizando *machine learning* y como variables independientes imágenes satelitales, datos meteorológicos y variables agronómicas; sin embargo, utilizando idéntica técnica y las mismas variables Shendryk et al. (2021) alcanzaron un RMSE superior a 16 ton/ha.

Por otra parte, el modelo de estimación del rendimiento industrial concuerda con el rendimiento agrícola en la necesidad de contar con información histórica de producción que sirva de base para comprender el potencial productivo de cada finca. El promedio histórico de rendimiento se ha usado en otros trabajos como variable

independiente, incrementando el poder predictivo del modelo (Krupavathi et al., 2022). Además, en nuestra investigación fue fundamental la complementariedad de los índices de vegetación, SR y GNDVI, lo cual valida la existencia de índices de vegetación que se adaptan de mejor forma a distintas etapas del ciclo de crecimiento (Simões et al., 2005). Asimismo, resulta esencial considerar el ciclo fenológico completo debido a la importancia que tienen las prácticas agronómicas en el desarrollo del cultivo y por consiguiente en las estimaciones de rendimiento (Bégué et al., 2010).

La validación del rendimiento industrial mostró un RMSE de 0,4 ton de azúcar/ha; este ajuste es superior al reportado por Shendryk et al. (2021) quienes utilizando técnicas de *machine learning* alcanzaron un RMSE de 2,3 ton de azúcar/ha al evaluar el rendimiento industrial a nivel de finca y un RMSE de 1 ton de azúcar/ha al agrupar el rendimiento industrial por ingenio azucarero, creando así un modelo más general.

Finalmente, a pesar de disponer de datos de campo fiables, incluyendo el rendimiento histórico que puede ser una variable no siempre disponible, el contexto general es de carencia de otros datos que pueden estar muy relacionados con el objetivo principal, como datos climáticos, información varietal o la fecha concreta de la cosecha, aspectos que en futuras investigaciones serán incluidos y evaluados.

## 5. Conclusiones

En este trabajo se ha desarrollado un modelo de predicción del rendimiento agrícola e industrial a través de una serie mensual de imágenes Sentinel-2 y Landsat-8, logrando así el ajuste de modelos operativos que permiten apoyar el proceso de toma de decisiones en la cosecha e industrialización de la caña de azúcar en una cooperativa de Costa Rica.

Los mejores resultados, con un  $R^2$  de 0,64 (RMSE de 8,0 ton/ha) para el rendimiento agrícola y de 0,59 (RMSE de 4,9 kg/ton) para el rendimiento industrial, se obtuvieron incluyendo en los modelos índices calculados durante las diferentes etapas del ciclo del cultivo, lo cual valida la funcionalidad de las series temporales de los índices de vegetación en el seguimiento de cultivos,

particularmente en el de caña de azúcar. El índice SR, al no estar normalizado, posee un umbral de valores más amplio y esto podría estar relacionado con la mayor capacidad de predicción, ya que la magnitud de las diferencias entre dos condiciones se amplía. No obstante, debido a que las fincas presentan ciclos fenológicos diferentes, se produce una elevada variabilidad en los valores de los índices, en general, repercutiendo en el ajuste de los modelos de regresión.

Para mejorar la capacidad predictiva de los modelos se podrían incluir variables independientes como la fecha específica de cosecha, el clima local o la variedad de caña de azúcar. En seguimiento a esta investigación se plantea realizar procesos de validación de los modelos con datos de campo obtenidos en futuras temporadas de cosecha y en otras cooperativas.

Finalmente, los modelos operativos obtenidos en la estimación de los rendimientos proporcionan unas herramientas muy útiles para la toma de decisiones antes, durante y después de la etapa de cosecha. Por ejemplo, la estimación de la producción previa a la cosecha permite gestionar las actividades relacionadas, destacando el transporte (cuanto volumen necesitan transportar), la mano de obra (cuantos operarios se requieren) y el proceso de industrialización (cuanto volumen de caña fresca se necesita procesar para la producción de azúcar).

## Agradecimientos

Los autores agradecen al Departamento Agrícola de CoopeVictoria R.L por el apoyo en el desarrollo de esta investigación. Además, se extiende el agradecimiento a la Universidad de Costa Rica, que a través de la Oficina de Asuntos Internacionales y Cooperación Externa (OAICE) ha financiado este trabajo, mediante el número de contrato OAICE-59-2021.

## Referencias

- Abdel-Rahman, E.M., Ahmed, F.B. 2008. The application of remote sensing techniques to sugarcane (*Saccharum* spp. hybrid) production: A review of the literature. *International Journal of Remote Sensing*, 29(13), 3753–3767. <https://doi.org/10.1080/01431160701874603>

- Abebe, G., Tadesse, T., Gessesse, B. 2022. Combined Use of Landsat 8 and Sentinel 2A Imagery for Improved Sugarcane Yield Estimation in Wonji-Shoa, Ethiopia. *Journal of the Indian Society of Remote Sensing*, 50, 143–157. <https://doi.org/10.1007/s12524-021-01466-8>
- Alemán-Montes, B., Henríquez-Henríquez, C., Ramírez-Rodríguez, T., Largaespada-Zelaya, K. 2021. Estimación de rendimiento en el cultivo de caña de azúcar (*Saccharum officinarum*) a partir de fotogrametría con vehículos aéreos no tripulados (VANT). *Agronomía Costarricense*, 45(1), 67–80. <https://doi.org/10.15517/rac.v45i1.45695>
- Alemán, B., Serra, P., Zabala, A. 2022. Estimación del rendimiento de la caña de azúcar en Costa Rica con datos de campo e índices de vegetación. En L.Á. Ruiz Fernández, J. Estornell Cremades, M. González de Audicana Amenábar, J. Álvarez Mozos (Ed.), *XIX Congreso de la Asociación Española de Teledetección*, 27–30.
- Allison, J.C.S., Pammenter, N.W., Haslam, R.J. 2007. Why does sugarcane (*Saccharum sp. hybrid*) grow slowly? *South African Journal of Botany*, 73(4), 546–551. <https://doi.org/10.1016/j.sajb.2007.04.065>
- Bégué, A., Lebourgeois, V., Bappel, E., Todoroff, P., Pellegrino, A., Baillarin, F., Siegmund, B. 2010. Spatio-temporal variability of sugarcane fields and recommendations for yield forecast using NDVI. *International Journal of Remote Sensing*, 31(20), 5391–5407. <https://doi.org/10.1080/01431160903349057>
- Canata, T.F., Wei, M.C.F., Maldaner, L.F., Molin, J.P. 2021. Sugarcane yield mapping using high-resolution imagery data and machine learning technique. *Remote Sensing*, 13(2), 1–14. <https://doi.org/10.3390/rs13020232>
- Chaves, M., Bermúdez, L. 2015. Agroindustria azucarera costarricense: un modelo organizacional y productivo efectivo con 75 años de vigencia. Introducción. En *Departamento de investigación y extensión de la caña de azúcar (DIECA)*.
- Chaves, M., Picoli, M., Sanches, I. 2020. Recent applications of Landsat 8/OLI and Sentinel-2/MSI for land use and land cover mapping: A systematic review. *Remote Sensing*, 12(18). <https://doi.org/10.3390/rs12183062>
- Cock, J.H. 2003. Sugarcane growth and development. *International Sugar Journal*, 105(1259), 540–552.
- Dubey, S.K., Gavli, A.S., Yadav, S.K., Sehgal, S., Ray, S.S. 2018. Remote Sensing-Based Yield Forecasting for Sugarcane (*Saccharum officinarum* L.) Crop in India. *Journal of the Indian Society of Remote Sensing*, 46(11), 1823–1833. <https://doi.org/10.1007/s12524-018-0839-2>
- ESA, (European Space Agency). 2021. *S2 MPC Sen2Cor Software*.
- Escadafal, R., Huete, A. 1991. Étude Des Propriétés Spectrales Des Sols Arides Appliquée à Lamélioration Des Indices de Vegetation Obtenus Par Télédection. *CR Académie des Sciences de Paris*, 312(2), 1385–1391. <http://www.scopus.com/inward/record.url?eid=2-s2.0-0026305591&partnerID=40&md5=1a9a77276f4613b8eec010a111f41ff0>
- Gitelson, A.A., Kaufman, Y.J., Merzlyak, M.N. 1996. Use of a green channel in remote sensing of global vegetation from EOS- MODIS. *Remote Sensing of Environment*, 58(3), 289–298. [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)
- Haboudane, D., Miller, J.R., Tremblay, N., Zarco-Tejada, P.J., Dextraze, L. 2002. Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. *Remote Sensing of Environment*, 81(2-3), 416–426. [https://doi.org/10.1016/S0034-4257\(02\)00018-4](https://doi.org/10.1016/S0034-4257(02)00018-4)
- Huete, A. 1988. A Soil-Adjusted Vegetation Index (SAVI). *Remote Sensing of Environment*, 25(1), 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Huete, A., Didan, K., Miura, T., Rodriguez, E.P., Gao, X., Ferreira, L.G. 2002. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(12), 195–213. [https://doi.org/https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/https://doi.org/10.1016/S0034-4257(02)00096-2)
- IMN, (Instituto meteorológico Nacional de Costa Rica). 2008. *Atlas climático de Costa Rica*. <https://www.imn.ac.cr/atlas-climatologico>
- INEC (Instituto Nacional de Estadística y Censos). 2020. *Encuesta Nacional Agropecuaria 2019: Resultados Generales de la Actividad Agrícola y Forestal*. <https://inec.cr/estadisticas-fuentes/encuestas/encuesta-nacional-agropecuaria?page=7>
- Inman-Bamber, N.G. 1994. Temperature and seasonal effects on canopy development and light interception of sugarcane. *Field Crops Research*, 36(1), 41–51. [https://doi.org/10.1016/0378-4290\(94\)90051-5](https://doi.org/10.1016/0378-4290(94)90051-5)
- James, G., Witten, D., Trevor, H., Tibshirani, R. 2013. *An Introduction to Statistical Learning - with Applications in R*, Gareth James, Springer. <https://doi.org/10.1007/978-1-4614-7138-7>

- Jiménez-Jiménez, S.I., Marcial-Pablo, M. de J., Ojeda-Bustamante, W., Sifuentes-Ibarra, E., Inzunza-Ibarra, M.A., Sánchez-Cohen, I. 2022. VICAL: Global Calculator to Estimate Vegetation Indices for Agricultural Areas with Landsat and Sentinel-2 Data. *Agronomy*, 12(7). <https://doi.org/10.3390/agronomy12071518>
- Jordan, C.F. 1969. Derivation of Leaf-Area Index from Quality of Light on the Forest Floor. *Ecology*, 50(4), 663–666. <https://doi.org/10.2307/1936256>
- Krupavathi, K., Raghobabu, M., Mani, A., Parasad, P.R.K., Edukondalu, L. 2022. Field-Scale Estimation and Comparison of the Sugarcane Yield from Remote Sensing Data: A Machine Learning Approach. *Journal of the Indian Society of Remote Sensing*, 50(2), 299–312. <https://doi.org/10.1007/s12524-021-01448-w>
- Li, J., Lu, X., Cheng, K., Liu, W. 2020. Regression and Time Series Model Selection. *Regression and Time Series Model Selection, 1968*. <https://doi.org/10.1142/3573>
- dos Santos Luciano, A.C., Picoli, M.C.A., Duft, D.G., Rocha, J.V., Leal, M.R.L.V., le Maire, G. 2021. Empirical model for forecasting sugarcane yield on a local scale in Brazil using Landsat imagery and random forest algorithm. *Computers and Electronics in Agriculture*, 184, 106063. <https://doi.org/10.1016/j.compag.2021.106063>
- Mata, R., Rosales, A., Sandoval, Da., Vindas, E., Alemán, B. 2020. *Subórdenes de suelos de Costa Rica [mapa digital]. Escala 1:200000*. <http://www.cia.ucr.ac.cr/es/mapa-de-suelos-de-costa-rica>
- Max, A., Wing, J., Weston, S., Williams, A., Keifer, C., Engelhardt, A., Cooper, T., Mayer, Z., Ziem, A., Scrucca, L., Hunt, T., Kuhn, M.M. 2020. *Package 'caret'* R.
- Morel, J., Todoroff, P., Bégué, A., Bury, A., Martiné, J.F., Petit, M. 2014. Toward a satellite-based system of sugarcane yield estimation and forecasting in smallholder farming conditions: A case study on reunion island. *Remote Sensing*, 6(7), 6620–6635. <https://doi.org/10.3390/rs6076620>
- Narmilan, A., Gonzalez, F., Salgadoe, A.S.A., Kumarasiri, U.W.L.M., Weerasinghe, H.A.S., Kulasekara, B.R. 2022. Predicting Canopy Chlorophyll Content in Sugarcane Crops Using Machine Learning Algorithms and Spectral Vegetation Indices Derived from UAV Multispectral Imagery. *Remote Sensing*, 14(5), 1140. <https://doi.org/10.3390/rs14051140>
- Panigrahy, S., Sharma, S.A. 1997. Mapping of crop rotation using multitemporal Indian Remote Sensing Satellite digital data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 52(2), 85–91. [https://doi.org/10.1016/S0924-2716\(97\)83003-1](https://doi.org/10.1016/S0924-2716(97)83003-1)
- Pearson, R.L., Miller, L.D. 1972. Remote Mapping of Standing Crop Biomass for Estimation of the Productivity of Shortgrass Prairie, Pawnee National Grasslands, Colorado. *Proceedings of the 8th International Symposium on Remote Sensing of the Environment*.
- Piekutowska, M., Niedbala, G., Piskier, T., Lenartowicz, T., Pilarski, K., Wojciechowski, T., Pilarska, A.A., Czechowska-Kosacka, A. 2021. The application of multiple linear regression and artificial neural network models for yield prediction of very early potato cultivars before harvest. *Agronomy*, 11(5), 885. <https://doi.org/10.3390/agronomy11050885>
- Rahman, M.M., Robson, A. 2020. Integrating Landsat-8 and Sentinel-2 Time Series Data for Yield Prediction of Sugarcane Crops at the Block Level. *Remote Sensing*, 12(8), 1313. <https://doi.org/doi:10.3390/rs12081313>
- Rahman, M.M., Robson, A.J. 2016. A Novel Approach for Sugarcane Yield Prediction Using Landsat Time Series Imagery: A Case Study on Bundaberg Region. *Advances in Remote Sensing*, 5, 93–102. <https://doi.org/http://dx.doi.org/10.4236/ars.2016.52008>
- Rao, P.V.K., Rao, V.V., Venkataratnam, L. 2002. Remote sensing: A technology for assessment of sugarcane crop acreage and yield. *Sugar Tech*, 4(3-4), 97–101. <https://doi.org/10.1007/bf02942689>
- Richardson, A.J., Wiegand, C.L. 1977. Distinguishing vegetation from soil background information. *Photogrammetric Engineering and Remote Sensing*, 43(12), 1541–1552.
- Rouse, J.W., Hass, R.H., Schell, J.A., Deering, D.W. 1973. Monitoring vegetation systems in the great plains with ERTS. *Third Earth Resources Technology Satellite (ERTS) symposium*, 351, 309–317. <https://ntrs.nasa.gov/archive/nasa/casi.ntrs.nasa.gov/19740022614.pdf>
- Rudorff, B.F.T., Batista, G.T. 1990. Yield estimation of sugarcane based on agrometeorological-spectral models. *Remote Sensing of Environment*, 33(3), 183–192. [https://doi.org/10.1016/0034-4257\(90\)90029-L](https://doi.org/10.1016/0034-4257(90)90029-L)
- Saez, J.V. 2017. *Dinámica de acumulación de sacarosa en tallos de caña de azúcar (Saccharum spp.) modulada por cambios en la relación fuente-destino*. Universidad Nacional de Córdoba.

- Shendryk, Y., Davy, R., Thorburn, P. 2021. Integrating satellite imagery and environmental data to predict field-level cane and sugar yields in Australia using machine learning. *Field Crops Research*, 260(October 2020), 107984. <https://doi.org/10.1016/j.fcr.2020.107984>
- Simões, M. dos S., Rocha, J.V., Lamparelli, R.A.C. 2005. Variáveis espectrais e indicadores de desenvolvimento e produtividade da cana-de-açúcar. *Scientia Agricola*, 62(3), 199–207. <https://doi.org/10.1590/S0103-90162005000300001>
- Sishodia, R.P., Ray, R.L., Singh, S.K. 2020. Applications of remote sensing in precision agriculture: A review. *Remote Sensing*, 12(19), 1–31. <https://doi.org/10.3390/rs12193136>
- Som-Ard, J., Atzberger, C., Izquierdo-Verdiguier, E., Vuolo, F., Immitzer, M. 2021. Remote sensing applications in sugarcane cultivation: A review. *Remote Sensing*, 13(20), 1–46. <https://doi.org/10.3390/rs13204040>
- USGS, (United States Geological Survey). 2022. Landsat 8-9 Collection 2 (C2) Level 2 Science Product ( L2SP ) Guide. En *USGS* (Vol. 2, Número March).
- Zhao, Y., Justina, D. Della, Kazama, Y., Rocha, J.V., Graziano, P.S., Lamparelli, R.A.C. 2016. Dynamics modeling for sugar cane sucrose estimation using time series satellite imagery. En C.M.U. Neale y A. Maltese (Eds.), *Remote Sensing for Agriculture, Ecosystems, and Hydrology XVIII* (Vol. 9998, p. 99980J). <https://doi.org/10.1117/12.2242490>
- Zumo, I.M., Hashim, M. 2020. Mapping Seasonal Variations of Grazing Land Above-ground Biomass with Sentinel 2A Satellite Data. *IOP Conference Series: Earth and Environmental Science*, 540(1). <https://doi.org/10.1088/1755-1315/540/1/012061>