

## CLASIFICACIÓN DE IMÁGENES DE TELEDETECCIÓN MEDIANTE APRENDIZAJE PROFUNDO PARA ESTUDIOS DE POBLACIÓN DE CAÑA DE AZÚCAR

Classification of remote sensing images using deep learning for sugar cane population studies.

Eduardo Garea Llano (1)

Silvio Vioel Rodríguez Hernández (2)

1 Unidad Científico Técnica GEOCUBA de Investigación y Consultoría. egarea@gmail.com

2 Unidad Científico Técnica GEOCUBA de Investigación y Consultoría. silvio@uct.geocuba.cu

### RESUMEN:

La plataforma satelital Sentinel-2, lanzada por la Agencia Espacial Europea, ha tenido una amplia aplicación en la agricultura de precisión. Su ventaja, además de todas las posibilidades tecnológicas, en el caso de Cuba, es su acceso libre, que abarata de forma sustancial los costos de soluciones tecnológicas desarrolladas sobre esta base. Por otro lado, en las actuales circunstancias, se hace necesario mejorar la exactitud en los métodos de estimación automatizada de la población del cultivo de la caña de azúcar, como elemento esencial para la apreciación de las producciones a obtener. Tomando en cuenta las condiciones de este cultivo en Cuba y a su vez la necesidad de una herramienta para la ayuda a la toma de decisiones en las empresas del grupo AZCUBA, proponemos el mejoramiento de la metodología computacional para la estimación de población del cultivo. Se presenta un modelo basado en aprendizaje profundo sobre la base de los conceptos de génesis semántica para la clasificación de imágenes Sentinel-2. El modelo propuesto toma como característica para la clasificación al índice de vegetación de diferencia normalizada (NVDI). Se mejora la metodología previa existente. Dicho modelo, integrado a la metodología fue aplicado en áreas cañeras del país. Los resultados fueron comparados, con los obtenidos por especialistas del cultivo y con los obtenidos por la metodología sin el modelo propuesto, demostrando una exactitud superior y la factibilidad de su aplicación.

**Palabras Clave:** Teledetección, Clasificación de imágenes, NVDI, Aprendizaje profundo, Génesis semántica, Caña de azúcar.

**ABSTRACT:** The Sentinel-2 satellite platform launched by the European Space Agency has seen wide application in precision agriculture. Its advantage, in addition to all the technological possibilities, in the case of Cuba, is its free access, which substantially lowers the costs of technological solutions developed on this basis. On the other hand, in the current circumstances, it is necessary to improve the accuracy in the methods of automated estimation of the population of

the sugarcane crop, as an essential element for the appreciation of the productions to be obtained. Taking into account the conditions of this crop in Cuba and, in turn, the need for a tool to help decision-making in the companies of the AZCUBA group, we propose the improvement of the computational methodology for estimating the population of the crop. A deep learningbased model based on semantic genesis concepts for Sentinel-2 image classification is presented. The proposed model takes as a characteristic for the classification the normalized difference vegetation index (NVDI). The previous existing methodology is improved. This model, integrated into the methodology, was applied in sugarcane areas of the country. The results were compared with those obtained by crop specialists and with those obtained by the methodology without the proposed model, demonstrating superior accuracy and the feasibility of its application.

**Key Words:** Remote Sensing, Image classification, NVDI, Deep Learning, Semantic Genesis, Sugar cane.

Recibido :19/03/2023

Aprobado: 15/05/2023

## 1. INTRODUCCIÓN

La teledetección proporciona cobertura de grandes áreas con alta precisión y puede ser una herramienta muy eficiente para una mejor gestión en todas las escalas. En este sentido, la teledetección usando imágenes multiespectrales es una puerta abierta para extensas operaciones de monitoreo de cultivos (Adams y Gillespie, 2006) y proporciona ahorros potenciales en tiempo y recursos. La agricultura de precisión ha crecido y se ha establecido como una herramienta fundamental para la gestión agrícola para pronosticar el rendimiento, monitorear el estrés de las plantas y optimizar las actividades de fertilización, riego y labranza del suelo para una gestión más sostenible de las prácticas agrícolas y mejoras en el rendimiento para los agricultores.

El lanzamiento de las plataformas gemelas Sentinel-2 A + B por parte de la Agencia Espacial Europea (ESA) ha dado como resultado una mejora de las posibilidades de la agricultura de precisión. La ESA proporciona a través de Sentinel-2 un número mejorado de bandas multiespectrales, un tiempo de visita corto y una alta resolución espacial que son de gran utilidad para la comunidad agrícola y para los investigadores agrícolas en todo el mundo.

En lo que respecta a la agricultura, en situaciones en las que los cultivos interactúan con cualquier aspecto de su entorno (variaciones climáticas estacionales, fenómenos meteorológicos extremos, plagas, propiedades del suelo, etc.) o cuando los cultivos crecen y pasan por diferentes etapas fenológicas, las interacciones entre las plantas y la reflectancia de la luz se traduce en cambios en los patrones de las señales de las plantas que pueden interpretarse utilizando datos de satélite.

En este sentido, la sensibilidad de los datos de teledetección hacia las propiedades biofísicas específicas de las plantas de interés se puede estimar utilizando índices de vegetación (Segarra et al, 2020) que suelen ser combinaciones de mediciones de longitudes de onda espectrales bastante simples.

La caña de azúcar (*Saccharum officinarum*) es un cultivo semi-perenne, que se puede cosechar anualmente hasta cinco años sin replantar. En Cuba las plantaciones tempranas se realizan entre los meses de febrero y marzo, y las plantas tardías entre julio y septiembre. Durante la temporada de crecimiento, el cultivo de caña de azúcar pasa por tres etapas de crecimiento distintas que consisten en emergencia (establecimiento del cultivo) en los primeros 3 meses, adaptación (crecimiento

vegetativo) en los siguientes 6 meses y maduración en los últimos 3 meses antes de la replantación (INICA).

El monitoreo del grado de población de los campos y el rendimiento de los cultivos se han convertido en dos aspectos importantes para la toma de decisiones en la agricultura cañera (INICA; Villegas-Delgado, 2013).

En Garea y Rodríguez (2021), se propuso una metodología computacional para la estimación de población de la caña de azúcar, utilizando imágenes Sentinel-2. La metodología se centra en la clasificación de las áreas cañeras a partir de intervalos fijos de Índice de vegetación de diferencia normalizada (NDVI). Estos intervalos representan a las clases en que se clasifican los diferentes estadios de crecimiento del cultivo y en la presencia o no del mismo en el área estudiada. Los intervalos y clases fueron definidos a partir de la sistematización de metodologías descritas en la literatura y el ajuste estadístico realizado por los autores a partir del muestreo de las diferentes clases en unidades productivas distribuidas en las regiones occidental y central de Cuba. La tabla 1 muestra las clases que comprenden la clasificación según los intervalos de NDVI.

Aunque la metodología propuesta se ha venido aplicando de forma experimental en diferentes empresas azucareras del país durante los años 2020 al 2022 con resultados satisfactorios, estos pueden variar en su grado de exactitud en la clasificación, debido a la gran diversidad de condiciones ambientales, atmosféricas y físicas que influyen sobre las imágenes utilizadas para la clasificación (Souza et al, 2022). Este hecho conlleva a que el uso de intervalos de NDVI fijos para cada clase produzca, en no pocas ocasiones, clasificaciones erróneas de las coberturas y un sesgo en la estimación final del índice de población del área estudiada.

**Tabla 1. Clases e intervalos de clasificación del NDVI para la estimación de la población de la caña de azúcar (Garea y Rodríguez, 2021)**

Clase	Intervalo de valores de NDVI
Agua	-1-(-0.8)
Suelo desnudo o rocas	-0.8-0
Suelo desnudo con pastos o maleza esparcida o restos de cosecha	0-0.1
Caña en crecimiento o crecida de bajo porte	0.1-0.21
Caña crecida	>0.21

El uso de las redes neuronales convolucionales (CNN) ha experimentado un acelerado desarrollo en los últimos 10 años con resultados muy prometedores y altos valores de exactitud en tareas de clasificación de coberturas terrestres (Muhammad et al, 2023). Cuando hablamos de redes neuronales convolucionales, nos referimos a un tipo de red neuronal artificial donde las neuronas corresponden a campos receptivos de una manera muy similar a las neuronas en la corteza visual primaria de un cerebro biológico. Pero además son de las últimas tendencias en procesamiento de imágenes con aprendizaje profundo (LeCun et al, 2015).

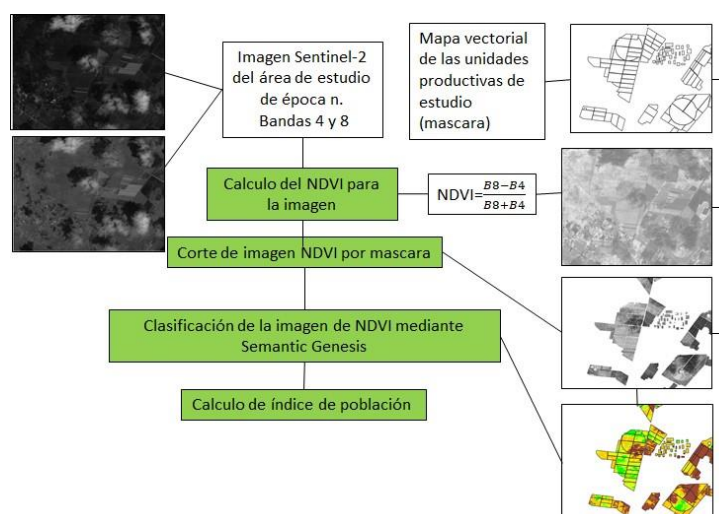
En Haghghi et al (2020), se propuso el marco de génesis semántica (*semantic genesis* o SG), un marco de aprendizaje auto-supervisado que permite que los modelos aprendan directamente la representación visual común de los datos de la imagen y aprovechen la representación semánticamente enriquecida de patrones anatómicos consistentes y recurrentes presentes en las imágenes médicas. Este modelo introdujo dos componentes novedosos: el autodescubrimiento y la auto-clasificación de la anatomía implícita en las imágenes médicas. Este marco de aprendizaje auto-supervisado permite entrenar modelos de aprendizaje profundo desde cero en imágenes sin etiquetar. SG está compuesto por una estructura de codificador-decodificador con conexiones de salto en el medio y un cabezal de clasificación al final del codificador. El objetivo del modelo es aprender diferentes conjuntos de representaciones enriquecidas semánticamente desde múltiples perspectivas. Para ello, los autores proponen tres componentes importantes: 1) autodescubrimiento de patrones; 2) auto-clasificación de patrones; y 3) auto-restauración de los patrones transformados. Una vez que se construye el conjunto de patrones auto-descubiertos, las ramas de clasificación y restauración se entrenan conjuntamente en el modelo. Los resultados presentados por estos autores demuestran que SG es superior a otros modelos basados en CNN, previamente entrenados mediante auto-supervisión o incluso totalmente supervisados.

Tomando en cuenta estos elementos y considerando que las coberturas que se deben clasificar poseen una marcada influencia de los patrones de textura que caracterizan a este cultivo, se plantea la hipótesis de que, es posible hacer una analogía entre estas características y las características de las imágenes médicas donde la textura es un elemento esencial que define los patrones anatómicos. En este trabajo se propone la sustitución de la clasificación por intervalos de NDVI, planteada como base de la metodología presentada en Garea y Rodríguez (2021) por un modelo basado en aprendizaje profundo utilizando los conceptos de SG. Se continúa con la descripción del modelo propuesto y los datos utilizados para el entrenamiento y prueba del modelo. Seguidamente se presentan los resultados experimentales obtenidos y su discusión. Finalmente se emiten las conclusiones del mismo.

## **2. METODOLOGÍA**

### **2.1. Génesis Semántica (SG) para la tarea de clasificación de imágenes**

En la figura 1 se presenta el esquema general de la metodología propuesta en Garea y Rodríguez (2021) modificada para la sustitución del proceso de clasificación por intervalos NDVI por clasificación mediante el modelo basado en SG.



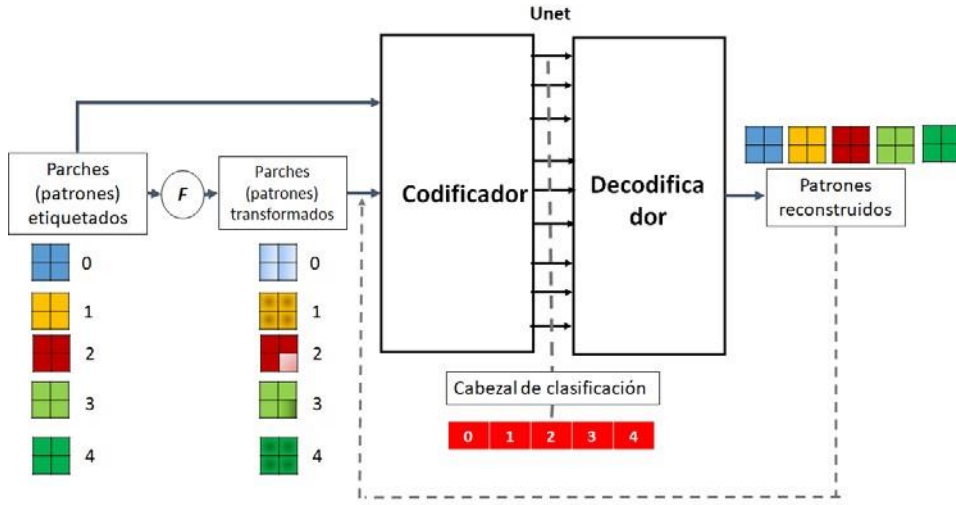
**Figura1. Esquema general de la metodología de Garea y Rodríguez (2021) modificada.**

El primer paso de la metodología se centra en el cálculo del NDVI. Para ello es necesaria la imagen correspondiente a la fecha que se desea evaluar y la extensión del área de estudio. El cálculo del NDVI se realiza de forma automática, a partir de operaciones aritméticas entre las imágenes de las bandas espectrales que lo integran. El segundo paso comprende el recorte de la imagen NDVI para cada una de las unidades productivas a evaluar. En el tercer paso se realiza la clasificación de la imagen NDVI de cada unidad productiva. Es precisamente en este paso donde se propone la sustitución del método propuesto por Garea y Rodríguez (2021).

Para esta tarea proponemos el enfoque SG (Haghighi et al, 2020). El marco de génesis semántica tiene como objetivo aprender diferentes conjuntos de representaciones enriquecidas con semánticas desde múltiples perspectivas y utilizar esta representación aprendida en la tarea de clasificación. En este trabajo proponemos la adaptación de este enfoque a la tarea de clasificación para imágenes de teledetección, más concretamente en la clasificación para la estimación del índice de población del cultivo de la caña de azúcar (Figura. 2).

Este marco consta de tres componentes: 1) Selección y etiquetado de patrones de coberturas, 2) Clasificación de patrones de coberturas y 3) Restauración de patrones de coberturas. Como se ilustra en la Fig. 2, el SG es conceptualmente simple: una estructura de codificador-decodificador basada en la CNN Unet (Ronneberger et al, 2015) con conexiones de salto entre la red y un cabezal de clasificación al final del codificador.

**Selección y etiquetado de patrones de coberturas:** en este primer paso, en el proceso de entrenamiento, se construye un conjunto de patrones a partir de las muestras (parches) de las diferentes coberturas correspondientes a las clases a estimar. Para ello, cortamos parches para cada clase que comparten una textura similar. Se asignan etiquetas a estos parches en función de la cobertura de la que se extrajo, lo que da como resultado un conjunto de datos, en el que cada parche está asociado con una de las clases. Dado que las coordenadas se seleccionan al azar, algunos de los patrones pueden no ser muy significativos a simple vista; sin embargo, estos patrones están asociados con la textura local del cultivo. En el proceso de clasificación, una vez que la red ha sido entrenada, solo recibe los parches de la imagen a clasificar como entrada sin etiquetar (Fig.2).



**Figura 2. Esquema de entrenamiento del modelo basado en SG**

**Clasificación de patrones de coberturas:** como entrada, en el proceso de entrenamiento, recibe los parches y los clasifica recursivamente enviándolos al decodificador hasta clasificar todos los parches según su etiqueta. Previamente, se realizan una serie de transformaciones a los parches de entrada que permiten obtener mayor robustez en las características profundas extraídas, a la vez que sirve como método de aumento de datos. En nuestro caso asumimos la serie de transformaciones propuestas en Haghighi et al, (2020), es decir, transformaciones lineales, no lineales y de cierre local.

En el proceso de clasificación, una vez entrenada la red, solo recibe los parches y el proceso termina con la salida del cabezal de clasificación sin llegar al decodificador.

**Restauración de patrones de coberturas:** el objetivo de la restauración es que el modelo aprenda diferentes representaciones visuales, recuperando patrones originales de las coberturas a clasificar. Como se muestra en la Fig. 2, la rama de restauración codifica el patrón de entrada en un espacio latente y lo decodifica a la resolución original para recuperar el patrón original.

Para entrenar el modelo, definimos las siguientes funciones de pérdida para la multitarea (Restauración y clasificación) (1):

$$L = \gamma_{cl} * L_{cl} + \gamma_{rc} * L_{rc} \quad (1)$$

Donde:

$\gamma_{cl}$  y  $\gamma_{rc}$  - regulan los pesos de las pérdidas de clasificación y reconstrucción, respectivamente.

$L_{cl}$  - es la función de pérdida del proceso de clasificación, en este caso adoptamos la función de pérdida de entropía cruzada categórica expresada por la expresión 2, donde  $N$  denota el tamaño del lote;  $y$  es la etiqueta de clase y  $p(y)$  es la probabilidad de predicción de la etiqueta.

$$L_{cl} = -\frac{1}{N} \sum_{i=1}^N (y_i \cdot \log(p(y_i)) + (1 - y_i) \cdot \log(1 - p(y_i))) \quad (2)$$

$Lrc$  es la distancia  $L2$  entre el patrón original y el patrón reconstruido expresado como una función de pérdida a través de la expresión 3, donde  $N$  es el tamaño del lote,  $X$  es la verdad del terreno (patrón original) y  $X'$  es la etiqueta obtenida en la predicción.

$$Lcl = -\frac{1}{N} \sum_{t=1}^N \|Xt - Xt'\|^2 \quad (3)$$

La adopción de  $Lcl$  basada en Haghghi et al (2020), permite que el modelo aprenda una representación enriquecida semánticamente. De manera similar, el uso de la función  $Lrc$  anima al modelo a aprender desde múltiples perspectivas al tratar de restaurar las imágenes originales, a partir de varias deformaciones de la imagen.

## 2.2. Datos de entrenamiento y prueba

Para el entrenamiento y validación del modelo de clasificación propuesto se tomaron un conjunto de imágenes Sentinel-2 correspondientes a la cobertura de la Empresa Azucarera Ciro Redondo, de la provincia Ciego de Ávila. Para el estudio se emplearon imágenes correspondientes a dos periodos; entre el 1 y el 23 de marzo de 2021 (correspondiente a la época fenológica de establecimiento y germinación de la planta) y del 20 de agosto al 9 de septiembre de 2021 (correspondiente a la época fenológica de crecimiento de la planta).

Para la prueba del modelo se tomaron imágenes del mismo lugar correspondientes a estos mismos periodos, pero del año 2022.

Para el proceso de entrenamiento se tomaron 500 muestras de cada una de las clases correspondientes a los tres estadios de desarrollo de la caña de las imágenes de la región del año 2021 y de otras regiones del país se tomaron 1500 muestras correspondientes al resto de las clases de la tabla 1. En total el conjunto estuvo conformado por 3000 muestras, de las cuales se tomó de forma aleatoria el 80% para entrenamiento y el 20% para validación. Igualmente se conformó un conjunto de prueba con 500 muestras (100 por cada clase), diferentes a las utilizadas en el entrenamiento correspondiente a las imágenes de 2022.

Para comparar el rendimiento del modelo propuesto, entrenamos otros 3 modelos usados en teledetección para la clasificación de coberturas terrestres: Vgg16 (Ye et al, 2021), ResNet50 (Amsa et al, 2021) e *Inception* (Firat et al, 2023). Estos tres modelos fueron entrenados con el mismo conjunto de entrenamiento para 200 épocas, usando entropía cruzada categórica como función de pérdida y el optimizador de Adam. A diferencia del modelo Unet, estos últimos tres modelos no poseen la estructura tipo codificador-decodificador.

## 2.3. Detalles de implementación y entrenamiento

La implementación de los modelos se realizó sobre la librería de código abierto Keras (con licencia MIT) escrita en *Python*. El objetivo de usar esta biblioteca fue facilitar la implementación del modelo porque Keras no funciona como un marco independiente, sino como una interfaz de usuario intuitiva (API) que permite el acceso a varios marcos de aprendizaje automático como *TensorFlow*.

El proceso de entrenamiento se realizó en un HPC de 5 nodos; Servidores HP Proliant XL230a Gen9 con 2 CPU x nodo: Intel Xeon E5-2670 a 2.30GHz, 12C, para un total de 24 *cores* por nodo, 120 *Computing Cores*. RAM: 48 GB por nodo. Los modelos fueron entrenados para 200 épocas.

### 3. RESULTADOS Y DISCUSIÓN

Para la evaluación del desempeño del modelo propuesto se utilizó la medida “*Accuracy*”, que es el número de aciertos reales obtenidos por el clasificador sobre el número total de muestras en el conjunto de prueba. Los resultados obtenidos se muestran en la Tabla 2. Se midieron dos valores de precisión. El primero (Val\_acc) obtenido sobre el proceso de entrenamiento (para el cual se tomó el valor máximo obtenido durante las 200 épocas de entrenamiento), y el segundo (Test\_acc), sobre el conjunto de prueba usando el modelo entrenado. Se puede observar que el modelo propuesto y ResNet50 obtuvieron los mejores resultados, con un desempeño similar en el conjunto de prueba.

**Tabla 2. Resultados obtenidos en el proceso de entrenamiento y prueba**

Modelo	Val_acc	Test_acc
Vgg16	0.875	0.842
ResNet50	0.941	0.933
Inception	0.837	0.815
Modelo propuesto	0.956	0.936

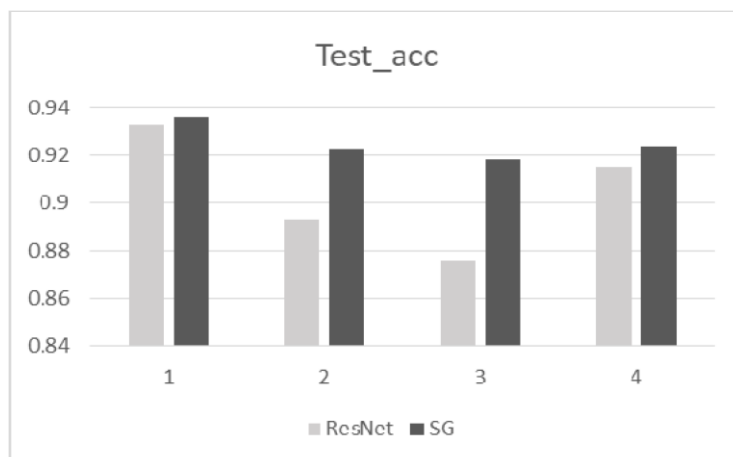
Para verificar la robustez de los resultados obtenidos por el clasificador implementado, se desarrolló un proceso de evaluación del mismo, mediante un esquema de validación cruzada de 4 veces (4fold). Para comparar el rendimiento del modelo propuesto, se aplicó este mismo esquema de validación cruzada al modelo ResNet50 que logró resultados similares a los nuestros en el primer experimento.

La validación cruzada es un método de remuestreo de datos para evaluar la generalización de los modelos predictivos y evitar el sobreajuste. En la validación cruzada de k veces, el conjunto de aprendizaje disponible se divide en k subconjuntos disjuntos de aproximadamente el mismo tamaño. Aquí, "doblar" (*fold*) se refiere al número de subconjuntos resultantes. Un muestreo aleatorio del conjunto de entrenamiento hace esta partición. El modelo se entrena usando k – 1 subconjuntos que representan el conjunto de entrenamiento. Luego, el modelo se aplica al subconjunto restante, denominado conjunto de validación, y se mide el rendimiento. Este procedimiento se repite hasta que cada k subconjunto haya servido como conjunto de validación. El promedio de las mediciones de rendimiento en los conjuntos de validación k es el rendimiento de validación cruzada.

Para nuestro experimento, la base de datos de 3000+500 muestras, se dividió aleatoriamente en 4 *folds* de 875 muestras cada uno, y el modelo se entrenó y probó utilizando el esquema de 4 *folds*.

La figura 3 muestra los resultados obtenidos. Se puede observar que, si bien el promedio de las medidas de desempeño del clasificador propuesto es de 0.925 con una desviación estándar de 0.007, el clasificador mantiene su precisión en todos los *folds* por encima de 0.92. Sin embargo, el modelo ResNet50 no mantuvo el mismo desempeño en los 4 *folds*, obteniendo un promedio final de 0.904 con una desviación estándar de 0.024.



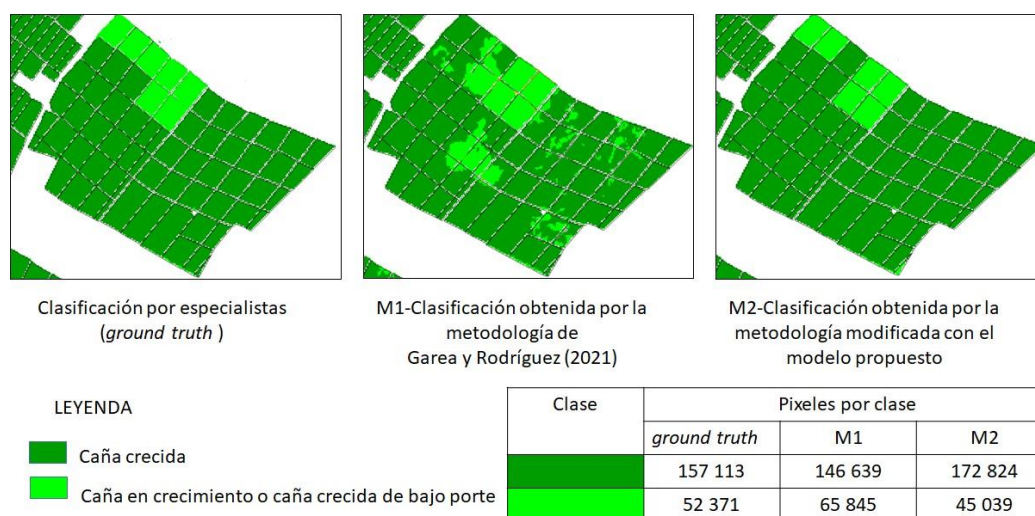


**Figura 3. Resultados de la validación cruzada 4 fold.**

Con el objetivo de comprobar la efectividad del cambio de método de clasificación en la metodología de estimación de la población de caña de azúcar (Garea y Rodríguez, 2021), realizamos la comparación de los resultados obtenidos por ambas variantes de la metodología sobre un área de la empresa “Ciro Redondo”, de la provincia Ciego de Ávila. Para ello se compararon los resultados de las clasificaciones con un mapa de inventario de siembra del cultivo, realizado por los especialistas de la empresa por métodos convencionales, donde aparecen las áreas que en ese momento (28 marzo de 2022) se encontraban todas pobladas por el cultivo y que fueron sembradas en la misma época, este mapa fue asumido como la verdad absoluta o *ground truth*, aunque resulta imposible saber realmente si esto es así, por lo que estos resultados preliminares deben ser aún comprobados en la práctica bajo criterios de especialistas en el cultivo. La figura 4 muestra el *ground truth* y los correspondientes resultados obtenidos por cada una de las variantes de la metodología.

Para realizar una evaluación cuantitativa de la eficacia se calcularon las métricas de Sensibilidad y Especificidad (5), teniendo en cuenta la clase de “caña crecida” (clase1) que en el *ground truth* aparece en el 75% de área estudiada, mientras que el resto (15%) corresponde a la clase de “caña en crecida de bajo porte” (clase 2). Asumimos entonces los píxeles correctamente clasificados como clase 1 (TP), los clasificados erróneamente como clase 1 (FP), los clasificados correctamente como clase 2 (TN) y los clasificados erróneamente como de clase 2 (FN). Las expresiones en (4) y (5) calcularon las métricas. La Tabla 3 presenta los resultados de estas métricas obtenidas para los métodos evaluados. La Tabla 4 muestra las matrices de confusión de ambas variantes de la metodología.

$$Sens = \frac{TP}{(TP + FN)} \quad (4) \quad (5) \quad Espec = \frac{TN}{(TN + FP)}$$



**Figura 4. Comparación del *ground truth* y los correspondientes resultados obtenidos por cada una de las variantes de la metodología. Tabla 3. Resultados de la comparación**

Metodología	<i>Sens</i>	<i>Espec</i>
Garea y Rodríguez, 2021	0.774	0.714
Modificada	0.999	0.740

**Tabla 4. Matrices de confusión obtenidas**

M1		M2	
TP=136 165	FP=10 474	TP=157 113	FP=15 711
FN= 39 660	TN=26 185	FN= 125	TN=44 914

Como puede observarse el modelo propuesto presenta mejor desempeño que la clasificación directa por intervalos de NDVI, el modelo es capaz de aprender a diferenciar con bastante exactitud a las dos clases que comprende la clasificación y que después se toman como base para el cálculo del índice de población. Está claro que estos son resultados preliminares que requieren un mayor volumen de experimentación y validación. Por otro lado, se hace necesario también entrenar el modelo con una mayor diversidad de muestras, tomadas en diferentes lugares del país y con diferentes fechas de adquisición de imágenes para obtener un clasificador con más capacidad de extrapolación. Sin embargo, consideramos que este puede ser un punto de partida para la obtención de resultados más precisos en la evaluación de las poblaciones del cultivo.

#### 4. CONCLUSIONES

En este trabajo se presenta un modelo basado en aprendizaje profundo sobre la base de los conceptos de génesis semántica para la clasificación de imágenes Sentinel-2. El modelo toma como característica para la clasificación al índice de vegetación de diferencia normalizada. Se mejora la metodología existente para estimar el índice de población de la caña de azúcar. El modelo propuesto, integrado a la metodología fue aplicado en áreas cañeras del país. Los resultados fueron comparados con los obtenidos por especialistas del cultivo y con los obtenidos por la metodología original, demostrando una exactitud superior y la factibilidad de su aplicación.

## 5. AGRADECIMIENTOS

Los autores agradecen al Instituto de Investigaciones de la Caña de Azúcar (INICA) por la asesoría técnica brindada sobre el tema agro-azucarero, especialmente al Dr.C. Federico Sulrroca Domínguez y al M.Sc. Isaías Machado. A especialistas e investigadores de la UCT GEOCUBA IC por la colaboración brindada, especialmente a los Dr.C Edel García Reyes, Dr. C Rafael Cruz Iglesias y Dr.C José L. Capote Fernández; a los M.Sc. Homero Menéndez Pérez y M.Sc. Verónica Crespo Regalado; y a la Lic. Alejandra Benítez Puebla.

## BIBLIOGRAFÍA

Adams, J.B.; Gillespie, A.R: “Remote Sensing of Landscapes with Spectral Images: A Physical Modeling Approach”; Cambridge University Press: Cambridge, UK, 2006; pp. 1–362.

Amsa S, et al, Satellite and Scene Image Classification Based on Transfer Learning and Fine Tuning of ResNet50 , *Mathematical Problems in Engineering*, vol. 2021, Article ID 5843816, 18 pages, 2021. <https://doi.org/10.1155/2021/5843816>.

Firat, H., Asker, M.E., Bayındır, M.İ. et al. Hybrid 3D/2D Complete Inception Module and Convolutional Neural Network for Hyperspectral Remote Sensing Image Classification. *Neural Process Lett* 55, 1087–1130 (2023). <https://doi.org/10.1007/s11063-022-10929-z>.

Garea E y Rodríguez SV. Estimación de población y rendimientos de la caña de azúcar en Cuba mediante teledetección espacial. *Memorias de la III Convención Científica Internacional 2021*. Universidad Central “Marta Abreu” de Las Villas. ISBN 978-959-312-479-9.

Haghighi, F., Hosseinzadeh Taher, M.R., Zhou, Z., Gotway, M.B., Liang, J. (2020). Learning Semantics-Enriched Representation via Self-discovery, Self-classification, and Self-restoration. In: *Medical Image Computing and Computer Assisted Intervention – MICCAI 2020*. MICCAI 2020. Lecture Notes in Computer Science, vol 12261. Springer, Cham. [https://doi.org/10.1007/978-3-030-59710-8\\_14](https://doi.org/10.1007/978-3-030-59710-8_14).

INICA Instituto de investigaciones del azúcar. “La caña de azúcar”. Editorial Ciencia y Técnica. La Habana.

LeCun, Y., Bengio, Y. & Hinton, G. Deep learning. *Nature* 521, 436–444 (2015). <https://doi.org/10.1038/nature14539>.

Muhammad Y., Wan J., Liu S., Hui S., Xu M. & Md Hossain (2023) Coupling of deep learning and remote sensing: a comprehensive systematic literature review, *IJRS*, 44:1, 157-193, DOI: 10.1080/01431161.2022.2161856.

Ronneberger, O., Fischer, P., Brox, T. U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., Hornegger, J., Wells, W., Frangi, A. (eds) *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. MICCAI 2015. Lecture Notes in Computer Science, vol 9351. Springer, Cham. [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28).

Segarra J. et al. “Review: Remote Sensing for Precision Agriculture: Sentinel-2 Improved Features and Applications”. *Agronomy* 2020, 10, 641; doi: 10.3390/agronomy10050641.

Souza, W.d.O.; Reis, L.G.d.M.; Ruiz-Armenteros, A.M.; Veleda, D.; Ribeiro Neto, A.; Frago Jr., C.R.; Cabral, J.J.d.S.P.; Montenegro, S.M.G.L. Analysis of Environmental and Atmospheric Influences in the Use of SAR and Optical Imagery from Sentinel-1, Landsat-8, and Sentinel-2 in the

Operational Monitoring of Reservoir Water Level. *Remote Sens.* 2022, 14, 2218. <https://doi.org/10.3390/rs14092218>.

Villegas-Delgado R.: “Potencial Agroproductivo de los Suelos Dedicados al Cultivo de la Caña de Azúcar”. Primera Aproximación. INICA. 2013.

Ye M. et al., "A Lightweight Model of VGG-16 for Remote Sensing Image Classification," in *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 14, pp. 6916-6922, 2021, doi: 10.1109/JSTARS.2021.3090085.