

UCLV
Universidad Central
"Marta Abreu" de Las Villas



FIE
Facultad de
Ingeniería Eléctrica

Departamento de Automática y Sistemas Computacionales

TRABAJO DE DIPLOMA

Título del trabajo: Propuesta de un clasificador para la identificación de parcelas del cultivo de caña mediante imágenes aéreas.

Autores del trabajo: Adrian Hernández Bernal

Tutores del trabajo: Ing. Joisel Martínez Gómez

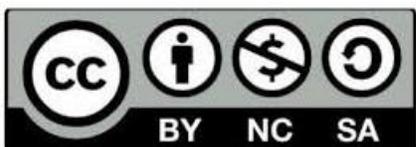
Ing. Patricia Rodríguez Ribalta

Santa Clara, julio, 2018
Copyright©UCLV

Este documento es Propiedad Patrimonial de la Universidad Central “Marta Abreu” de Las Villas, y se encuentra depositado en los fondos de la Biblioteca Universitaria “Chiqui Gómez Lubian” subordinada a la Dirección de Información Científico Técnica de la mencionada casa de altos estudios.

Se autoriza su utilización bajo la licencia siguiente:

Atribución- No Comercial- Compartir Igual



Para cualquier información contacte con:

Dirección de Información Científico Técnica. Universidad Central “Marta Abreu” de Las Villas. Carretera a Camajuaní. Km 5½. Santa Clara. Villa Clara. Cuba. CP. 54 830

Teléfonos.: +53 01 42281503-1419

PENSAMIENTO

*El éxito debe medirse no por la posición a que una persona ha llegado, sino por su
esfuerzo por triunfar.
Booker T. Washington*

DEDICATORIA

A mi mamá y a mi papá

Que son el motivo de que yo esté en este momento aquí.

A mis dos hermanos

Que siempre me ayudaron

A mis abuelos

Que Dios no permitió que estuvieran en este momento físicamente.

A mi novia

Que siempre me apoyó en todo, y me dio fuerzas para seguir cuando pensaba que todo estaba perdido.

A mi familia en general

Que siempre me llevaron presente cada día de mis estudios.

A todos mis compañeros

Que siempre me ayudaron y compartieron cada día junto a mí.

AGRADECIMIENTOS

A mis padres

Por todo el apoyo que me han dado.

A mis queridos abuelos

Que siempre me apoyaron en estos años de carrera.

A mi novia

Que siempre ha estado presente en todos estos días.

A mis dos excelentes tutores Patricia y Joisel

Muchas gracias, creo que estoy en deuda con ustedes por todo el apoyo y ayuda que me han dado en la realización de este trabajo.

Al Dr. Rubén Orozco Morales

Por toda su ayuda en la realización de este trabajo de diploma.

A mis amigos

Los que ya se graduaron y los que están hoy disfrutando de este triunfo.

RESUMEN

En la actualidad muchos de los campos de caña en Cuba carecen de procesos automáticos para la evaluación de su rendimiento, donde muchas de las tareas se realizan manualmente, generando grandes costos y largo tiempo de realización.

En este trabajo se realiza una propuesta de clasificación, mediante segmentación binaria, a imágenes aéreas tomadas por un VANT en un campo sembrado ubicado en el municipio de Ranchuelo, provincia Villa Clara. Para realizar la elección de la propuesta se implementaron seis algoritmos de segmentación y sus resultados fueron evaluados por especialistas mediante una inspección visual. La propuesta se realizó teniendo en cuenta el método de segmentación que mejor desempeño tuvo, frente a su costo computacional. Este estudio permite identificar la cantidad de parcelas presentes en el campo y valorar el rendimiento del terreno, siendo una importante aplicación para decisiones agronómicas que se tomen posteriormente sobre los campos de cultivo.

TABLA DE CONTENIDOS

PENSAMIENTO	i
DEDICATORIA.....	ii
AGRADECIMIENTOS.....	iii
RESUMEN	iv
INTRODUCCIÓN.....	1
CAPÍTULO 1. REVISIÓN BIBLIOGRÁFICA	5
1.1 Imagen digital	5
1.1.1 Imágenes aéreas.....	6
1.1.2 Clasificación de imágenes	6
Clasificación digital de imágenes	7
1.2 Algoritmos de segmentación	7
1.2.1 Algoritmo Otsu	8
1.2.2 Algoritmo <i>Fuzzy C-means</i> (FCM).....	9
1.2.3 Segmentación por textura	10
1.2.4 Algoritmo de Maximización de Expectativas (<i>EM</i> por sus siglas en inglés)	14
1.3 Conclusiones del capítulo.....	15
CAPÍTULO 2. MATERIALES Y MÉTODOS	16
2.1 Descripción del proceso.....	16

2.2	Adquisición de la imagen digital utilizada	16
2.2.1	Propiedades de la cámara.	17
2.3	Software y propiedades computacionales.....	17
2.4	Preprocesamiento de la imagen	19
2.5	Segmentación de la imagen.....	19
2.5.1	Segmentación mediante el método de Otsu	20
2.5.2	Segmentación mediante el método de <i>Fuzzy C-means</i> (FCM).....	20
2.5.3	Algoritmo mediante textura	20
2.6	Algoritmo de Maximización de Expectativas	21
2.7	Evaluación de la segmentación	21
2.8	Conclusiones del capítulo.....	21
CAPÍTULO 3 RESULTADOS Y DISCUSIÓN		22
3.1	Resultado de la segmentación mediante el algoritmo de Otsu	22
3.2	Resultado de la segmentación mediante el algoritmo <i>Fuzzy C-means</i> (FCM).	23
3.3	Resultados de la segmentación mediante los métodos de textura.	24
3.3.1	Algoritmo de la matriz de co-ocurrencia de gris (GLCM)	24
3.3.2	Algoritmo Local Binary Pattern (LBP)	25
3.3.3	Algoritmo Momento Estadístico (MS)	25
3.4	Algoritmo de Maximización de Expectativas (EM).....	26
3.5	Selección del algoritmo para la clasificación.	27
3.6	Conteo de parcelas.....	30
3.7	Análisis económico y medio ambiental.....	31
CONCLUSIONES Y RECOMENDACIONES		32
	Conclusiones.....	32

Recomendaciones	32
REFERENCIAS BIBLIOGRÁFICAS	33
ANEXOS	37

INTRODUCCIÓN

En el mundo moderno los métodos de clasificación se están desarrollando con gran velocidad, ya que su utilidad es muy favorable para el avance tecnológico. La clasificación de imágenes es un área transversal a otras áreas de la ciencia y tiene una fundamentación matemática y estadística. En la actualidad es aplicada a campos tan diversos como la Medicina, la Biología, la Bioinformática, la Robótica, la Meteorología, la Agricultura de Precisión, la seguridad en instalaciones, etc.

Hasta hace poco, la disponibilidad de imágenes de alta resolución era limitada debido a los altos costos de adquisición. Debido al desarrollo reciente en los Vehículos Aéreos No Tripulados (VANT) o UAV (*Unmanned Aerial Vehicle*), las imágenes con altas resoluciones espaciales y temporales están disponibles a bajo costo, lo que ha elevado las oportunidades, incluyendo otras aplicaciones, de comprender la variabilidad en el campo de las condiciones del cultivo y suelo, útiles para diversas decisiones agronómicas.

La clasificación de imágenes es tal vez una de las tareas de investigación dentro de los enfoques por computadora que más trabajo ha poseído en los últimos años, sin embargo, es claro que aún existen errores y dificultades sobre los cuales los científicos no han podido agredir directamente, es decir, aunque la investigación en el tema ha sido suficiente y se han logrado adelantos reveladores, el ideal de duplicar la capacidad del ojo y el cerebro humano está aún lejos de obtener.

En las últimas décadas se viene trabajando con técnicas computacionales para la clasificación automática de imágenes y se han logrado adelantos significativos. Para ello se realiza como tarea previa la segmentación de las imágenes. Existen algunas técnicas de segmentación binaria que resultan de gran utilidad en la clasificación como son la segmentación por el método de Otsu y mediante el algoritmo de *Fuzzy C-means* (FCM).

Los algoritmos de segmentación más usados y que han tenido un gran auge principalmente en las últimas dos décadas son los métodos de texturas, el algoritmo de Otsu y segmentación por superpíxeles, como consecuencia de sus teorías de aprendizaje estadístico. Estos métodos han sido aplicados con éxito a tareas de clasificación y reconocimiento de patrones.

En este trabajo se realizará un estudio previo sobre distintos clasificadores mediante la segmentación binaria para realizar la propuesta de uno de ellos según sus resultados. Estos resultados serán evaluados a partir de la correcta identificación que se realice de las parcelas de cultivo de caña mediante imágenes aéreas tomadas por un VANT en un campo sembrado en la provincia de Villa Clara. El estudio permitirá conocer la cantidad de parcelas que existen un campo de caña mediante imágenes aéreas.

Por tal razón surge como **problema científico**:

¿Cómo determinar las parcelas en un campo de caña a partir de imágenes aéreas para agricultura de precisión?

Objetivo general:

Proponer un clasificador por segmentación binaria capaz de identificar las parcelas de un campo de caña mediante imágenes aéreas para agricultura de precisión.

Objetivos Específicos:

1. Realizar un estudio sobre algunos métodos de clasificación por segmentación a través de una revisión bibliográfica.
2. Probar distintos clasificadores de acuerdo a su desempeño en estas imágenes.
3. Evaluar los clasificadores de acuerdo a su tiempo computacional y a la valoración de expertos.
4. Seleccionar un clasificador de acuerdo a sus resultados.

Interrogantes Científicas

A partir del problema planteado se pueden determinar las siguientes interrogantes científicas:

- ¿Cuál es la situación actual y las tendencias del empleo de las imágenes aéreas para la agricultura de precisión?

- ¿Cuáles clasificadores se pudieran probar para obtener elementos de interés en las imágenes aéreas?
- ¿Cómo podemos evaluar la efectividad de estos clasificadores?

Tareas de investigación

- Análisis de la búsqueda bibliográfica sobre la temática.
- Estudio sobre los distintos tipos de segmentación existentes.
- Revisión de los criterios de evaluación de clasificadores por segmentación binaria.
- Evaluación del clasificador por segmentación binaria seleccionado.

Posibles resultados

Con la realización de este trabajo se obtendrá un clasificador que nos permita identificar la cantidad de parcelas en un campo de caña mediante imágenes aéreas. Estos posibles resultados apoyarán el desarrollo de métodos para el manejo de nuevas formas de los cultivos, permitiendo optimizar el desarrollo de los sistemas productivos mediante la producción eficiente de caña en la agricultura, siendo un avance para la economía del país.

Estructura del Trabajo

El informe de la investigación se estructura en: Introducción, Capitulo, Conclusiones, Referencias Bibliográficas y Anexos.

Introducción

Se definirá importancia, necesidad y la actualidad del tema que se aborda y se dejarán explícitos los elementos del diseño teórico.

Capitulo

Capítulo I: En el primer capítulo, se revisará el estado del arte de la temática del trabajo y se realizará el análisis crítico de la literatura consultada. Además, se presentan las principales metodologías que constituyen el eje de esta investigación y se plantea la panorámica general existente en torno al problema que se aborda.

Capítulo II: En este capítulo se dará una descripción detallada de los clasificadores por segmentación binaria a utilizar para realizar la propuesta. También se desarrollará la

metodología del trabajo para la selección del clasificador usado para el análisis de las imágenes.

Capítulo III: En este capítulo se evaluarán los resultados obtenidos de la clasificación mediante su tiempo de ejecución y con la valoración de expertos.

Conclusiones: Se realizará una valoración para conocer si los objetivos iniciales fueron cumplidos en correspondencia con los resultados que se obtuvieron.

Recomendaciones.

Referencias bibliográficas.

Anexos.

CAPÍTULO 1. REVISIÓN BIBLIOGRÁFICA

En este capítulo se expone una revisión sobre los aspectos más importantes que se usarán en la realización del siguiente trabajo, se definirá que es la clasificación de imágenes digitales y la descripción de métodos de segmentación.

1.1 Imagen digital

Una imagen digital se define como una función de dos variables $f(x,y)$ donde x y y son coordenadas espaciales y el valor de f en un punto dado es la intensidad de la imagen en dicho punto (Gonzalez and Woods 2012).

En la actualidad todas las informaciones están pasando por un proceso de digitalización. Las imágenes también sufren este proceso. Se conoce que el cine, la televisión, el diseño gráfico e, incluso, los diseños industriales producen miles de imágenes digitales que luego son almacenadas en algún soporte físico donde posteriormente son enviadas por transmisión electrónico, visualizadas por algún medio o impresas en papel.

Cuando se emplea imágenes digitales tenemos que tomar algunas decisiones para lograr el compromiso entre la calidad y el tamaño de la imagen, donde para lograr esto debemos tener bien claro los conceptos básicos.

Dentro de estas imágenes tenemos diferentes tipos como son las imágenes vectoriales y las imágenes *bitmap*, donde según el uso que se le dará, será su selección. Estas imágenes poseen cada una diferentes características que la distinguen una de otra, y así se pueden seleccionar para un uso en específico.

1.1.1 Imágenes aéreas

Las imágenes aéreas son un estudio de la superficie terrestre mediante el empleo de cámaras fotográficas situadas en diversos vehículos aéreos. Están enfocadas a aplicaciones en el campo de la indagación arqueológica, geológica o topográfica, igualmente en agricultura para obtener información sobre la naturaleza de los terrenos y la ramificación de los cultivos. Además se emplean en el sector militar para recibir información sobre objetivos estratégicos. La reproducción de estas imágenes aéreas se manifiesta en medios digitales a una resolución de 18 micras, en los formatos *.tif* y *.jpg* (Ibañez Asensio, Gisbert Blanquer et al. 2010).

1.1.2 Clasificación de imágenes

La clasificación de un objeto consiste en asignarlo a una de las clases disponibles. Estos objetos se pueden definir por diferentes características, como es su textura, color y tamaño. Expresado más rigurosamente, el objetivo de la clasificación, dado un conjunto de objetos presentes en la imagen, cada uno de los cuales viene descrito por un conjunto de variables, es determinar en cada uno de ellos a la clase con la que mejor se asemeja. Al final, la imagen ha quedado dividida en áreas que están etiquetadas, o simplemente segmentada en regiones, por lo cual a este proceso también se le llama segmentación de la imagen.

Cuando realizamos la clasificación debemos tener definida las fronteras entre las distintas clases. Regularmente se calculan estas mediante un proceso de entrenamiento en el que se utilizan las características de una cadena de prototipos.

A la hora de clasificar un objeto desconocido tenemos que asignarlo a la clase en la cual las características empleadas mediante el entrenamiento tienen más comunicación con las tipologías del objeto. Cuando los objetos tienen similitudes se suele utilizar otros métodos de clasificación. Si estas similitudes son muy pequeñas se utilizan otros métodos como es el emparejamiento por plantilla (Chuvieco 1991).

Un clasificador se emplea persiguiendo los siguientes objetivos:

- Segmentación de imágenes (por color, textura, etc.)
- Reconocimiento de objetos.
- Control de calidad.
- Detección de novedad.

- Reconocimiento óptico de caracteres.

Clasificación digital de imágenes

La clasificación digital de imágenes se define como el proceso de producir mapas temáticos, teniendo como objetivo la adquisición de una nueva imagen, donde cada uno de los píxeles que son definidos sirvan como identificador de la clase donde se haya incluido (Chuvieco 1991). Los píxeles se organizan en un número determinado de clases o categorías de datos, fundado en los valores de un conjunto de variables o de píxeles. Si el valor cumple un conjunto de condiciones se determina a una clase que responde a esas condiciones.

La clasificación está relacionada con la obtención de un mapa temático a partir de la conversión de los tonos continuos de la imagen mediante un proceso que categoriza los píxeles en tipos de coberturas o temas (L Gil, Garcia et al. 2003). Los datos multiespectrales se manejan para ejecutar la clasificación y el patrón espectral presente dentro de los datos de cada píxel se utiliza como la base numérica para la categorización (Lillesand, Kiefer et al. 2014).

1.2 Algoritmos de segmentación

Cuando segmentamos una imagen lo que hacemos es subdividir la imagen en regiones o partes que la conforman. Esta termina cuando el objetivo de interés sea separado. Este proceso nos facilita identificar y extraer las diferentes características de un objeto en la imagen procesada (Leehan, Bañuelos et al. 2000, Gonzalez and Woods 2012).

En (Gonzalez and Woods 2012) y (Leehan, Bañuelos et al. 2000) se muestran varios métodos de segmentación, donde los métodos más clásicos se pueden clasificar como:

- Métodos heurísticos: Se asientan en el conocimiento previo de la imagen a segmentar y en la práctica del observador, en muchas ocasiones incluyen métodos supervisados.
- Métodos de detección de discontinuidades: Segmentan la imagen a partir de grandes cambios en los niveles de grises.
- Métodos basados en la propiedad de similitud de los valores de los niveles de grises: Se agrupan los puntos a partir de ciertos criterios de similitud u homogeneidad.
- Métodos basados en el umbralado del histograma: Estos logran un umbral de comparación para el asociamiento de los píxeles.

La segmentación se ha creado con el objetivo de segmentar imágenes, y resultando que no exista un método de segmentación que pueda solucionar todos los problemas que se nos muestran, se combinan varias técnicas para lograr resultados satisfactorios, ya sea desde el punto cualitativo como cuantitativo (Gonzalez and Woods 2012).

1.2.1 Algoritmo Otsu

El método de Otsu es un método de segmentación que utiliza un valor global de umbralización que depende solo del valor gris de la imagen. Fue propuesto por el erudito Otsu en 1979 y es ampliamente utilizado porque es simple y eficaz.

En este método se plantea una forma de minimizar la suma contenida en las variaciones dentro de las clases estructura y fondo, y así lograr establecer un umbral óptimo. Para esto se supone que el nivel de gris de un histograma es normalizado dentro de una distribución de probabilidad (ver ecuación 1.1). Se produce un umbral k tal que C_0 es el conjunto de píxeles con intensidades $[1, 2, \dots, k]$, y C_1 el conjunto de píxeles con intensidades $[k+1, \dots, L]$.

$$P_i = \frac{n_i}{N} \quad 1.1$$

Donde:

N = es el número total de píxeles de la imagen.

n_i = es el número de píxeles que tiene una intensidad.

L = número total de intensidades distintas en la imagen.

Para un mejor entendimiento de lo que hace este método se usa un valor óptimo que logra minimizar las varianzas entre las clases σ_B^2 definida en la ecuación 1.2 (Otsu 1979).

$$\sigma_B^2 = w_0 w_1 (\mu_1 - \mu_0)^2 \quad 1.2$$

Donde:

w_0 y w_1 son las probabilidades de las intensidades C_0 y C_1 .

μ_0 y μ_1 son las medidas de esas probabilidades con respecto a P_i y a la intensidad i .

El método requiere calcular un histograma de nivel de gris antes de ejecutar. Sin embargo, debido a la unidimensional de solo tener en cuenta la información de nivel de gris, no brinda un mejor resultado de segmentación. Para ello Otsu propuso algoritmos que funcionan tanto para el umbral de nivel de gris de cada píxel como en su información de correlación espacial dentro del vecindario; obteniendo resultados satisfactorios cuando se aplica a imágenes ruidosas (Wenqing 1993).

En (Gong, Li et al. 1998), se propuso una técnica recursiva rápida que puede reducir de forma eficiente el tiempo de cálculo. Sin embargo, el método de Otsu utiliza una búsqueda exhaustiva para evaluar el criterio para maximizar la varianza entre clases. A medida que aumenta el número de clases de una imagen, el método de Otsu toma demasiado tiempo para ser práctico en la selección del umbral multinivel (Sahoo, Soltani et al. 1988).

Este algoritmo de segmentación es uno de los más usados en la actualidad, debido a que es un algoritmo que resulta ser muy eficiente. Se ha utilizado en diversos trabajos como el de segmentación de células contaminadas con malaria, donde se desea separar y reconocer cuáles son las células parasitadas, como es el caso del trabajo realizado por (Mendoza Ramos 2014).

También este método fue utilizado en (Hernandez-Juarez, Mejia-Rodriguez et al. 2017) para una evaluación y comparación cuantitativa con otros métodos de segmentación en imágenes médicas para evaluar la segmentación de tumores cerebrales.

1.2.2 Algoritmo *Fuzzy C-means* (FCM)

El algoritmo *Fuzzy C-means* (FCM) es una de las técnicas más conocidas de agrupación, desarrollado por Dunn (Chattopadhyay, Pratihar et al. 2006) y, luego Bezdek (Bezdek 1981) lo modificó en los años 1981. Es un algoritmo difuso e iterativo que forma parte de técnicas de agrupación no supervisado y consiste en encontrar grupos o patrones en un conjunto de datos, para que luego esta información sirva para la clasificación (Yen and Langari 1999).

Este algoritmo en particular, se puede emplear para conseguir una segmentación a través de la clasificación de píxeles difusos. A diferencia de los métodos de clasificación difíciles que obligan a los píxeles a pertenecer exclusivamente a una clase, FCM permite que los píxeles pertenezcan a múltiples clases con diversos grados de membresía. Este enfoque permite

flexibilidad adicional en muchas aplicaciones y recientemente se ha utilizado en el procesamiento de imágenes de resonancia magnética (RM). Sin embargo, no aborda la intensidad en el artefacto de homogeneidad que ocurre en casi todas las imágenes de RM (Chattopadhyay, Pratihari et al. 2006).

1.2.3 Segmentación por textura

La textura es la característica visual o táctil de la superficie de un objeto (Díaz 2013). Según (Huergo Suárez 2013), la textura son características físico-estructurales dadas a un objeto por el tamaño, forma, arreglo y proporciones de sus partes. Cuando analizamos las imágenes digitales, conocemos que la textura visual en estas imágenes se representa como la variación de los valores de las intensidades de los píxeles que crean ciertos patrones repetitivos.

Tres métodos de segmentación mediante textura se mencionan a continuación:

- Algoritmo de la matriz de co-ocurrencia de gris (por sus siglas en inglés *GLCM*).
- Algoritmo *Local Binary Pattern (LBP)*.
- Algoritmo Momento Estadísticos (por sus siglas en inglés *SM*.)

Estos métodos de textura se han empleado en múltiples trabajos, como es el caso de (Callejo 2015) para reconocer plantas verdes alineadas en forma de surcos o dispersas según el cultivo, malas hierbas y otros componentes añadidos. Este trabajo se centró en investigaciones para el análisis de las texturas en imágenes capturadas por sistemas de visión en campos de maíz, y se realizó desde el punto de vista: cromático y espacial.

Algoritmo de la matriz de co-ocurrencia de gris (GLCM)

La matriz de co-ocurrencia de nivel de gris (GLCM) (Haralick and Shanmugam 1973), es uno de los métodos de análisis de textura más conocidos, cuyo algoritmo estima las propiedades de la imagen relacionadas con las estadísticas de segundo orden. Cada entrada (i, j) en GLCM corresponde al número de apariciones del par de niveles de gris i y j que son una distancia desde la imagen original. Con el fin de estimar la similitud entre las diferentes matrices de co-ocurrencias de niveles grises, Haralick (Haralick and Shanmugam 1973) propuso 14 características estadísticas extraídas de ellas. Para reducir la complejidad computacional, solo se seleccionaron algunas de estas características. La descripción de 4 de las características más

relevantes que se usan ampliamente en la literatura (Gonzalez 2016)-(Haralick 1979) se dan en la Tabla 1.1.

Tabla 1.1 Características extraídas de la GLCM.

Energía	$\sum_i \sum_j P_d^2(i, j)$
Entropía	$-\sum_i \sum_j P_d(i, j) \log P_d(i, j)$
Contraste	$\sum_i \sum_j (i - j)^2 P_d(i, j)$

La energía, también llamada Segundo Momento Angular (Haralick and Shanmugam 1973) y Uniformidad en (Gonzalez 2016), es una medida de la uniformidad de textura de una imagen. La energía alcanza su valor más alto cuando la distribución del nivel de gris tiene una forma constante o periódica. Una imagen homogénea contiene muy pocas transiciones de tonos grises dominantes, y por lo tanto, la matriz para esta imagen tendrá menos entradas de mayor magnitud, lo que dará como resultado un gran valor para la característica de energía. Por el contrario, si la matriz contiene una gran cantidad de entradas pequeñas, la característica de energía tendrá un valor menor.

La entropía mide el desorden de una imagen y alcanza su mayor valor cuando todos los elementos en la matriz P son iguales (Gonzalez 2016). Cuando la imagen no es textualmente uniforme muchos elementos GLCM tienen valores muy pequeños, lo que implica que la entropía es muy grande. Por lo tanto, la entropía es inversamente proporcional a la energía de GLCM (Haralick and Shanmugam 1973).

Este algoritmo se ha aplicado en (Soh and Tsatsoulis 1999) para el mapeo de hielo marino con imágenes aéreas a 100 metros de altura. En este trabajo se evaluó cuantitativamente parámetros de texturas y representaciones para determinar qué valores de parámetros y representaciones son los mejores para mapear la textura del hielo marino. También se llevó a cabo experimentos sobre los niveles de cuantificación de la imagen.

Algoritmo Patrones Binarios Locales (por sus siglas en inglés LBP)

Los patrones binarios locales (LBP) son un tipo de descriptor visual utilizado para la clasificación en la visión por computadora. El LBP se describió por primera vez en 1994 y

desde entonces se ha descubierto que es una característica poderosa para la clasificación de texturas. Además, se ha determinado que cuando el LBP se combina con el histograma del descriptor de gradientes orientados (*HOG* por sus siglas en inglés), mejora considerablemente el rendimiento de detección en algunos conjuntos de datos (Wang, Han et al. 2009). Una comparación de varias mejoras del LBP original fue realizada en 2015 por (Silva 2015).

Se diseñó originalmente para la descripción de la textura. El operador asigna una etiqueta a cada píxel de una imagen mediante el umbral de la vecindad de 3×3 de cada píxel con el valor de píxel central y considerando el resultado como un número binario. Luego, el histograma de las etiquetas se puede usar como un descriptor de textura. Para poder tratar las texturas a diferentes escalas, el operador LBP se amplió para usar barridos de diferentes tamaños (Ojala, Pietikainen et al. 2002). La definición del vecindario local como un conjunto de puntos de muestreo espaciados uniformemente en un círculo centrado en el píxel que se va a etiquetar permite cualquier radio y número de puntos de muestreo. La interpolación bilineal se usa cuando un punto de muestreo no cae en el centro de un píxel.

Otra extensión del operador original es la definición de los llamados patrones uniformes (Ojala, Pietikainen et al. 2002). Un patrón binario local se denomina uniforme si el patrón binario contiene como máximo dos transiciones a bit de 0 a 1 o viceversa cuando el patrón de bits se considera circular. En el cálculo del histograma de LBP, se utilizan patrones uniformes para que el histograma tenga un contenedor separado para cada patrón uniforme y todos los patrones no uniformes se asignan a un solo contenedor.

Debido al gran poder discriminativo y a su bajo costo computacional se ha convertido en estos últimos tiempos en una de las soluciones más utilizadas en numerosas aplicaciones relacionadas con la textura. La característica más importante en este método de segmentación es que para las aplicaciones reales es muy robusto y ofrece ciertas variaciones en las intensidades del nivel de grises. Para calcular LBP sobre una imagen en escala de grises se utiliza la ecuación 1.3.

$$LBP_{P,R} = \sum_{p=0}^{P-1} S(g_p - g_c) 2^p, \quad s(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases} \quad 1.3$$

Donde P es el número de vecinos que se van a considerar, R es el tamaño del vecindario y, g_c y g_p son los valores de gris del píxel central y cada uno de los p píxeles del vecindario

respectivamente. En la figura 1.2 se muestra un ejemplo del cálculo del LBP de manera gráfica sobre un píxel cualquiera de una imagen para los parámetros $P=8$ y $R=1$.

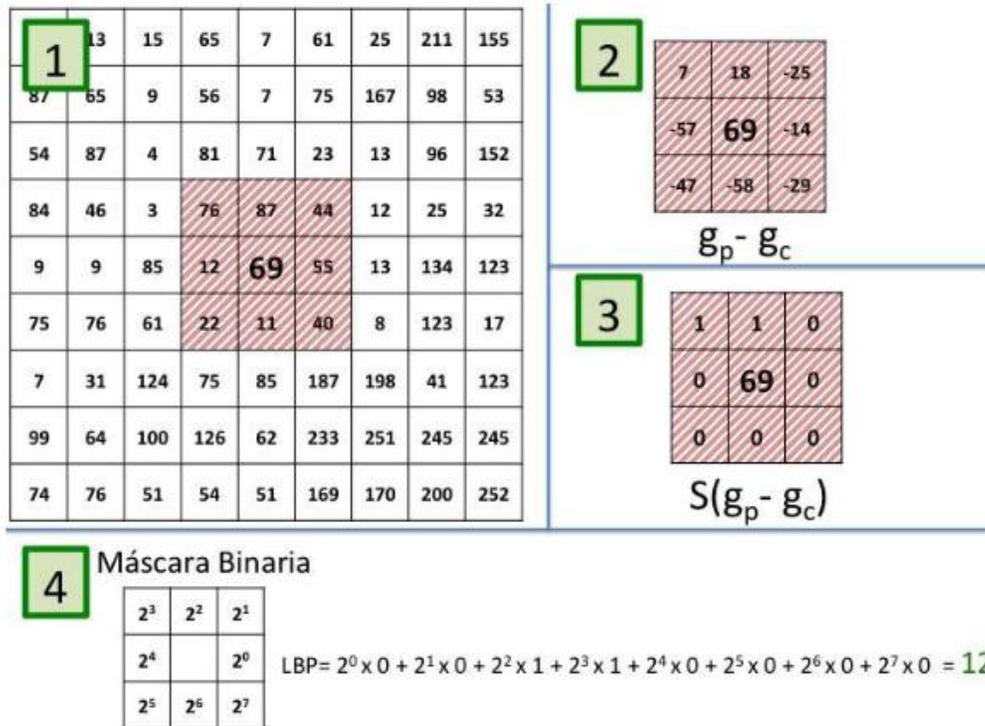


Fig. 1.1 Esquema de los pasos necesarios para obtener el valor de LBP de un píxel concreto.

Se han evaluado diferentes técnicas del método LBP para el reconocimiento de rostros demostrando, entre muchas cosas que, si se dividía el rostro en diferentes regiones para luego describirlas usando este método, aumentaba la efectividad de la precisión de los sistemas de clasificación frente a la descripción de rostro por completo (Yang and Chen 2013).

El trabajo de (Gu and Liu 2013) se centra en detectar los ojos de las personas para estimar la posición de la cara teniendo en cuenta que el ojo es una región de la imagen con una alta variabilidad con respecto a las zonas adyacentes del mismo (resto de la cara).

Momento estadístico (SM por sus siglas en inglés)

El vector de características se genera a través de los 4 primeros momentos centrales estadísticos debido a sus propiedades de rotación, cambio e invarianza de escala. El momento central de orden k , cm_k , de una distribución x se calcula mediante el valor esperado (ver ecuación 1.4) donde mu es la media de x .

$$cm_k = E(x - \mu)^k \quad 1.4$$

Donde:

k: orden del momento central

mu: media de x

El SM mide la aleatoriedad de una distribución, y el significado de los primeros 4 momentos centrales estadísticos es:

- Primer momento central: Valor medio.
- Segundo momento central: Varianza estadística.
- Tercer momento central: Asimetría, una medida de la simetría de la distribución.
- Cuarto momento central: Una medida de si la distribución es alta y delgada en comparación con una distribución normal de la misma varianza. Como es un cuarto poder, siempre es positivo. Un concepto relativo, curtosis, se define como el cuarto momento normalizado menos 3.

En (Palomino, Flores et al. 2010) se analizan los métodos estadísticos de primer y segundo orden. Los métodos de primer orden involucran píxeles simples, mostrando un histograma de los niveles de gris en una imagen, y se le pueden suponer como datos de media, varianza, suavidad, sesgo, curtosis, correlación, energía o entropía para reconocer una textura. Los estadígrafos de segundo orden poseen propiedades de pares de píxeles. Un ejemplo es el método de matrices de co-ocurrencia los cuales presentan características como, contraste, entropía, energía, correlación y homogeneidad.

1.2.4 Algoritmo de Maximización de Expectativas (EM por sus siglas en inglés)

Este algoritmo de maximización de expectativas (EM) utiliza una demostración para agrupar el color de la imagen en diferentes grupos. El agrupamiento de EM se caracteriza por su simplicidad relativa y tiempo de ejecución razonable. El algoritmo EM es un procedimiento iterativo eficiente para calcular la estimación de máxima verosimilitud (ML por sus siglas en inglés) en presencia de datos perdidos u ocultos. En la estimación de ML, deseamos estimar los parámetros del modelo para los cuales los datos observados son los más probables. Cada iteración del algoritmo EM consta de dos procesos: el E-step y el M-step. En la expectativa, o E-step, los datos faltantes se estiman dados los datos observados y la estimación actual de los parámetros del modelo. Esto se logra utilizando la expectativa condicional, explicando la

elección de la terminología. En el paso M-step, la función de verosimilitud se maximiza bajo el supuesto de que se conocen los datos faltantes. La estimación de los datos faltantes del paso E-step se usa en lugar de los datos faltantes reales (Dempster, Laird et al. 1977).

El algoritmo EM se ha convertido en una herramienta popular en problemas de estimación estadística que involucran datos incompletos, o en problemas que pueden plantearse en una forma similar, (McLachlan and Krishnan 2007). Es un método iterativo de optimización para estimar algunos parámetros desconocidos, dados los datos de medición.

El algoritmo EM también se ha utilizado en varios marcos de estimación de movimiento (Weiss 1998) y se han utilizado varios de ellos en métodos de restauración de supe-resolución de multi-rama que combinan la estimación de movimiento (Hardie, Barnard et al. 1997).

1.3 Conclusiones del capítulo

Estos nuevos proyectos que se están desarrollando en el mundo serán una poderosa herramienta para el desarrollo y el sostén de nuevas técnicas en la agricultura. Con lo planteado se procede a realizar una propuesta de un clasificador basado en segmentación binaria para la identificación de las parcelas en el cultivo de la caña de azúcar. Se dejan bien definidos los conceptos más importantes para la realización de este trabajo, sus características y ventajas de cada uno de ellos.

CAPÍTULO 2. MATERIALES Y MÉTODOS

En este capítulo se abordará sobre los métodos y materiales que se emplearon para la realización de este trabajo. Se describe detalladamente todos los pasos que se siguieron en cada epígrafe. Se define bien la descripción del proceso, la adquisición, preprocesamiento y clasificación de la imagen, el software y los requisitos computacionales.

2.1 Descripción del proceso

El proceso general para el análisis automatizado de la identificación de parcelas en imágenes aéreas para la agricultura de precisión consta de: adquisición de la imagen digital, preprocesamiento, segmentación de las regiones de interés (parcelas) y clasificación, esto se observa en la figura 2.1.

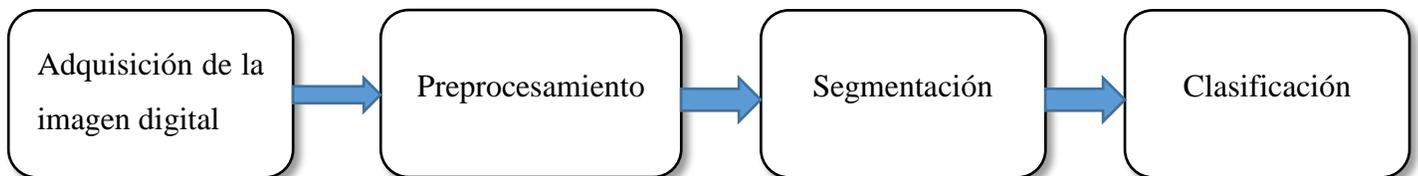


Fig. 2.1: Diagrama de bloques del proceso general para análisis automatizado de la identificación de las parcelas.

2.2 Adquisición de la imagen digital utilizada.

Las imágenes del presente trabajo fueron adquiridas mediante el vuelo de un VANT a 120 metros de altura en un campo de caña ubicado en el municipio de Ranchuelo, en la provincia de Villa Clara (Ver figura 2.2). Nuestro objetivo se enfocó en tratar de reconocer las parcelas de este campo de caña, lo cual se logró mediante los métodos de segmentación explicados en el capítulo I.



Fig. 2.2: Imagen original.

2.2.1 Propiedades de la cámara.

Las principales características de la cámara son:

- Cámara multispectral para la agricultura.
- Autocalibrada usando el sensor de irradiación.
- Cámara RGB de 16 mpx para exploración.
- Tasa alta de toma fotográfica (1 foto por segundo).
- Independiente del VANT.
- Protocolo estándar PTP para la comunicación con los VANTs.
- Alimentada por USB.

La imagen utilizada en este trabajo, tiene formato *.tif*, resolución de 11851x10218 píxeles y se encuentra en el espacio de color RGB.

2.3 Software y propiedades computacionales

El procesamiento de las imágenes se utilizó empleando el software Matlab versión 8.5.0.197613 (R2015a). Matlab es un lenguaje de alto nivel para la informática técnica. Integra computación, visualización y programación en un entorno fácil de usar donde los problemas y soluciones se expresan en notación matemática familiar. Los usos típicos incluyen:

- Matemáticas y computación.

- Desarrollo de algoritmos.
- Modelado, simulación y creación de prototipos.
- Análisis, exploración y visualización de datos.
- Gráficos científicos y de ingeniería.
- Desarrollo de aplicaciones, incluida la creación de interfaces gráficas de usuario.

Es un sistema interactivo cuyo elemento de datos básicos es una matriz que no requiere dimensionamiento. Esto le permite resolver muchos problemas técnicos de cómputo, especialmente aquellos con formulaciones matriciales y de vectores, en una fracción del tiempo que tomaría escribir un programa en un lenguaje escalar no interactivo como *C* o *Fortran*.

Mediante la ayuda de este software se realizó este trabajo, debido a que el mismo posee muchas de las funciones implementadas, con mayor apoyo en su *Toolbox* de Procesamiento Digital de Imágenes; siendo, *imread*, *im2double*, *im2bw* y *imwrite* las principales funciones empleadas.

Propiedades computacionales

En la realización de este trabajo se requerían ciertas propiedades computacionales debido al gran tamaño de la imagen, lo cual demandaba mucho tiempo de ejecución cuando se procesaba con el software Matlab. Las propiedades de la computadora que se empleó para el desarrollo de los algoritmos se muestran en la tabla 2.1:

Tabla 2.1 Propiedades computacionales.

Fabricante	Acer
Modelo	Lenovo ThinkCentre M8400t-N000
Procesador	Intel(R) Core(TM) i5-3470 @ 3.20 GHz
Cantidad de memoria del sistema	16,00 GB en RAM
Tipo de sistema	Sistema de 64 bit
Cantidad de procesadores	4

2.4 Preprocesamiento de la imagen

Inicialmente la imagen fue girada -15° y recortada, buscando su enfoque en las regiones que eran de interés. Esta nueva imagen posee una resolución de 6294×6397 píxeles, en formato *.tif* y se encuentra en el espacio de color RGB. Posteriormente se procedió a filtrarla mediante la función *medfil2* para eliminar el ruido aditivo y atenuar las altas frecuencias. Luego se homogenizó con la función *imopen* para lograr separar mejor las guardarrayas de las parcelas (ver figura 2.3). Una vez acondicionada la imagen se procede a la segmentación de la misma.



Fig. 2.3: Imagen acondicionada.

2.5 Segmentación de la imagen

La segmentación de esta imagen se realizó mediante los siguientes métodos:

- Algoritmo de *Fuzzy C-means* (FCM).
- Algoritmo Otsu.
- Algoritmo de Textura.
- Algoritmo de Minimización de Expectativas (EM).

2.5.1 Segmentación mediante el método de Otsu

Para la segmentación de esta imagen, se empleó el algoritmo de Otsu, utilizado para este tipo de imágenes en varios trabajos citados en la bibliografía (N. Abbas 2014),(Z. May 2013) y que fue descrito en el epígrafe 1.2.1. Este umbral se calculó mediante la función *graythresh* y luego con la función *im2bw* se binarizó la imagen. Una vez segmentada la imagen por este método se procedió, mediante la función *imcomplement*, a invertir los complementos de la imagen y luego con la función *imfill* se rellenaron las parcelas para lograr una mejor clasificación.

2.5.2 Segmentación mediante el método de *Fuzzy C-means* (FCM)

El otro método que se utilizó para la segmentación de esta imagen fue el método FCM, el cual nos brindó resultados muy similares al anterior método descrito. El umbral de este método fue calculado mediante la función *fcm* y luego con la función *im2bw* fue binarizada la imagen. Una vez segmentada la imagen, se ejecutó la misma metodología de post-procesamiento que con el método anterior.

2.5.3 Algoritmo mediante textura

Para el método de segmentación por textura se implementaron tres algoritmos.

Algoritmo de la matriz de co-ocurrencia de gris (GLCM)

Este algoritmo procesa cada sub-imagen usando la función *segmentationGLCM* (Kolian 2018) y devuelve un vector de características para cada píxel de la sub-imagen central. Este vector se genera a través del GLCM implementado la función en Matlab, *graycomatrix* la cual adquiere una matriz tridimensional. Los vectores de características de píxeles a lo largo de la dimensión de la matriz están agrupados por clústeres. El resultado final en este algoritmo es la agrupación de los píxeles en un esquema de segmentación (ver figura 2.4). Luego mediante la función *im2bw* del Matlab se binarizó la imagen.

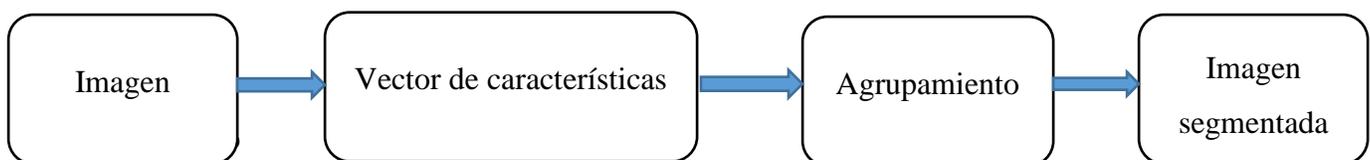


Fig. 2.4 Esquema de segmentación por GLCM.

Local Binary Pattern (LBP)

En este método se empleó una función específica llamada *segmentationLBP* (Kolian 2018) que etiqueta cada píxel de la imagen analizando su vecindario y compara el nivel de gris de cada uno de estos píxeles para ver su umbral. Posteriormente mediante la función *im2bw* del Matlab se binarizó la imagen.

Algoritmo por Momento Estadístico

La función *segmentationStatMoments* (Pitsios 2018) se utiliza para adquirir un vector de características para el píxel de la sub-imagen central. El vector de características se genera mediante un vector de características compuesto por los 4 primeros momentos centrales estadísticos. Como resultado, cada píxel se agrupa dando como resultado un esquema de segmentación (Ver figura 2.4). El esquema es simple y primitivo. Simplemente se implementa para explicar un esquema de segmentación básico y una plataforma para comparar varios espacios de funciones.

2.6 Algoritmo de Maximización de Expectativas

En este método se empleó la función *ExpectatMaxim* (Pitsios 2018) creada para agrupar el color de la imagen en diferentes grupos. Luego, mediante la función *im2bw* de Matlab se binarizó la imagen resultante de aplicar esta función. Este algoritmo se considera como uno de los más sencillos y posee un tiempo de ejecución bastante rápido.

2.7 Evaluación de la segmentación

Para la evaluación de los algoritmos de segmentación se realizó una valoración mediante tres expertos en Procesamiento Digital de Imágenes, los cuales emitieron una evaluación para cada uno de los resultados de las segmentaciones aplicadas a la imagen en estudio. Para ello, los mismos tuvieron las mismas condiciones de observación y una presentación aleatoria de los resultados. Con este criterio y el tiempo de ejecución de cada algoritmo se puede estimar el mejor clasificador para este estudio, teniendo en cuenta la aplicación de este trabajo.

2.8 Conclusiones del capítulo

En el presente capítulo se explican los medios empleados para el desarrollo de esta investigación y se describen los métodos aplicados a la imagen evaluada.

CAPÍTULO 3 RESULTADOS Y DISCUSIÓN

En el presente capítulo se realiza un análisis de los resultados al aplicar los algoritmos de segmentación propuestos: Otsu, *Fuzzy C-means*, matriz de co-ocurrencia de gris (GLCM), Local Binary Pattern (LBP), Momento Estadístico (MS), Minimización de Expectativas (EM). Se realiza una comparación entre los resultados obtenidos para diferentes capacidades computacionales en el entorno de ejecución y se comparan los resultados de los algoritmos donde se busca la mejor clasificación. Además, se propone la mejor segmentación para este tipo de imágenes aéreas.

3.1 Resultado de la segmentación mediante el algoritmo de Otsu

En la figura 3.1 se señala en rojo como el algoritmo no logra una buena segmentación, pues no se definen las parcelas que se encuentran en esta área. Este problema se debe al cambio de coloración del suelo en esta área por encontrarse húmedo.

En el área señalada con en amarillo se muestra una parcela que se no se encuentra al 100% y el método logra separar y segmentar de forma regular.

En el área señalada en color verde podemos apreciar una parcela bien segmentada, la cual se encuentra casi al 100%, lo que nos muestra una buena segmentación para esta área.

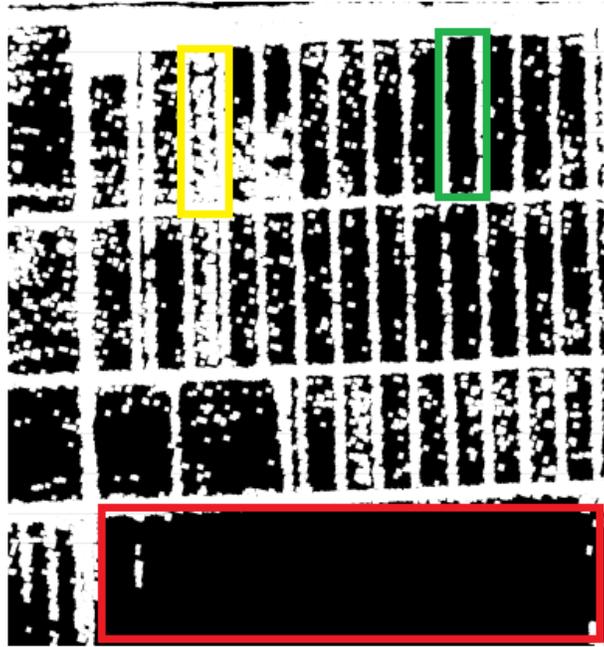


Fig 3.1 Segmentación mediante Otsu.

3.2 Resultado de la segmentación mediante el algoritmo *Fuzzy C-means* (FCM).

Este algoritmo realiza la segmentación muy similar al método anterior, con la diferencia de que este método cuenta con un tiempo mayor de ejecución.

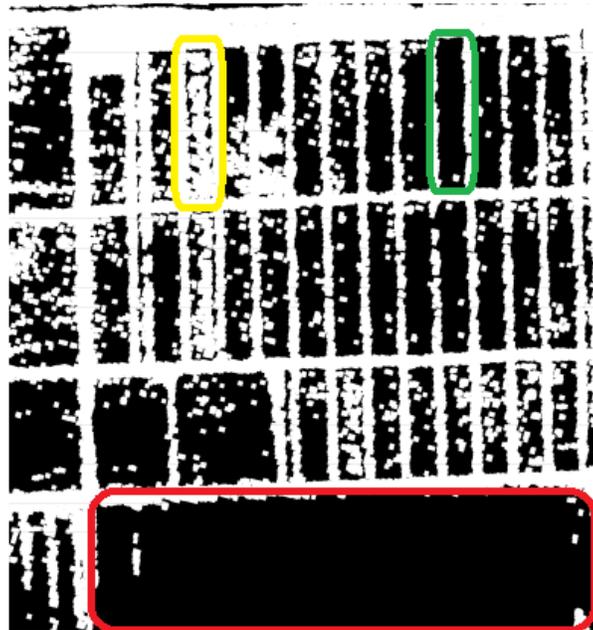


Fig. 3.2 Segmentación mediante *Fuzzy C-means*.

En la figura 3.2 se señala con el color rojo la parte inferior de la parcela, la cual mediante este método en esta área no se logró una correcta segmentación. En esta área se encuentra el suelo húmedo y este método cuando segmenta toma esta región con el mismo umbral de la plantación.

En el área señalada con color amarillo nos muestra una segmentación de una parcela la cual no se encuentra en el 100% y logra definir bastante bien las regiones de las parcelas.

En el área señalada con color verde mostramos un área segmentada casi 100%, siendo una de los mejores resultados de este método.

3.3 Resultados de la segmentación mediante los métodos de textura.

Los tres algoritmos empleados resultaron satisfactorios en algunos casos. Estos métodos contaban con la deficiencia de un alto costo computacional.

3.3.1 Algoritmo de la matriz de co-ocurrencia de gris (GLCM)

En la segmentación mediante la matriz de co-ocurrencia de gris por textura se observa que no se logró clasificar de una manera concreta las parcelas en la imagen. En la figura 3.3 se puede apreciar que apenas se logra diferenciar lo que es cultivo y lo que es terreno. Sin embargo, se nota una pequeña clasificación en la parte inferior donde, en los métodos anteriores era imposible diferenciar cambios entre suelo y plantación.

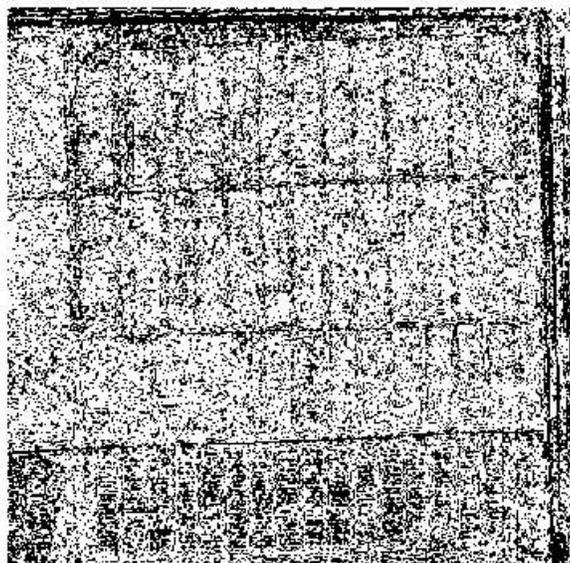


Fig. 3.3 Segmentación mediante GLCM.

3.3.2 Algoritmo Local Binary Pattern (LBP)

En este algoritmo se muestra que al igual que el método anteriormente descrito no se logra una buena segmentación, se definen muy poco las parcelas, y en las parcelas inferiores a penas se pueden definir las guardarrayas. Presentándose este método superior a los anteriores en el aspecto visual, pero siendo aún insuficiente para una buena clasificación de las parcelas.

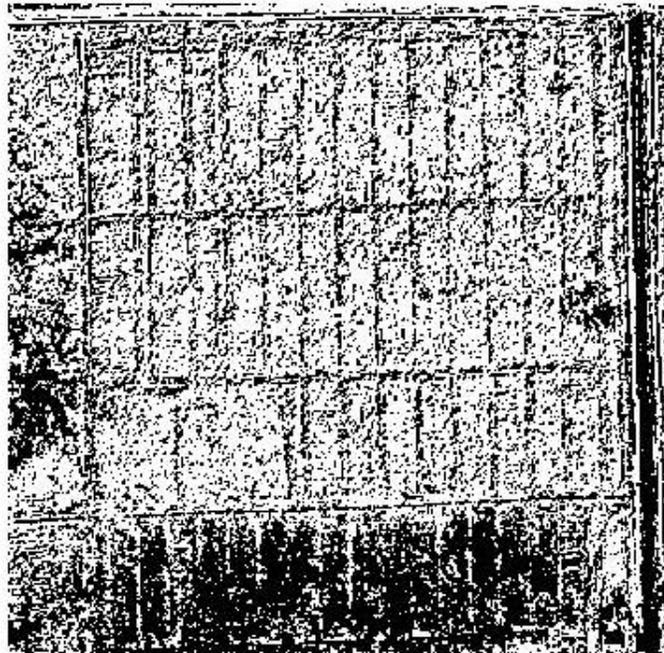


Fig. 3.4 Segmentación mediante LBP.

3.3.3 Algoritmo Momento Estadístico (MS)

El empleo de este método permite separar bien las parcelas del cultivo. Además se logran observar los perímetros de cada parcela e identificar las parcelas inferiores que, hasta este momento no se había logrado obtener con los otros métodos trabajados. En la figura 3.5 se muestran los resultados que se obtuvieron mediante este método de segmentación.



Fig. 3.5 Segmentación mediante SM.

Como se muestra en la figura se 3.5 se resalta en color amarillo una parcela la cual no fue segmentada correctamente, donde se puede observar que la guardarraya no está bien definida. También en color verde se resaltan las parcelas inferiores las cuales por los otros métodos de segmentación antes descritos no habían logrado una buena segmentación. Se logra en general una buena segmentación.

3.4 Algoritmo de Maximización de Expectativas (EM)

El resultado obtenido en este método nos asegura en mejor medida lo que es cultivo, lo cual podemos apreciar en la figura 3.6. Los puntos que nos quedan dentro de la imagen segmentada corresponden a plantas dentro de las parcelas, pero no es este el objetivo perseguido en esta investigación.

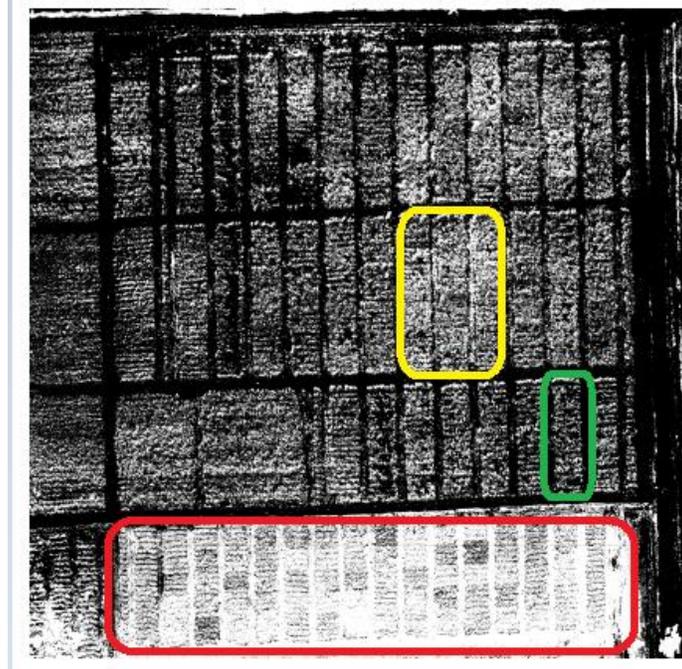


Fig. 3.6 Segmentación mediante EM.

En la figura 3.6 señalamos en color rojo la parte inferior de la imagen donde se muestra que no se define bien cada parcela de cultivo de caña en la imagen. Señalamos en amarillo un área donde no se logró definir bien las guardarrayas de las parcelas. El área señalada en verde representa una parcela la cual fue una de las mejores segmentadas. De forma general podemos decir que este método segmentó la imagen bastante bien.

3.5 Selección del algoritmo para la clasificación.

Para la selección del clasificador mediante segmentación nos basamos en dos aspectos esenciales: tiempo de ejecución y valoración de expertos. A continuación, se muestra, en la tabla 3.1, el tiempo promedio de ejecución de los algoritmos implementados en la imagen aérea.

El método de Otsu demanda el menor tiempo de ejecución, mientras que el mayor tiempo lo demanda el método de GLCM. Por su parte, el tiempo del método de Momento Estadístico (textura) es el otro método que mayor demanda hace de ejecución. Esto se debe a que los de mayor tiempo realizan procesamientos cíclicos mientras que los demás solo ejecutan una iteración.

Tabla 3.1 Tiempo promedio de ejecución de los algoritmos implementados.

Algoritmos de Segmentación	Algoritmo de Otsu	Algoritmo de <i>Fuzzy C-means</i>	Algoritmo (GLCM)	Algoritmo (LBP)	Algoritmo Momento Estadístico	Algoritmo Maximización Expectativas
Tiempo de ejecución	1 min	15 min	13 horas	40 min	3 horas	18 min

También para la selección de este algoritmo se tomó en cuenta el criterio que emitieron los expertos mediante una valoración visual del resultado de cada método. En la tabla 3.2 se muestran los resultados de cada valoración con un rango de 2 a 5 puntos para cada algoritmo. Además, se muestra el valor promedio de cada uno de estos métodos.

Tabla 3.2 Evaluación perceptual.

Observadores	Otsu	<i>Fuzzy C-means</i>	GLCM	LBP	Momento Estadístico	Maximización de expectativas
1	5	4	3	4	5	5
2	3	3	2	3	4	4
3	3	4	2	3	5	5
Promedio	3.67	3.67	2.34	3.34	4.67	4.67

Podemos observar que los expertos evalúan con mejor puntuación los algoritmos de Momento Estadístico y Maximización de Expectativas con un promedio de 4.67 puntos y como el peor caso el algoritmo de GLCM con un promedio total de 2.34 puntos.

A continuación, se presentan dos gráficas donde podemos observar una representación de los algoritmos contra el tiempo de ejecución y contra los resultados de los expertos.

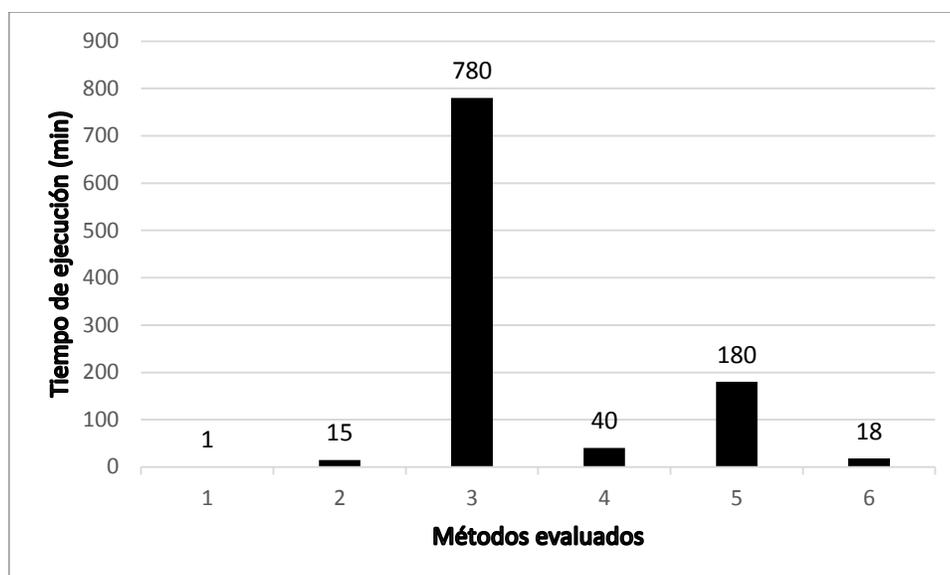


Fig. 3.7 Representación de los tiempos de ejecución de cada algoritmo (1-Otsu, 2-Fuzzy C-means, 3-GLCM, 4-LBP, 5-Momento estadístico, 6-Maximización de expectativas).

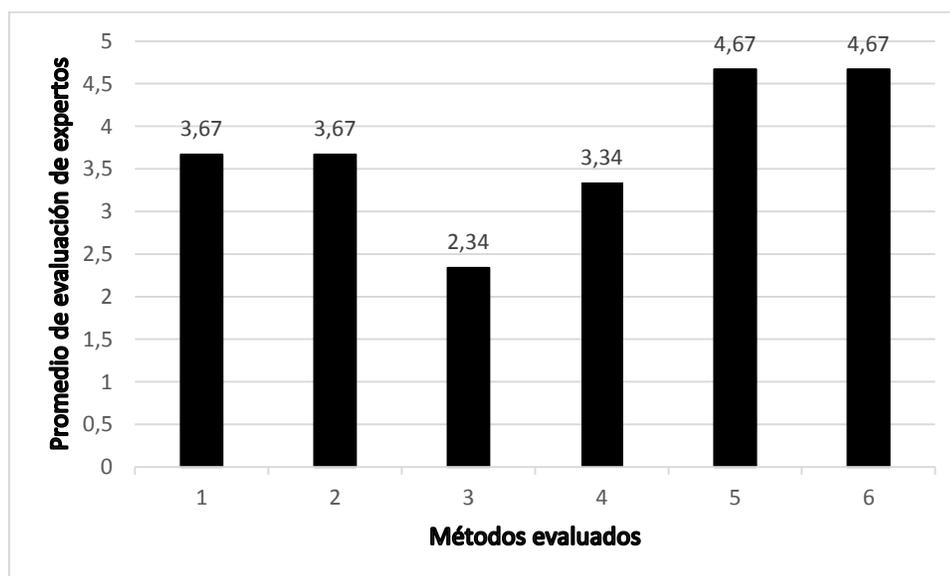


Fig. 3.8 Representación gráfica de las evaluaciones de los expertos (1-Otsu, 2-Fuzzy C-means, 3-GLCM, 4-LBP, 5-Momento estadístico, 6-Maximización de expectativas).

Con este análisis realizado y enfocándonos en la aplicación que tiene este trabajo se concluyó que el algoritmo con mejor resultado para la clasificación de parcelas en un campo de caña es el algoritmo de Momento Estadístico mediante textura. El otro algoritmo, Maximización de Expectativas, resultó tener resultados similares al seleccionado, pero por cuestión de la

aplicación a realizar se seleccionó el de Momento Estadístico, aunque se conoce que este cuenta con mayor carga computacional, pero cuando se quiere aplicar en el conteo las parcelas este método las define mejor, mientras que el otro se podría usar para definir mejor el cultivo.

3.6 Conteo de parcelas

Como una aplicación de este trabajo se realizó el conteo de parcelas según el método propuesto. Logramos contar las parcelas del campo de caña resultando tener 56 parcelas. En la figura 3.9 se muestra con puntos azules cada parcela encontrada por esta aplicación.

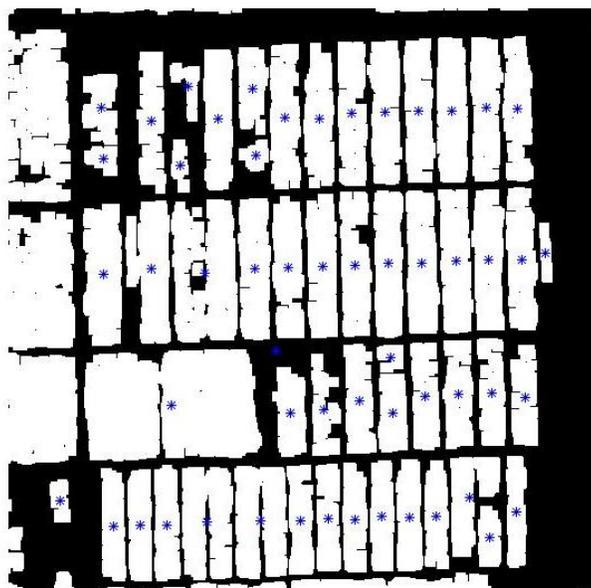


Fig. 3.9 Conteo de parcelas.

Se muestra que la aplicación no tiene un 100% de efectividad debido a que en algunas parcelas existe sub-clasificación y otras con sobre-clasificación. En la figura 3.10 se muestra con el color rojo parcelas que presentaron sobre-clasificación (señala dos parcelas cuando debería ser una sola) y con el color verde parcelas con sub-clasificación (señala una cuando debería señalar dos).

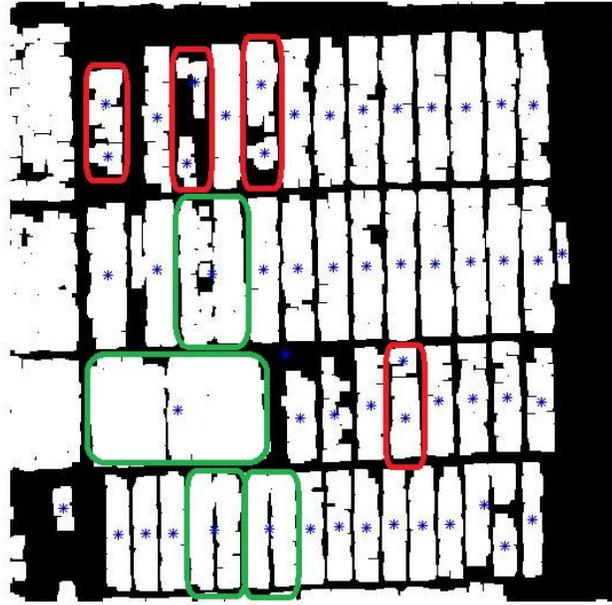


Fig. 3.11 Señalamientos de sub-clasificación (verde) y sobre clasificación (rojo).

3.7 Análisis económico y medio ambiental

El uso de estos algoritmos de segmentación en la clasificación de objetos de interés en imágenes aéreas resulta un ahorro significativo en tareas que en la actualidad se realizan de forma manual. Además, podemos inferir que al tener un conteo físico de las parcelas de caña de azúcar se puede estimar un rendimiento del campo según lo sembrado, dando una idea del estimado de producción del cultivo y, a su vez, un estimado total de las ganancias.

En el ámbito medio ambiental, es mucho más claro, ya que mediante estas segmentaciones se pueden clasificar las imágenes aéreas. Se logra de forma automática, rápida y precisa conocer afectaciones que pueden tener algunas de estas parcelas, como pudieran ser plagas, terrenos en malas condiciones, mucha humedad o sequía. Se podrían tomar medidas inmediatas de tipo local, sin afectar al medio con una sobrecarga de pesticidas o químicos empleados para el tratamiento de las afecciones mencionadas y además se le ahorra al país en la compra indebida de productos.

CONCLUSIONES Y RECOMENDACIONES

Conclusiones

1. Se probaron distintos clasificadores por segmentación, según resultados obtenidos por otros investigadores, los cuales en la mayoría de los casos develaron resultados aceptables.
2. Se realizaron dos evaluaciones, una subjetiva y una objetiva, atendiendo a la evaluación visual por expertos y tiempo de ejecución, respectivamente.
3. A pesar de no ser el algoritmo de mejor desempeño computacional, debido a que no es el más rápido en ejecución, se seleccionó el algoritmo de Momento Estadístico como el mejor en cuanto a segmentación y debido a la aplicación que se propone, la cual consiste en hacer un conteo de las parcelas de la imagen.

Recomendaciones

Recomendamos, en primer lugar, seguir investigando en otros métodos de segmentación y clasificación capaces de generar resultados que eliminen problemas de sub-clasificación y sobre clasificación que se presentan en esta investigación. También, proponemos extender las aplicaciones que se pueden llevar a cabo con esta clasificación, como puede ser el caso de calcular el área de las parcelas con el fin de estimar el rendimiento total del campo.

REFERENCIAS BIBLIOGRÁFICAS

Bezdek, J. C. (1981). Objective Function Clustering. Pattern recognition with fuzzy objective function algorithms, Springer: 43-93.

Callejo, M. I. R. (2015). Segmentación automática de texturas en imágenes agrícolas, Universidad Complutense de Madrid.

Chattopadhyay, S., et al. (2006). "Performance studies of some similarity-based fuzzy clustering algorithms." International Journal of Performability Engineering 2(2): 191-200.

Chuvienco, E. (1991). "Fundamentos de Teledetección espacial." Estudios Geográficos 52(203): 371.

Dempster, A. P., et al. (1977). "Maximum likelihood from incomplete data via the EM algorithm." Journal of the royal statistical society. Series B (methodological): 1-38.

Díaz, R. (2013). Mezcla de regiones en imágenes sobresegmentadas usando rasgos de textura. in Facultad de Ingeniería Eléctrica, Universidad Central "Marta Abreu" de Las Villas

Gong, J., et al. (1998). "Fast recursive algorithms for two-dimensional thresholding." Pattern recognition 31(3): 295-300.

Gonzalez, R. C. (2016). Digital image processing, Prentice hall.

Gonzalez, R. C. and R. E. Woods (2012). Digital image processing, Upper Saddle River, NJ: Prentice Hall.

Gu, J. and C. Liu (2013). "Feature local binary patterns with application to eye detection." Neurocomputing 113: 138-152.

Haralick, R. M. (1979). "Statistical and structural approaches to texture." Proceedings of the IEEE **67**(5): 786-804.

Haralick, R. M. and K. Shanmugam (1973). "Textural features for image classification." IEEE Transactions on systems, man, and cybernetics(6): 610-621.

Hardie, R. C., et al. (1997). "Joint MAP registration and high-resolution image estimation using a sequence of undersampled images." IEEE transactions on Image Processing **6**(12): 1621-1633.

Hernandez-Juarez, S., et al. (2017). Evaluación cuantitativa del desempeño de métodos de segmentación aplicados a imágenes médicas para el análisis de estructuras anatómicas de interés. Memorias del Congreso Nacional de Ingeniería Biomédica.

Huergo Suárez, S. B. (2013). Desarrollo de herramientas de cálculo de rasgos para la clasificación de imágenes en microscopía celular. Facultad de Ingeniería Eléctrica, Universidad Central "Marta Abreu" de Las Villas.

Ibañez Asensio, S., et al. (2010). "Características de las fotografías aéreas. Conceptos básicos."

Kolian (2018). "GitHub." Retrieved abril, 2018, from <https://github.com/kolian1/texture-segmentation-LBP-vs-GLCM>.

L Gil, J., et al. (2003). Enfoques para la clasificación digital de imágenes mono y multispectrales y su implementación en el software cubano TN Estudio V2. 0.

Leehan, J. A., et al. (2000). "Procesamiento de imágenes biomédicas." Universidad Autónoma Metropolitana de México, Unidad Iztapalapa, México DF.

Lillesand, T., et al. (2014). Remote sensing and image interpretation, John Wiley & Sons.

McLachlan, G. and T. Krishnan (2007). The EM algorithm and extensions, John Wiley & Sons.

Mendoza Ramos, V. (2014). Implementación y aplicación de funciones de granulometría morfológica para la clasificación de imágenes de microscopía celular, Universidad Central "Marta Abreu" de Las Villas.

N. Abbas, D. M., and A. H. Abdullah (2014). "Semi-Automatic Clustered Red Blood Cells Splitting and Counting in Thin Blood Smear Images."

Ojala, T., et al. (2002). "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns." IEEE Transactions on pattern analysis and machine intelligence **24**(7): 971-987.

Otsu, N. (1979). "A threshold selection method from gray-level histograms." IEEE Transactions on systems, man, and cybernetics **9**(1): 62-66.

Palomino, N. L. S., et al. (2010). "Procesamiento Digital de textura: Técnicas utilizadas en aplicaciones actuales de CBIR." Revista de investigación de Sistemas e Informática **7**(1): 57-64.

Pitsios (2018). "GitHub." Retrieved marzo, 2018, from <https://github.com/pitsios-s/ImageSegmentation>.

Sahoo, P. K., et al. (1988). "A survey of thresholding techniques." Computer vision, graphics, and image processing **41**(2): 233-260.

Silva, F. D. L. (2015). Recognition of facial expressions and their temporal segments using LBP-TOP descriptors in Random Forests.

Soh, L.-K. and C. Tsatsoulis (1999). "Texture analysis of SAR sea ice imagery using gray level co-occurrence matrices." IEEE Transactions on geoscience and remote sensing **37**(2): 780-795.

Wang, X., et al. (2009). An HOG-LBP human detector with partial occlusion handling. Computer Vision, 2009 IEEE 12th International Conference on, IEEE.

Weiss, Y. (1998). Bayesian motion estimation and segmentation, Massachusetts Institute of Technology.

Wenqing, L. J. L. (1993). "The Automatic thresholding of gray-level pictures via two-dimensional otsu method [J]." Acta Automatica Sinica **1**: 015.

Yang, B. and S. Chen (2013). "A comparative study on local binary pattern (LBP) based face recognition: LBP histogram versus LBP image." Neurocomputing **120**: 365-379.

Yen, J. and R. Langari (1999). Fuzzy logic: intelligence, control, and information, Prentice Hall Upper Saddle River, NJ.

Z. May, S. A. M. A., and R. Salamat (2013). "Automated quantification and classification of malaria parasites in thin blood smears,." 369-373.

ANEXOS

Códigos utilizados para el acondicionamiento de la imagen.

```
I=imread ('Etical20metros.tif'); %cargar la imagen
I1=I(:,:,1);
I2=I(:,:,2);
I3=I(:,:,3);
I=cat(3,I1,I2,I3);
figure(1), imshow(I);
Irotate=imrotate(I,-15); % rotar la imagen a -15 grados
imshow(Irotate)
imwrite(Irotate,'Irotate.tif') % guardar la imagen rotada

rec=Irotate(4107:10400,4104:10500); %se recorta la imagen
figure(2), imshow(rec);
imshow(rec);
imwrite(rec,'rec.tif'); %se guarda la imagen rotada y recortada
%%
J= medfilt2(rec,[10 10]);% filtrado de mediana
figure(3), imshow(J);
imwrite(J,'J.tif');

se = strel('disk',25);
ICOM = imopen(J,se);
figure(5), imshow(ICOM);
imwrite(ICOM,'ICOM.tif');
```