

Estimación de la edad del cultivo de palma de aceite (*elaeis guineensis*) en función de índices de vegetación y humedad mediante imágenes satelitales y aprendizaje automático

Oil palm age estimation based on vegetation and moisture indices using satellite imagery and machine learning

Natalia Gómez-Calderón¹, Fernando Watson-Hernández²,
Roger Rojas-Vásquez³, Yerlin Quesada-Mora⁴

Gómez-Calderón, N; Watson-Hernández, F; Rojas-Vásquez, R; Quesada-Mora, Y. Estimación de la edad del cultivo de palma de aceite (*elaeis guineensis*) en función de índices de vegetación y humedad mediante imágenes satelitales y aprendizaje automático. *Tecnología en Marcha*. Vol. 39 N° especial sobre Inteligencia Artificial. Febrero, 2026. Pág. 264-275.

 <https://doi.org/10.18845/tm.v39i5.8514>

1 Instituto Tecnológico de Costa Rica, Escuela de Ingeniería Agrícola. Cartago, Costa Rica.

 ngomez@itcr.ac.cr

 <https://orcid.org/0000-0001-7961-7529>

2 Instituto Tecnológico de Costa Rica, Escuela de Ingeniería Agrícola. Cartago, Costa Rica.

 fwatson@itcr.ac.cr

 <https://orcid.org/0000-0001-8258-4668>

3 Instituto Tecnológico de Costa Rica, Escuela de Ingeniería Agrícola. Cartago, Costa Rica.

 rogerrojas@estudiantec.cr

 <https://orcid.org/0000-0002-1607-3680>

4 Instituto Tecnológico de Costa Rica, Escuela de Ingeniería Agrícola. Cartago, Costa Rica.

 quesadayer@estudiantec.cr

 <https://orcid.org/0000-0001-6658-2494>



Palabras clave

Random Forest; XGBoost; Landsat; Google Earth Engine; agricultura digital.

Resumen

El aceite de palma (*Elaeis guineensis*) es uno de los aceites vegetales más consumidos en el mundo y es un ingrediente clave en cadenas de valor globales rentables. En Costa Rica, es uno de los tres cultivos con mayor área agrícola ocupada. Este estudio tiene como objetivo estimar la edad del cultivo de palma aceitera en función de índices de vegetación y humedad generados con imágenes satelitales mediante técnicas de aprendizaje automático, para esto se consideró información de 20 años de un cultivo de palma aceitera ubicado en el Pacífico Central de Costa Rica y sus imágenes satelitales LANDSAT. Se generaron dos modelos, el modelo *Random Forest* (RF) presentó mejores resultados al usar un *ntree* de 10000 en el entrenamiento, obteniéndose los siguiente coeficientes: NSE=0,9161, RMSE=1,6485 años, MAE=1,0178 años y $r^2=0,9476$; y el modelo *XGBoost* utilizando un *max.depth* de 4, *nrounds* de 50 y *nthread* de 10 en el entrenamiento para el que se obtuvo; NSE=0,9530, RMSE=1,23 años, MAE=0,89 años y $r^2=0,9577$. Para los datos obtenidos en la validación, con RF resultaron los coeficientes de: NSE=0,5395, RMSE=3,76 años, MAE= 2,46 años y $r^2=0,5533$; para el modelo *XGBoost* se obtuvo NSE=0,6204, RMSE=3,41 años, MAE= 2,24 años y $r^2=0,6210$. La variable más importante en ambos modelos fue el percentil 75 del NDMI. El modelo más adecuado y con mejor rendimiento es *XGBoost*, sin embargo, no se recomienda cuando las edades del cultivo sobrepasen los 25 años.

Keywords

Random Forest; XGBoost; Landsat; Google Earth Engine; digital agriculture.

Abstract

Palm oil (*Elaeis guineensis*) is one of the most widely consumed vegetable oils in the world and is a key ingredient in profitable global value chains. In Costa Rica, it is one of the three crops with the largest occupied agricultural area. The objective of this study is to estimate the age of the palm oil crop based on vegetation and humidity indices generated with satellite images using machine learning techniques, for this information will be taken from 20 years of a palm oil crop located in the Central Pacific of Costa Rica and its LANDSAT satellite images. Two models were generated, the Random Forest (RF) model presented better results when using a *ntree* of 10000 in training, obtaining the following coefficients; NSE=0,9161, RMSE=1,6485 years, MAE=1,0178 years and $r^2=0,9476$; and the XGBoost model using a *max.depth* of 4, *nrounds* of 50 and *nthread* of 10 in the training for which it was obtained: NSE=0,9530, RMSE=1,23 years, MAE=0,89 years and $r^2=0,9577$. For the data obtained in the validation, the RF coefficients were: NSE=0,5395, RMSE=3,76 years, MAE= 2,46 years and $r^2=0,5533$; for the XGBoost model NSE=0,6204, RMSE=3,4114 years, MAE= 2,23 years and $r^2=0,6210$. The most important variable in both models was the NDMI 75th percentile. The most suitable model with the best performance is XGBoost, however it is not recommended when the age of the crop exceeds 25 years.

Introducción

Los cultivos oleaginosos son un porcentaje importante de uso de la tierra agrícola en el mundo. Específicamente el cultivo de palma aceitera representa aproximadamente el 37% de la superficie total de tierra dedicada a la producción de cultivos del mundo [1] y en Costa Rica

es uno de los principales cultivos agrícolas. Según [2] y [3], esta es una actividad rentable que mejora la economía de las zonas en las que se produce. Debido a su alto rendimiento en cuanto a extracción de aceite, la palma se ha convertido en uno de los aceites vegetales más consumidos a nivel global [4], cuya plantación juega un papel vital en el mercado mundial de aceites comestibles [3]. Por lo anterior, es necesario encontrar una forma automática de predecir diversas variables de manejo del cultivo como una herramienta de apoyo para la toma de decisiones [3], [5].

Una vez que las plantas de palma aceitera superan los 25 años de edad, su potencial de producción generalmente disminuye, dejan de ser comercialmente productivas y toman decisiones de manejo agronómico específico o bien se reemplazan las plantas viejas con plantas nuevas, por lo que identificar dentro de grandes extensiones la edad del cultivo o de las plantas constituye una información útil en el manejo de los recursos para la producción [6]. Por otra parte, según [7] y [8], la palma de aceite es un árbol perenne, por lo que el cultivo tiene una estructura de dosel que permite aplicar teledetección mediante imágenes aéreas o satelitales que muestren tomas superiores de las áreas sembradas, lo que facilita la clasificación del cultivo utilizando índices de vegetación obtenidos de imágenes multiespectrales cuyos datos de cada píxel y del cultivo, permiten determinar correlaciones con el uso de algoritmos para el análisis de datos, por lo que es recomendado evaluar más de un algoritmo de aprendizaje automático (*machine learning*) mejorando así la precisión de las estimaciones [9], [10] y [11].

El manejo de datos mediante técnicas de aprendizaje automático ha demostrado buenos resultados y resulta muy prometedor para la evaluación del estado del cultivo de palma de aceite [10], [6] y [5], pues a partir de los resultados se puede conocer que características son sensibles a las distorsiones introducidas por las imágenes [3]. Además, los datos basados en reflectancia espectral se han utilizado ampliamente en el monitoreo de condiciones de los cultivos y estimación de su rendimiento [12].

Las imágenes LANDSAT 5 Thematic Mapper han sido utilizadas para obtener datos de radiancia, modelo de predicción de la edad, estimaciones de rendimiento y monitoreo de enfermedades [5], [13] y [14] son de acceso libre, suministran información de hasta 11 longitudes de onda (bandas), con resoluciones de entre 15 m y 100 m, debido a la variación en los distintos sensores de Landsat. Estos rangos son aceptables debido a que las zonas de manejo del cultivo de palma aceitera en Costa Rica superan las cuatro hectáreas según datos del INEC [15].

Es importante encontrar las relaciones entre los índices de vegetación obtenidos a partir de las imágenes, el rendimiento, las condiciones climáticas y edáficas y la edad del cultivo para la gestión de la producción de palma de aceite en función de los índices de vegetación y humedad generados a partir imágenes LANDSAT 5, 7 y 8 en el Pacífico Central de Costa Rica, debido a la variabilidad climática de la región, con el fin de generar una herramienta que facilite la proyección del comportamiento del cultivo. El objetivo de este proyecto fue estimar de la edad del cultivo de palma de aceite en función de los índices de vegetación y humedad generados a partir imágenes satelitales mediante técnicas de aprendizaje automático.

Metodología

En el estudio se consideraron 103 unidades productivas (UP) de una agroindustria de palma aceitera, ubicada en el Pacífico Central de Costa Rica. Se utilizó información histórica de 16-20 años del cultivo sobre variedad genética, rendimiento (t/ha) y año de siembra.

Para las unidades productivas consideradas, se obtuvieron las imágenes LANDSAT 5, 7 y 8 Collection 1 Tier 1 *calibrated top-of-atmosphere (TOA) reflectance* [16], desde enero de 1996 hasta diciembre del 2016, correspondientes a 712 imágenes utilizadas en este estudio. En la plataforma *Google Earth Engine* (GEE), fue creado un código de programación en lenguaje *Java Script*, para generar de forma cíclica (para cada imagen obtenida), 12 índices tanto de vegetación como de humedad, lo que generó una nueva colección de 20 años de historial con una resolución interanual para cada uno de los índices utilizados. La herramienta requirió como entrada la información de la geometría del área de cada una de las 103 UP, las cuales constituyen la unidad mínima de área de información de producción *-feature collection-*, para obtener una descripción estadística del comportamiento de los índices en cada UP para cada fecha de captura de la imagen, determinando valores mínimos, máximos, cuartiles 25 y 75, medias, medianas y desviaciones estándar. Los valores estadísticos se ordenaron de forma cronológica y creando un archivo de forma automática para cada una de las UP. Cada UP contiene en total 84 variables.

Se obtuvieron nueve índices de vegetación (ARVI, AVI, EVI, GCI, GNDVI, NDVI, NPCRI, SAVI, SIPI) y tres índices de humedad (MSI, NDMI, NDWI). El paso de cada banda por estos canales dota de diferentes tonalidades los elementos dependiendo de la respuesta de estos frente a las longitudes de onda [17]. Los satélites LANDSAT 5, 7 y 8 distribuyen las señales recibidas en distintas bandas, su distribución denotada según sus siglas o nombre en inglés se muestra en los cuadros 1 y 2.

Cuadro 1. Señales que reciben las distintas bandas para satélites LANDSAT 5, 7 y 8.

Landsat 5 y 7		Landsat 8	
Banda	Señal	Banda	Señal
1	BLUE	2	BLUE
2	GREEN	3	GREEN
3	RED	4	RED
4	NIR	5	NIR
5	SWIR 1	6	SWIR 1
7	SWIR 2	7	SWIR 2

Fuente: [18], [19] y [20].

Cuadro 2. Índices de vegetación obtenidos a partir de datos multiespectrales de las imágenes.

Variable	Índice	Ecuación*	Fuente
Vegetación	ARVI	$(NIR - (2 \cdot RED) + BLUE) / (NIR + (2 \cdot RED) + BLUE)$	[21]
Vegetación	AVI	$[NIR \cdot (1 - RED) \cdot (NIR - RED)]^{1/3}$	[22]
Vegetación	EVI	$2,5 \cdot (NIR - RED) / (NIR + 6 \cdot RED - 7,5 \cdot BLUE + 1)$	[23]
Vegetación	GCI	$(NIR / GREEN) - 1$	[21]
Vegetación	GNDVI	$(NIR - GREEN) / (NIR + GREEN)$	[23]
Vegetación	NDVI	$(NIR - RED) / (NIR + RED)$	[23]
Vegetación	NPCRI	$(RED - BLUE) / (RED + BLUE)$	[22]
Vegetación	SAVI	$1,5 \cdot (NIR - RED) / (NIR + RED + 0,5)$	[23]
Vegetación	SIPI	$(NIR - BLUE) / (NIR + BLUE)$	[23]
Agua	MSI	$(SWIR / NIR)$	[24]
Agua	NDMI	$(NIR - SWIR) / (NIR + SWIR)$	[24]
Agua	NDWI	$(GREEN - NIR) / (GREEN + NIR)$	[24]

En el software RStudio [25], [22] se reordenó la base de datos de edad del cultivo, material genético, lote, rendimiento e índices, eliminando los datos faltantes y generando una nueva base de datos a partir de esta. La cual contiene solo los índices y edad como la variable dependiente. Se filtraron los datos, eliminando los valores de ndmi_mean < 0.2 debido a que se estimaron como valores afectados por nubosidad que disminuyen el valor real del lote. En la Figura 1 se muestra un diagrama de la metodología utilizada.




Figura 1. Diagrama metodológico del análisis de la información y sensibilidad de los modelos generados.

La base de datos luego fue dividida en etapa de entrenamiento (*Training Data*) y validación (*Test Data*) de manera aleatoria, con 70 y 30% de los datos respectivamente. Se aplicaron los modelos de *Random Forest (RF)* y *XGBoost*, cuyos resultados fueron evaluados aplicando cuatro coeficientes para obtener la mejor calibración de los modelos (Cuadro 3); Coeficiente de eficiencia de Nash-Sutcliffe (NSE), la raíz del error cuadrático medio (RMSE), el coeficiente medio de error absoluto (MAE) y el coeficiente de determinación (r^2).

Cuadro 3. Coeficientes para determinación de la eficiencia de los modelos resultantes. Parrita, Costa Rica. 2021.

Coeficiente	Ecuación*
NSE	$1 - \frac{\sum_{i=1}^n (y_i^{obs} - y_i^{sim})^2}{\sum_{i=1}^n (y_i^{obs} - \bar{y}^{obs})^2}$
RMSE	$\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i^{obs} - y_i^{sim})^2}$
MAE	$\frac{1}{n} \sum_{i=1}^n y_i^{obs} - y_i^{sim} $
r^2	$\left(\frac{\sum [(y_i^{obs} - \bar{y}^{obs})(y_i^{sim} - \bar{y}^{sim})]}{\sqrt{\sum (y_i^{obs} - \bar{y}^{obs})^2 * \sum (y_i^{sim} - \bar{y}^{sim})^2}} \right)^2$

*Donde n es la cantidad de datos disponibles para el estudio, y_i^{obs} corresponde a la información de la edad del cultivo obtenido para el intervalo en estudio, $\bar{y}^{obs}$ es el promedio de la edad del cultivo obtenido para el intervalo en estudio, y_i^{sim} es la edad del cultivo simulada y $\bar{y}^{sim}$ es el promedio de la edad del cultivo simulada.

Se construyeron modelos de aprendizaje automático (*Machine Learning*) según las estructuras de *RF* y *XGBoost*, para calibrar los modelos. Los valores de NSE y r^2 se clasificaron según los rangos de aceptabilidad expuestos por Moriasi *et al.* [26]. Para RMSE y MAE se consideró que errores menores al 25% de la edad media son aceptables, entre 25% y 40% son regulares y más de un 40% son insatisfactorios.

Para el modelo RF, se probaron tres diferentes valores de número de árboles (*ntree*): 500, 5000 y 10000. El mejor desempeño según los coeficientes de evaluación estadística utilizados se obtuvo para *ntree* = 10000. En el modelo *XGBoost*, se utilizó un *max.depth* de 4, *nrounds* de 50 y *nthread* de 10. Se filtraron los datos por correlación entre índices y edad del cultivo. En ambos modelos se utilizó además de los VIs, una clasificación numérica del material genético.

Resultados

La plantación de palma utilizada se caracterizó por tener una edad media de 10 años, 4 meses y 6 días con un rango máximo de edad entre 0 y los 32 años, pero en donde, la gran mayoría de los datos se concentraron entre los 3 y 19 años. La información de la edad de la planta de palma aceitera utilizada tiene un comportamiento normal (Figura 2).




Figura 2. Caracterización grafica del comportamiento de la edad de la palma de aceite. Parrita, Costa Rica. 1996-2016.

Coefficientes de los modelos de predicción de la edad del cultivo

En la etapa de entrenamiento ambos modelos (*RF*, *XGBoost*) mostraron valores de los coeficientes NSE y r^2 superiores a 0,91, con MAE promediado de 11 meses y 19 días y RMSE promedio de 1,44 años. Estos rendimientos disminuyeron en la validación, en donde el modelo *XGBoost* tuvo mejores valores en los índices de eficiencia y error que el modelo *RF* (Cuadro 4).

Cuadro 4. Coeficientes de evaluación de calibración de los modelos utilizados. Parrita, Costa Rica. 1996-2016.

Modelo	Fase	NSE	MAE	RMSE	r^2
RF	Train	0,9161	1,0178	1,6485	0,9476
	Test	0,5395	2,4589	3,7571	0,5533
XGBoost	Train	0,9530	0,8859	1,2333	0,9577
	Test	0,6204	2,2250	3,4114	0,6210

En la fase de entrenamiento, *XGBoost* mostró el mejor ajuste global, alcanzando valores superiores de NSE (0,9530) y r^2 (0,9577), junto con menores errores MAE (0,8859) y RMSE (1,2333), en comparación con *RF* (NSE = 0,9161; r^2 = 0,9476; MAE = 1,0178; RMSE = 1,6485). Estos resultados indican una mayor capacidad de *XGBoost* para capturar la variabilidad de los datos durante el aprendizaje (Figura 3).

En la fase de prueba, ambos modelos evidenciaron una reducción del desempeño, siendo *XGBoost* el que mantuvo mejores métricas predictivas (NSE = 0,6204; r^2 = 0,6210) frente a *RF* (NSE = 0,5395; r^2 = 0,5533), además de registrar menores valores de MAE (2,2250 vs. 2,4589) y RMSE (3,4114 vs. 3,7571). Estos resultados reflejan una mayor capacidad de generalización del modelo *XGBoost* sobre datos no vistos, destacando su potencial para aplicaciones de agricultura de precisión, con valores que según Moriasi *et al.* [26] son aceptables. El coeficiente de error MAE=2,22 años es aceptable mientras que el RMSE=3,4 años es regular según lo establecido en la metodología (2,6 años).




Figura 3. Comparación de la edad observada con la edad simulada, en los procesos de calibración y validación. Parrita, Costa Rica. 1996-2016.

En la fase de validación, la dispersión aumentó notablemente, reflejando la variabilidad residual del sistema y la complejidad espacial del proceso de estimación (Figura 3). No obstante, XGBoost presentó una nube de puntos más concentrada alrededor de la línea 1:1, particularmente en el rango intermedio de edades, lo que indica una mayor estabilidad predictiva frente a RF. En ambos modelos se aprecia una tendencia a subestimar edades altas y a sobreestimar edades bajas, sugiriendo un efecto de regresión hacia la media, típico en enfoques de aprendizaje supervisado aplicados a datos heterogéneos.

Adicionalmente, se identifican valores atípicos principalmente en la fase de prueba, asociados a predicciones extremas, lo cual pone de manifiesto la influencia de condiciones locales no completamente capturadas por las variables explicativas, lo que se evidenció en un lote con edad superior a los 28 años según la información del cultivo (Figura 4), mientras que los modelos les asignaron una edad inferior a los cuatro años, por lo que los modelos subestimaron la edad cuando el cultivo superó los 20 años.




Figura 4. Visualización de resultados para el año 2016. Parrita, Costa Rica. 2021.

Importancia de los índices de vegetación y humedad para la predicción de la edad del cultivo

El índice más significativo para ambos modelos (RF y XGBoost) fue el *ndmi_p75* (Figura 5). Para el modelo RF la variable *msi_p25* es la segunda en importancia y la variación espacial de estos dos VIs también es utilizada [29], ya que variables de los valores estadísticos en los percentiles 25 y 75, máximos y mínimos, aparecen ente los 10 mejor calificados. Para el modelo *XGBoost*, la segunda variable en relevancia es el *npcr_min*, cuya importancia relativa es del 25%. Para ambos modelos, el principal peso estadístico recae en la variabilidad del percentil 75 del índice de vegetación *ndmi* (Figura 5).




Figura 5. Importancia relativa de los índices en cada uno de los modelos. Parrita, Costa Rica. 1996-2016.

Discusión

Los modelos mostraron un mejor desempeño en el rango de edades en donde más información existe, debido a que cuentan con un número mayor de datos para su entrenamiento. Los principales problemas de modelos se observan al identificar edades que superan los 20 años [27] tendiendo a subestimar la edad. En tanto, para edades entre los 8 y 18 años los modelos muestran un buen desempeño comparado con otros trabajos [28]. Al acortar el rango de edades entre 0 – 20 años ambos modelos obtienen en promedio $NSE=0,81$, $RMSE=2,14$ años, $MAE=1,6$ años y $r^2=0,80$. En este contexto, se propone la integración de variables edáficas y climáticas, junto con información multitemporal, como una estrategia para fortalecer la representación de la dinámica del cultivo y disminuir la incertidumbre asociada a procesos de extrapolación espacial y temporal.

Los resultados obtenidos concuerdan con diversos autores, demostrando que el NDVI, SAVI y otros índices de vegetación tienen poca o nula correlación con la edad de la palma [28]. Además, se demuestra que para las condiciones de nubosidad del Pacífico de Centroamérica es posible determinar la edad de unidades productivas de palma de aceite por medio de la utilización de imágenes satelitales Landsat. Sin embargo, el estudio presenta limitaciones, ya que, tiene problemas para la identificación de áreas de cultivo con edades superiores a los 20 años, lo que probablemente se debe a poca información o que después de esa edad, la variación de las copas de la palma es poca y no permite realizar estimaciones por este método [27].

La utilización de modelos de elevación que incorporen como variable la altura del cultivo, podría mejorar este tipo de modelos de predicción, entendiendo que otros estudios han generado mejores resultados a escalas menores de área y utilizando información LiDAR dentro de sus variables [30].

Conclusiones

Se concluye que, el modelo más adecuado y con mejor rendimiento es *XGBoost* cuando se hace la evaluación y predicción de edad para la planta de palma de aceite con cualquier material genético. Lo anterior, a partir de variables de índices de vegetación y humedad obtenidos como producto del análisis de imágenes satelitales Landsat 6, 7 y 8 desde 1996 hasta 2016. Los índices de vegetación y humedad NDVI y MSI, tienen mayor representación en sus percentiles 25 y 75 en los modelos de mejor rendimiento (RF y *XGBoost*), por lo que, para la predicción y evaluación de la edad de las plantas de palma de aceite en la zona del Pacífico Central de Costa Rica, se debe considerar la distribución estadística de los datos dentro de las unidades productivas para optimizar el desempeño de los modelos de predicción.

Agradecimientos

A los productores de palma aceitera del Pacífico Central de Costa Rica por facilitar los registros históricos de rendimientos de la producción y a la Vicerrectoría de Investigación y Extensión del Instituto Tecnológico de Costa Rica (ITCR), por brindar las facilidades para desarrollar el estudio “Modelación del rendimiento de cultivo de palma de aceite a partir de imágenes satelitales multiespectrales, en el Pacífico Central de Costa Rica”, proyecto inscrito en el año 2020.

Referencias

- [1] A. Descals, D. L. A. Gaveau, S. Wich, Z. Szantoi, y E. Meijaard, "Global mapping of oil palm planting year from 1990 to 2021", *Earth Syst Sci Data*, vol. 16, núm. 11, pp. 5111–5129, nov. 2024, doi: 10.5194/essd-16-5111-2024.
- [2] P. Clare, "El cultivo de la palma aceitera en Costa Rica en el contexto del TLC con los Estados Unidos de Norteamérica", *Revista Espiga*, vol. 5, núm. 9, pp. 95–124, 2004, doi: 10.22458/re.v5i9.1108.
- [3] P. N. Chowdhury, P. Shivakumara, L. Nandanwar, F. Samiron, U. Pal, y T. Lu, "Oil palm tree counting in drone images", *Pattern Recognit Lett*, vol. 153, pp. 1–9, 2022, doi: 10.1016/j.patrec.2021.11.016.
- [4] K. L. Chong, K. D. Kanniah, C. Pohl, y K. P. Tan, "A review of remote sensing applications for oil palm studies", *Geo-Spatial Information Science*, vol. 20, núm. 2, pp. 184–200, 2017, doi: 10.1080/10095020.2017.1337317.
- [5] C. Li *et al.*, "Integrating Multi-Temporal Landsat and Sentinel Data for Enhanced Oil Palm Plantation Mapping and Age Estimation in Malaysia", *Remote Sens (Basel)*, vol. 17, núm. 16, p. 2908, ago. 2025, doi: 10.3390/rs17162908.
- [6] C. CHARLOQ, A. S. THOHA, A. YAZID, A. M. SIDIQ, y O. A. LUBIS, "Estimating oil palm (*Elaeis guineensis*) production potential using Unmanned Aerial Vehicle", *Biodiversitas*, vol. 25, núm. 9, sep. 2024, doi: 10.13057/biodiv/d250919.
- [7] A. C. Morel, J. B. Fisher, y Y. Malhi, "Evaluating the potential to monitor aboveground biomass in forest and oil palm in Sabah, Malaysia, for 2000–2008 with Landsat ETM+ and ALOS-PALSAR", *Int J Remote Sens*, vol. 33, núm. 11, pp. 3614–3639, 2012, doi: 10.1080/01431161.2011.631949.
- [8] A. Rodríguez *et al.*, "Implications of crop model ensemble size and composition for estimates of adaptation effects and agreement of recommendations", *Agric For Meteorol*, vol. 264, pp. 351–362, 2019, doi: 10.1016/j.agrformet.2018.09.018.
- [9] S. Khanal, J. Fulton, A. Klopfenstein, N. Douridas, y S. Shearer, "Integration of high resolution remotely sensed data and machine learning techniques for spatial prediction of soil properties and corn yield", *Comput Electron Agric*, vol. 153, pp. 213–225, 2018, doi: 10.1016/j.compag.2018.07.016.
- [10] A. D. Amiruddin, F. M. Muharam, M. H. Ismail, N. P. Tan, y M. F. Ismail, "Hyperspectral spectroscopy and imbalance data approaches for classification of oil palm's macronutrients observed from frond 9 and 17", *Comput Electron Agric*, vol. 178, p. 105768, 2020, doi: 10.1016/j.compag.2020.105768.
- [11] J. Zheng *et al.*, "Growing status observation for oil palm trees using Unmanned Aerial Vehicle (UAV) images", *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 173, pp. 95–121, 2021, doi: 10.1016/j.isprsjprs.2021.01.008.
- [12] J.-H. RYU, D. OH, y J. CHO, "Simple method for extracting the seasonal signals of photochemical reflectance index and normalized difference vegetation index measured using a spectral reflectance sensor", *J Integr Agric*, vol. 20, núm. 7, pp. 1969–1986, 2021, doi: 10.1016/S2095-3119(20)63410-4.
- [13] Q. Zhao, L. Yu, Z. Du, y K. Kanniah, "Towards an Annually Updated Oil Palm Age Database (OPAD) with Multimodal Remote Sensing Features: Design and Preliminary Result", *Journal of Advanced Geospatial Science & Technology*, vol. 4, núm. 1, pp. 16–42, mar. 2024, doi: 10.11113/jagst.v4n1.85.
- [14] F. Watson-Hernández, N. Gómez-Calderón, y R. P. da Silva, "Oil Palm Yield Estimation Based on Vegetation and Humidity Indices Generated from Satellite Images and Machine Learning Techniques", *AgriEngineering*, vol. 4, núm. 1, pp. 279–291, mar. 2022, doi: 10.3390/agriengineering4010019.
- [15] INEC, *VI Censo Nacional Agropecuario: Características de las Fincas y de las Personas Productoras*. San José, Costa Rica, 2015.
- [16] G. Chander, B. L. Markham, y D. L. Helder, "Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors", *Remote Sens Environ*, vol. 113, núm. 5, pp. 893–903, 2009, doi: 10.1016/j.rse.2009.01.007.
- [17] D. Ramos, "Combinación de bandas en imágenes de satélite Landsat y Sentinel", 2021. Consultado: el 16 de diciembre de 2021. [En línea]. Disponible en: <https://mappinggis.com/2019/05/combinaciones-de-bandas-en-imagenes-de-satelite-landsat-y-sentinel>
- [18] EOS (Earth Observing System), "LANDSAT 7", 1999. Consultado: el 14 de diciembre de 2021. [En línea]. Disponible en: <https://eos.com/find-satellite/landsat-7>
- [19] EOS (Earth Observing System), "LANDSAT 8", 2013. Consultado: el 14 de diciembre de 2021. [En línea]. Disponible en: <https://eos.com/find-satellite/landsat-8>
- [20] EOS (Earth Observing System), "LANDSAT 5 (TM)", 2012. Consultado: el 14 de diciembre de 2021. [En línea]. Disponible en: <https://eos.com/find-satellite/landsat-5-tm>

- [21] T. Dube, S. Pandit, C. Shoko, A. Ramoelo, D. Mazvimavi, y T. Dalu, "Numerical assessments of leaf area index in tropical savanna rangelands, South Africa using Landsat 8 OLI derived metrics and in-situ measurements", *Remote Sens (Basel)*, vol. 11, núm. 7, 2019, doi: 10.3390/rs11070829.
- [22] D. Sykas, "Remote Sensing Satellite Data and Spectral Indices. Spectral Indices with multispectral satellite data", 2020. Consultado: el 16 de diciembre de 2021. [En línea]. Disponible en: <https://www.geo.university/pages/blog?p=spectral-indices-with-multispectral-satellite-data#:~:text=Bare>
- [23] C. Tan *et al.*, "Predicting grain protein content of field-grown winter wheat with satellite images and partial least square algorithm", *PLoS One*, vol. 15, núm. 3, pp. 1–15, 2020, doi: 10.1371/journal.pone.0228500.
- [24] M. Zakir, "GIS and RS Based Spatio-Temporal Analysis of Soil Moisture/Water Content Variation in Southern Irrigated Part of Sindh, Pakistan", *Journal of Remote Sensing & GIS*, vol. 07, núm. 04, 2018, doi: 10.4172/2469-4134.1000250.
- [25] R Studio, "R Studio", 2021. Consultado: el 9 de diciembre de 2021. [En línea]. Disponible en: <https://www.rstudio.com>
- [26] D. Moriasi, J. Arnold, M. Van-Liew, R. Bingner, R. Harmel, y T. Veith, "Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations", *Trans ASABE*, vol. 50, núm. 3, pp. 885–900, 2007, doi: 10.13031/2013.23153.
- [27] A. Chemura, I. van Duren, y L. M. van Leeuwen, "Determination of the age of oil palm from crown projection area detected from WorldView-2 multispectral remote sensing data: The case of Ejisu-Juaben district, Ghana", *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 100, pp. 118–127, 2015, doi: 10.1016/j.isprsjprs.2014.07.013.
- [28] K. P. Tan, K. D. Kanniah, y A. P. Cracknell, "Use of UK-DMC 2 and ALOS PALSAR for studying the age of oil palm trees in southern peninsular Malaysia", *Int J Remote Sens*, vol. 34, núm. 20, pp. 7424–7446, 2013, doi: 10.1080/01431161.2013.822601.
- [29] J. McMorow, "Linear regression modelling for the estimation of oil palm age from Landsat TM", *Int J Remote Sens*, vol. 22, núm. 12, pp. 2243–2264, 2001, doi: 10.1080/01431160117188.
- [30] H. M. Rizzei, H. Z. M. Shafri, M. A. Mohamoud, B. Pradhan, y B. Kalantar, "Oil Palm Counting and Age Estimation from WorldView-3 Imagery and LiDAR Data Using an Integrated OBIA Height Model and Regression Analysis", *J Sens*, pp. 1–13, 2018, doi: 10.1155/2018/2536327.

Declaración sobre uso de Inteligencia Artificial (IA)

Los autores aquí firmantes declaramos que no se utilizó ninguna herramienta de IA para la conceptualización, traducción o redacción de este artículo.