

CLASIFICACIÓN DE COBERTURAS TERRESTRES: MÉTODOS SUPERVISADOS Y NO-SUPERVISADOS APLICADOS A CULTIVOS DE CAÑA DE AZÚCAR

Recibido: 15 de septiembre/2020
Aceptado: 29 de septiembre de 2020

H. R. Lárraga Altamirano¹
A. M. Piedad Rubio²
D. R. Hernández López³
O. Espinosa Guerra⁴

RESUMEN

El presente trabajo centra su atención en el estudio de los métodos de clasificación que ofrece uno de los sistemas de información geográfica libre y de código abierto de mayor uso en la actualidad, *Quantum Geographic Information System (QGIS)*, considerando como sujetos de prueba ortomosaicos de cultivos de caña de azúcar. Los vehículos aéreos no tripulados equipados con cámaras RGB permitieron realizar la fotogrametría que contiene la información espectral de la superficie terrestre. Para este caso, se utilizaron los algoritmos de clasificación denominados como: Distancia Mínima, Ángulo Espectral y *Kmeans*, los dos primeros supervisados y el último no supervisado. Los resultados de la clasificación supervisada fueron analizados mediante una matriz de confusión para conocer el grado de exactitud global y la índice kappa de cada técnica. Los datos resultantes muestran la efectividad de cada método y se presentan recomendaciones a la metodología que contribuirán a mejorar la clasificación de ortomosaicos de cultivos de caña de azúcar basada en la información espectral.

PALABRAS CLAVE

Clasificación supervisada, no-supervisada, Caña de azúcar, Distancia Mínima, Ángulo Espectral, *Kmeans*

ABSTRACT

This paper focuses its attention on the study of the classification methods offered by one of the most widely used free and open source geographic information system, Quantum Geographic Information System (QGIS), considering as test subjects orthomosaic of sugar cane crops. Unmanned aerial vehicles equipped with RGB cameras made it possible to carry out photogrammetry containing spectral information of land cover. For this case, the classification algorithms named as: Minimum Distance, Spectral Angle and Kmeans were used, the first two supervised and the last one unsupervised. The results of the supervised classification were analyzed using a confusion matrix to determine the degree of global accuracy and the kappa index of each technique. The resulting data show the effectiveness of each method and recommendations are presented that will contribute to improve the methodology of orthomosaic classification based on the spectral information of the sugarcane crop.

KEY WORDS:

Supervised classification, unsupervised, Sugarcane , Minimum Distance, Spectral Angle and Kmeans

¹ Profesor de Tiempo Completo. Tecnológico Nacional de México, Campus Ciudad Valles, hugo.larraga@tecvalles.mx

² Profesora de Tiempo Completo. Tecnológico Nacional de México, Campus Ciudad Valles, ana.piedad@tecvalles.mx

³ Profesora de Tiempo Completo. Tecnológico Nacional de México, Campus Ciudad Valles, dalia.hernandez@tecvalles.mx

⁴ Profesor de Tiempo Parcial. Tecnológico Nacional de México, Campus Ciudad Valles, omar.espinosa@tecvalles.mx

INTRODUCCIÓN

Es innegable que la agricultura es parte vital para la existencia de la especie humana como actividad principal en la producción de alimentos. El continuo crecimiento de la población mundial exige inversiones más inteligentes en la administración del campo, por una parte, la demanda de mayores niveles de producción de alimentos y por otra, la escasez de recursos naturales como el agua y suelos fértiles (Tripicchio, Satler, Dabisias, Ruffaldi, & Avizzano, 2015). Para lograr una agricultura sustentable el uso de la tecnología juega un papel importante, diversas técnicas son empleadas para incrementar el rendimiento de los cultivos, reducir los costos de producción y mantener el equilibrio con el medio ambiente. El uso de los Sistema de Información Geográfica (SIG) ayudan, por ejemplo, a construir mapas para ubicar sectores de riesgo en el campo, distribuir cultivos de acuerdo al tipo de suelo, clasifican la vegetación para predecir el rendimiento de los cultivos e impactos ambientales, modelan patrones de pérdida de agua, seguimiento de trayectoria de animales, entre otras tareas (Abdullahi, Sheriff, & Mahieddine, 2017).

La disciplina que propone a los productores reducir los esfuerzos propios que implica la labor del campo y producir cultivos de manera sostenible y sustentable mediante la integración de tecnología se denomina, Agricultura de Precisión (AP). De las aplicaciones de mayor uso en el sector agrícola que provee la AP es el monitoreo de cultivos mediante imágenes, a través del cual, es posible determinar índices de biomasa, estrés hídrico, detección temprana de enfermedades, uso de suelo, entre otros factores que influyen en la toma de decisiones de quienes administran el campo (Constante, y otros, 2016). Estas tareas realizan procesos de cómputo especializados para el tratamiento de las imágenes, como identificar objetos dentro de una fotografía y extraer características que los identifiquen inequívocamente en cualquier escenario. Una de las fases de mayor importancia en el procesamiento de imágenes es la clasificación, con la cual es posible agrupar los píxeles en clases de características similares. La utilidad de este proceso se ve en el monitoreo de cultivos, donde un sistema de estimación de la superficie cultivada a través de imágenes adquiridas por percepción remota es esencial y cuya exactitud, depende de que tan efectivo sea el modelo de clasificación para proporcionar datos que reflejen con más acierto la realidad (Mate, Singh, & Khobragade, 2016).

Por lo anterior, el presente trabajo centra su atención en el estudio de los métodos de clasificación que ofrece uno de los SIG libre y de código abierto de mayor uso en la actualidad, *Quantum Geographic Information System (QGIS)*, considerando como sujetos de prueba ortomosaicos de cultivos de caña de azúcar. Se reconocen dos tipos de técnicas de clasificación: supervisadas y no supervisadas, ambas, ampliamente utilizadas por los SIG que a través del análisis de la información espectral distinguen clases de objetos en un mapa, tales como: cultivos, edificios, arboles, calles, predios baldíos, casas habitacionales, etc. (Long & Srihann, 2004). Clasificar, es la tarea de etiquetar un grupo de píxeles de una imagen que se encuentran en el mismo dominio espectral (clase o categoría), permitiendo así, diferenciarlo de otros grupos. La clasificación no supervisada es una operación de segmentación de la imagen, basada en algoritmos de agrupamiento o *clustering*, cuya finalidad es agrupar los elementos en función de alguna similitud entre ellos; mientras que la clasificación supervisada se basa en la existencia de áreas de entrenamiento en donde se parte de un conjunto de clases preestablecidas con un píxel representativo a cada una de ellas (Dallos Bustos, 2017).

La metodología propone cuatro etapas para el desarrollo del estudio: la planeación del vuelo, donde se adquieren la galería de imágenes de los cultivos de caña de azúcar; el procesamiento de imágenes para generar los ortomosaicos; la clasificación supervisada y no supervisada y, por último; el análisis de la información obtenida. En el apartado de resultados se presentan evidencias de cada paso del desarrollo, incluye imágenes de los cultivos mapeados, el resultado de la clasificación de 3 algoritmos utilizados y la discusión de estos productos, además de exponer los análisis estadísticos para determinar la exactitud de la clasificación. Se concluye con las observaciones de cada método implementado, el software utilizado y recomendaciones para trabajos futuros

METODOLOGÍA

La Percepción Remota es un componente determinante en la AP, sobre todo, cuando se habla de monitoreo de cultivos a través de imágenes aéreas o satelitales con las que es posible clasificar unidades de vegetación, crear inventarios, conocer las etapas de crecimiento, el vigor vegetal, necesidades nutrimentales, hacer estimaciones de la biomasa y rendimientos, muestrear propiedades físicas y químicas del suelo en complejos entornos biofísicos (Aguilar Rivera, 2015). La radiación reflejada por la vegetación es capturada en una imagen por medio de un sensor (cámara) colocado en un vehículo aéreo no tripulado (VAN) que recorre amplias extensiones de terreno. Estas imágenes que contienen la información espectral del cultivo son afectadas por un conjunto de variables que influyen en el procesamiento de los píxeles, es por eso que la segmentación y clasificación de objetos es la etapa de mayor relevancia en el proceso de análisis de una imagen (Sabzi, Abbaspour-Gilandeh, & Javadikia, 2017). El experimento tuvo como sujetos de estudio dos cultivos de caña de azúcar de los ranchos El Encanto y La Aurora ubicados en el municipio de Ciudad Valles, San Luis Potosí, México. El procedimiento constó de cuatro fases:

Plan del vuelo

Las imágenes son adquiridas a través de un vehículo aéreo no tripulado (VAN) conocido como dron, modelo DJI Phantom 4 Pro equipado con una cámara RGB para sensar las bandas rojo, verde y azul del espectro electromagnético, con una duración de vuelo de aproximadamente 20 minutos por batería. El software para operar el vehículo que se utilizó fue la aplicación DJI GO 4 para Android, la cual, a través de la telemetría, permite detectar el estado de la aeronave, los sensores y la cámara.

En este caso, se utilizó Google Earth para conocer la geolocalización de los predios y así poder exportarlos como archivos kmz, e importarlos en el software de vuelo programado, de esta manera el piloto conoce el área que se volará anticipadamente. Para programar la fotogrametría del vuelo se usó la aplicación Pix4D Capture y Ctrl + DJI solo disponible para Android, la configuración de los parámetros del vuelo autónomo se muestra a continuación:

Traslape (*Overlapping*): 80%

Velocidad: intermedia

Ángulo de la cámara: 90 gados

Orientación: forward

Altura: 70 metros

Es recomendable realizar una visita al campo para estudiar las condiciones del terreno, observar si existen obstáculos, sus alturas y ubicaciones, condiciones del viento, infraestructura que genere radiación electromagnética, con la intención de tener datos

confiables de configuración y evitar una colisión durante el vuelo (González, Amarillo, Amarillo, & Sarmiento, 2015).

Procesamiento de imágenes

Una vez que el vuelo se ha realizado y se dispone de la galería de imágenes de los cultivos, la siguiente etapa es la construcción del ortomosaico, esta se realizó con el software de transformación conocido como Pix4D Mapper. Los sistemas de transformación procesan las imágenes utilizando los datos geoespaciales adheridos en los metadatos, combinándolas muy similar a la integración de un mosaico para presentar una sola imagen (ortoimagen) del cultivo. Las imágenes RGB capturadas son utilizadas para generar productos cartográficos como: el mapa de reflectancia, el modelo de elevaciones, nube de puntos, entre otros.

Es importante señalar que los productos son elementos de 2D (dos dimensiones), a pesar de que el software permite el modelado 3D, se recomienda que se inhabiliten las opciones para efectos de consumir menos tiempo en el procesamiento que consume una cantidad de tiempo considerable. El resultado final es una única imagen en formato .tif del total de la extensión de la superficie sobrevolada por el dron (Tapia Arenas, Guevara Bonilla, & Esquivel Segura, 2019).

Clasificación de las imágenes

La clasificación del mosaico RGB creado a partir del índice de las imágenes capturadas por el dron, tiene como finalidad distinguir las unidades de vegetación correspondientes al cultivo de caña de azúcar, de otro tipo de vegetación y del suelo. Los primeros dos métodos de clasificación a implementar son supervisados, requieren de una etapa de entrenamiento y son conocidos como: Distancia Mínima y Ángulo Espectral. El primero utiliza valores espectrales medios de las distintas clases, ignorando las varianzas entre ellas, mientras que los segundos utilizan una regla de decisión basada en ángulos espectrales formados entre un espectro de referencia y un píxel no clasificado en un espacio de n dimensiones, donde n es el número de bandas disponibles (Willington, Nolasco, & Bocco, 2013). El tercer método por implementar es de categoría no supervisado se denomina *Kmeans* o clusterización. Esta técnica clasifica un determinado conjunto de objetos en k *clusters* (clases), cada *cluster* es representado por la media de sus puntos, es decir, su centroide (Cambronero, 2006).

Para la clasificación supervisada se establecieron tres clases de entrenamiento: la caña de azúcar (clase 1), suelo natural (clase 2) y otra vegetación (clase 3), representadas por buffers de píxeles extraídos de la imagen original por medio del componente *Semi-Automatic Classification Plugin* (SCP) y la herramienta *Region Of Interest* (ROI). Esto, permite crear la firma espectral de cada clase que identifica y etiqueta el resto de los píxeles de la ortoimagen, los algoritmos ejecutados son Distancia Mínima y Ángulo Espectral. La clasificación no supervisada es realizada por la herramienta *System for Automated Geoscientific Analyses* (SAGA), la cual implementa el algoritmo *Kmeans* que actúa sobre imágenes monobanda, por lo que se separa la ortoimagen en los componentes: R, G y B. Los parámetros del *Kmeans*, especifican el número de *clusters* en que se agrupara los píxeles y de iteraciones para establecer los centroides, se definieron los valores de 10 y 5 respectivamente.

Evaluación del modelo

Los modelos de clasificación de imágenes requieren métodos de evaluación para medir el nivel de exactitud. El mecanismo más usual para realizar esta actividad se conoce como matriz de confusión; este estadístico contiene la información obtenida por el algoritmo de clasificación versus la clase a la que las muestras de la escena realmente pertenecen, con esta información se calcula el nivel de concordancia entre regiones identificadas por el clasificador y la ubicación real en el terreno. El índice de exactitud es la proporción del total de las clasificaciones correctas respecto al total de píxeles procesados por la matriz. Otro índice de efectividad en el proceso de clasificación es Kappa, el cual mide el porcentaje de acierto entre lo clasificado y las clases muestra (Santamaria & Aldalur, 2014).

La matriz de confusión se implementó con la herramienta SAGA, a través del conjunto de funciones que posee para la clasificación de imágenes. Se comparó la efectividad de los métodos de clasificación supervisada y se obtuvo la combinación de ambas clasificaciones, adicionalmente se calcularon los índices de exactitud y kappa. La clasificación no supervisada se consideró como un marco de referencia para determinar las clases de entrenamiento no forma parte de la matriz de confusión.

RESULTADOS

La planeación del vuelo dio inicio con la geolocalización de los predios en Google Earth, donde se focaliza con un polígono en rojo el área que se planea volar, aproximadamente se cubren en ambos casos de 8 a 9 hectáreas, Figura 1.



Figura 1. Geolocalización de los predios a estudiar, A) El Encanto B) La Aurora Fte. Google Earth

La ubicación es exportada en formato kmz para ser utilizada por el software de vuelo programado Pix4D Capture, posterior, se configuró la misión con los parámetros señalados en la sección anterior, Figura 2.



Figura 2. Configuración del plan de vuelo en Pix4D Capture Fte. Propia

De la ejecución del vuelo se obtuvieron dos galerías de imágenes RGB pertenecientes a los ranchos El Encanto y La Aurora, productores de caña de azúcar, con 173 y 198 fotografías georreferenciadas, respectivamente.

La construcción de los ortomosaicos de cada terreno se realizó en Pix4D Mapper, el proceso duró aproximadamente 7 horas, utilizando un equipo Laptop Dell Inspiron 15, Intel Core I7 8th Gen, 16 GB RAM, Figura 3.




Figura 3. Procesamiento de imágenes Pix4D Mapper Fte. Propia

El procesamiento de imágenes produce la nube de puntos, el modelo digital de superficie y la ortoimagen esperada para el análisis, Figura 4.




Figura 4. Ortomosaicos A) El Encanto y B) La Aurora. Fte. Propia

Estas ortoimágenes muestran los cultivos de caña de azúcar de los dos casos de estudio, se observan elementos como carreteras, veredas, vegetación diversa, construcciones, líneas eléctricas y por supuesto, los cultivos de caña de azúcar. Un productor cañero requiere conocer la cantidad de caña que produce por hectárea, es por eso por lo que, la tarea de clasificar eficientemente constituye la base para tomar decisiones acertadas.

Como se explicó anteriormente, los métodos para clasificar son supervisados y no supervisados, en este caso, se inició en QGIS la implementación de los algoritmos de Distancia Mínima y Angulo Espectral.

Para la etapa de entrenamiento de estas técnicas supervisadas se crearon cuatro macro clases: caña (verde), suelo (gris), otra vegetación (amarillo) y áreas sin interés (blanco). Por cada una de estas se definieron cuatro regiones de interés, a excepción de la última, que solo ocupa una muestra de pixeles pues representa el contorno de la fotografía. En color oscuro se puede apreciar las áreas de entrenamiento que sirven para calcular la firma espectral que define a un cuerpo, Figura 5.

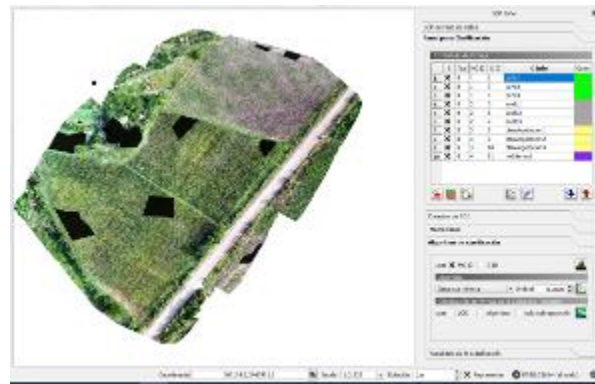


Figura 5. Entrenamiento para Clasificación Supervisada Fte. Propia

Posterior a la configuración del entrenamiento se ejecutaron los dos algoritmos. La Figura 6a muestra el resultado de la clasificación por Distancia Mínima, de la misma manera, la Figura 6b presenta el resultado de la clasificación por Ángulo Espectral.




Figura 6. Resultado de la clasificación supervisada El Encanto A) Distancia Mínima B) Ángulo Espectral. Fte. Propia

Aunque pareciera que los dos algoritmos producen los mismos resultados, existen pequeñas diferencias que se aprecian en las imágenes, por ejemplo, el suelo (color gris) se percibe con mayor presencia entre el cultivo en la Figura 6a, en el campo real estas diferencias podrían abarcar varios metros cuadrados y poner en duda la toma de una decisión. Para el caso de estudio La Aurora, la Figura 7a y 7b presentan los ortomosaicos clasificados, no se definieron nuevos entrenamientos debido a que las características del cultivo son muy similares al anterior y el vuelo se realizó con las mismas condiciones técnicas, climáticas y de horario.




Figura 7. Resultado de la clasificación supervisada La Aurora A) Distancia Mínima B) Ángulo Espectral. Fte. Propia

La clasificación no supervisada se realizó por medio del algoritmo Kmeans, también a través de la plataforma QGIS. El proceso consistió en agrupar en 10 clases los objetos del ortomosaico, esta clusterización puede conducir la investigación hacia nuevas hipótesis, como, por ejemplo, utilizar los centroides de los grupos como firma espectral de las clases de entrenamiento, en la discusión de resultados se comentará sobre este caso particular que se muestra en la Figura 8.




Figura 8. Resultado de la clasificación no supervisada A) El Encanto B) La Aurora Fte. Propia

La clusterización etiqueta en colores azul los tipos de suelo natural y asfalto, de la misma manera identifica las construcciones dentro de esta gama, la vegetación a nivel de suelo está representada con colores amarillos y la vegetación alta y la caña con colores rojo. De ahí, que este método quizá pueda ser usado para identificar con mayor exactitud las clases y su firma espectral, datos de entrada de las técnicas supervisadas, sin embargo, ese tema excede el ámbito de estudio de este trabajo.

Para la evaluación del modelo se calcularon las matrices de confusión utilizadas para comparar los métodos de Distancia Mínima y Ángulo Espectral, además de conocer el grado de exactitud en que los píxeles han sido clasificados correctamente por el algoritmo (exactitud global), y el grado de acierto en que los píxeles se han clasificado correctamente respecto a la clase a la que pertenecen (kappa). En la Tabla 1, se muestran la matriz de confusión para el rancho El Encanto.

Tabla 1. Matriz de confusión, El Encanto. Fte. Propia

Nombre	Caña	Suelo	OtraVegetación	NoClasificado	Totales
Caña	22763932	363802	517067	0	23644801
Suelo	0	8226879	3208614	0	11435493
OtraVegetación	76779	265812	15046908	0	15389499
NoClasificado	0	0	0	33849497	33849497
	22840711	8856493	18772589	33849497	84319290

Exactitud	55%
Kappa	48%

En esa clasificación espectral la tasa de exactitud global fue del **55%** y, **48%** de los píxeles están correctamente ubicados en las clases a las que pertenecen. Los píxeles pertenecientes al contorno de la imagen son etiquetados como No Clasificados, lo cual es correcto, pues no contienen información de interés para los productores cañeros o para el cálculo del índice de exactitud global. La Caña es clasificada adecuadamente, **27%** global con aproximadamente el **100%** de los píxeles etiquetados correctamente, presenta un mínimo grado de confusión con otra vegetación. El suelo representa la cantidad menor de píxeles analizados (**9%** global), el **90%** se etiquetó en la clase correcta con grados mínimos de confusión entre las clases 1 y 3. La otra vegetación tiende a confundirse con la clase 2 (suelo) en un grado de significancia, posiblemente porque hay una fracción del predio que tiene un cultivo diferente a la caña de azúcar con follaje de menor espesor para el que no se definió un patrón espectral, presenta un **80%** de los píxeles etiquetados correctamente.

La Tabla 2 presenta los resultados de la matriz de confusión para el rancho La Aurora. Se observa un índice de exactitud global del **65%** con una índice kappa del **57%**, la diferencia radica en que el ortomosaico presenta menos elementos que el campo anterior, por ejemplo, no tiene cultivos diferentes a la caña, tampoco construcciones que puedan confundirse con las clases definidas. Presenta un comportamiento de clasificación similar, el Suelo es el grupo con menor cantidad de píxeles a analizar, el **85%** de otra vegetación se clasificó correctamente, el aumento respecto al caso anterior se puede atribuir a la no existencia de cultivos diferentes y, presenta confusión con la clase 2.

Tabla 2. Matriz de confusión, La Aurora. Fte. Propia

Nombre	Caña	Suelo	OtraVegetación	NoClasificado	Totales
Caña	28740958	241963	678157	0	29661078
Suelo	0	9667350	2889509	0	12556859
OtraVegetación	184181	146511	19174703	0	19505395
NoClasificado	0	0	0	26907078	26907078
Totales	28925139	10055824	22742369	26907078	88630410

Exactitud	65%
Kappa	57%

La combinación de los algoritmos supervisados se observa en la Figura 9 para ambos casos de estudio, la leyenda de color advierte la relación de confusión entre clases.

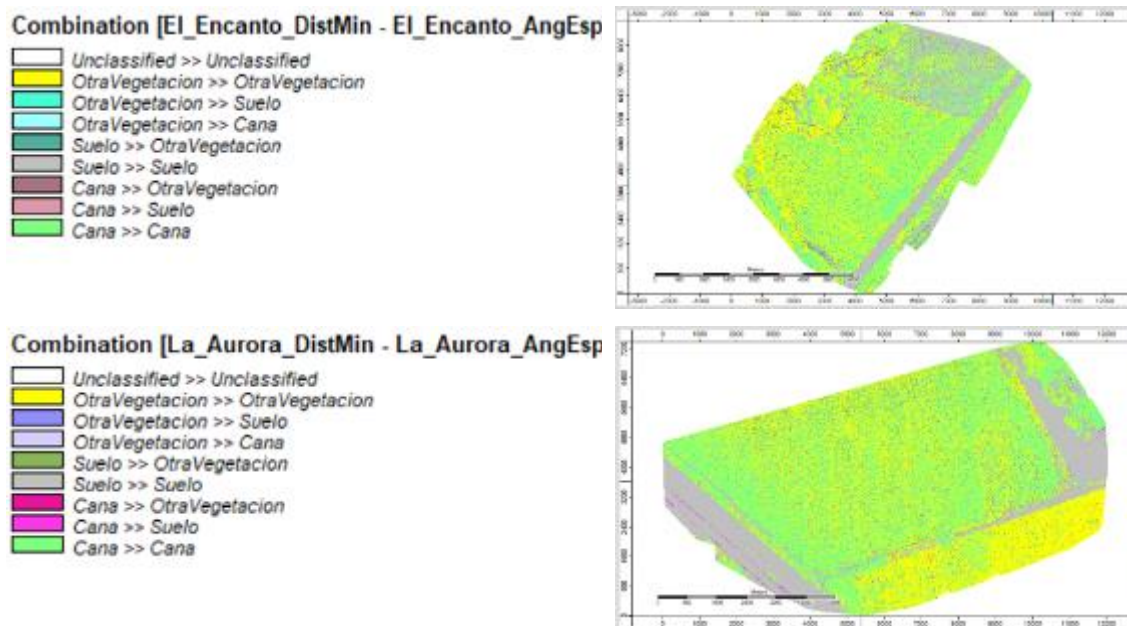


Figura 9. Combinación de algoritmos clasificación supervisada Fte. Propia

CONCLUSIONES

En base a los resultados anteriores, se determina que los algoritmos de Distancia Mínima y Ángulo Espectral son eficientes, porque etiquetan correctamente los grupos de píxeles en las clases adecuadas, sin embargo, los índices de exactitud global no se consideran óptimos. Se recomienda que para mejorar la clasificación se integren un número mayor de clases durante el entrenamiento, en la Figura 9 se muestra la confusión entre clases, es decir, se identifican aquellas que requieren diversificarse, de esta manera se consideran otros elementos dentro del ortomosaico con información espectral que evite la confusión.

Trabajos Futuros

- Estudiar otros algoritmos de clasificación supervisada como el de Máxima Probabilidad para tener un elemento más en la evaluación de exactitud.
- La información de las bandas RGB es limitada, con el equipo adecuado es posible recuperar datos del espectro infrarrojo ocupado en una gran variedad de aplicaciones en el monitoreo de cultivos mediante el Índice de Vegetación de Diferencia Normalizada (NDVI).
- Adicionalmente a la información espectral es posible incorporar datos espaciales para análisis de textura
- El número de *clusters* en la clasificación no supervisada es posible calcularlo por medio del método de codo para *kmeans*.

BIBLIOGRAFÍA

- Abdullahi, H. S., Sheriff, R. E., & Mahieddine, F. (2017). Convolution neural network in precision agriculture for plant image recognition and classification. *Seventh International Conference on Innovative Computing Technology (Intech)* (págs. 1-3). Londres: IEEE.
- Aguilar Rivera, N. (2015). Percepción remota como herramienta de competitividad de la agricultura. *Revista Mexicana de Ciencias Agrícolas*, 399-405.
- Aguilar, N., Galindo, G., Fortanelli, J., & Contreras, C. (2010). Índice normalizado de vegetación en caña de azúcar en la Huasteca Potosina. *Avances en investigación agropecuaria*, 14(2), 49-65.
- Cambronero, C. G. (2006). Algoritmos de aprendizaje: knn & kmeans. *Inteligencia en Redes de Comunicación* (pág. 23). Madrid: Universidad Carlos III de Madrid.
- Constante, P., Gordon, A., Chang, O., Pruna, E., Acuna, F., & Escobar, I. (2016). Artificial Vision Techniques to Optimize Strawberry's Industrial Classification. *IEEE Latin America Transactions*, 14(6), 2576-2581.
- Dallos Bustos, C. D. (2017). *Modelo Para Clasificación de Imágenes Multiespectrales a Partir de los Complejos de Células Abstractas (CCA)*. Bogotá: Universidad Distrital Francisco José de Caldas.
- González, A., Amarillo, G., Amarillo, M., & Sarmiento, F. (2015). Drones Aplicados a la Agricultura de Precisión. *Revista Especializada en Ingeniería*, 23-37.
- Long, W., & Srihann, S. (septiembre de 2004). Land cover classification of SSC image: unsupervised and supervised classification using ERDAS Imagine. *In IGARSS 2004. 2004 IEEE International Geoscience and Remote Sensing Symposium*, 4, págs. 2707-2712.
- Mate, P. G., Singh, K. R., & Khobragade, A. (2016). Feature extraction algorithm for estimation of agriculture acreage from remote sensing images. *World Conference on*

Futuristic Trends in Research and Innovation for Social Welfare (Startup Conclave) (págs. 1-5). IEEE.

- Sabzi, S., Abbaspour-Gilandeh, Y., & Javadikia, H. (2017). Machine vision system for the automatic segmentation of plants under different lighting conditions. *Biosystems Engineering*, 161, 157-173.
- Santamaria, M., & Aldalur, B. (2014). Enfoque estadístico de análisis de textura: su aplicación a la clasificación de un ortofotomosaico del valle de inundación del arroyo Naposta Grande. *GeoFocus*, 55-67.
- Tapia Arenas, A., Guevara Bonilla, M., & Esquivel Segura, E. (2019). *Procesamiento de imágenes a partir de vehículos aéreos no tripulados utilizando software libre*. Costa Rica: Tecnológico de Costa Rica.
- Tripicchio, P., Satler, M., Dabisias, G., Ruffaldi, E., & Avizzano, C. A. (2015). Towards smart farming and sustainable agriculture with drones. In *2015 International Conference on Intelligent Environments* (págs. 140-143). IEEE.
- Willington, E., Nolasco, M., & Bocco, M. (2013). Clasificación supervisada de suelos de uso agrícola en la zona central de Córdoba (Argentina): comparación de distintos algoritmos sobre imágenes Landsat. *Congreso Argentino de AgroInformática* (págs. 207-216). Argentina: JAIIO - CAI.