

Identificación Asistida de Regiones de Interés Agronómico en Imágenes Aéreas Multiespectrales

Agustín Solano¹, Alejandro Hadad¹

Laboratorio de Sistemas de Información, Facultad de Ingeniería, Universidad Nacional de Entre Ríos

{asolano@bioingenieria.edu.ar, ajhadad@bioingenieria.edu.ar}

Resumen Actualmente, en los sistemas agropecuarios, es posible realizar una administración variable de los insumos para mejorar la eficiencia de la actividad agroindustrial y optimizar la logística del proceso de cosecha. En este sentido, se propuso, para el cultivo de caña de azúcar, utilizar herramientas de sensoramiento remoto y métodos computacionales para identificar áreas útiles que permitan realizar una administración diferenciada del cultivo.

Cuando al cosecharse la caña existe incidencia de vuelco de los tallos, junto con ellos se recolecta materia extraña, material no molible (vegetal o mineral). Al ingresar al ingenio la materia extraña provoca una importante pérdida de eficiencia en la manufactura del azúcar y afecta su calidad.

Teniendo en cuenta esta problemática, a partir del análisis de imágenes aéreas multiespectrales de campos cultivados con caña, se estudió la respuesta espectral del cultivo en distintas bandas del espectro electromagnético y se segmentaron regiones homogéneas de uso práctico para que el productor tome decisiones sobre la utilización de insumos y recursos según la variabilidad del sistema (caña en pie o caña caída).

Los resultados de la segmentación resultaron satisfactorios, pudiéndose obtener regiones homogéneas y calcular la superficie de las distintas regiones según el estado de la caña. También se realizó un análisis económico.

1. Introducción

Las características del sistema productivo agropecuario argentino y la necesidad de los productores de lograr la mayor eficiencia, precisión y productividad se reflejan en la constante demanda de herramientas, datos, información y nuevos conocimientos referidos a la Agricultura de Precisión (AP).

Entendiendo la AP como la aplicación de tecnología y principios para manejar la variabilidad espacio-temporal asociada a los aspectos de la producción agrícola, permitiría explorar y dimensionar el beneficio productivo y económico de adecuar las prácticas de manejo de forma sitio-específica. Permite reducir además el impacto ambiental y realizar una mejor utilización del potencial productivo del campo [9].

En este sentido, el sensoramiento remoto cumple una función fundamental. Sensoramiento Remoto se define como el área de conocimiento que, entre otras cosas, se ocupa de la adquisición de imágenes de la superficie terrestre sin entrar en contacto con ella, y del procesamiento, análisis y aplicación de la información obtenida [2]. Comprende una serie de técnicas precisas, eficientes, económicas y confiables a la hora de realizar un inventario de los recursos naturales de un área específica.

Las imágenes obtenidas pueden integrarse con otras capas de información espacial en un Sistema de Información Geográfica (GIS), con el uso de Sistemas de Posicionamiento Global (GPS) para localizar posiciones de interés, para luego realizar acciones de manejo para aplicar medidas correctivas en dichos sitios. La aparición comercial de imágenes de alta resolución y adquiridas en distintas bandas del espectro electromagnético ha impulsado la utilidad del sensoramiento remoto para propósitos agronómicos y relacionados con la agricultura de precisión.

A nivel regional, el sensoramiento remoto puede jugar un papel importante en el monitoreo de la cosecha y siembra en campos de pequeña escala donde información actualizada es difícil de encontrar. Existen numerosos estudios [10,13,17,21] que evidencian que la información espectral se relaciona con variables agronómicas y pueden utilizarse para monitorear cultivos y pronosticar rendimientos.

Realizar un manejo variable de los insumos a utilizar, según la variabilidad de los sistemas agropecuarios, permitiría mejorar la eficiencia de la actividad agroindustrial y optimizar la logística del proceso de cosecha. Este manejo variable podría ser aplicado a los procesos de cultivo y siembra de soja, trigo, maíz, o al proceso de cosecha en cultivos como la caña de azúcar.

El principal aporte de valor del presente trabajo final de carrera está relacionado a la identificación de regiones homogéneas, con un tamaño y forma que sean de uso práctico para el productor. Dichas regiones deberían permitirle al productor tomar decisiones para implementar un manejo diferenciado del cultivo con las herramientas de las cuales dispone.

Con este objetivo en mente, se aplicó una metodología basada en análisis algorítmico, construcción de modelos y experimentación numérica, incorporando enfoques de análisis para mejorar la detección del estado del cultivo a través del procesamiento de imágenes aéreas multiespectrales de los cuadros productivos de los campos con actividad agropecuaria. En particular, se trabajó con cultivos de caña de azúcar.

2. Cultivo de Caña de Azúcar

La caña de azúcar (*Saccharum officinarum*) es una especie vegetal, pluri-anual, que tiene un tallo macizo que acumula un jugo con 16 a 20 % de azúcares. Permite la manufactura de azúcar blanco de consumo y la elaboración de alcohol, energía, papel, entre otros productos. El cultivo de caña de azúcar en Argentina se encuentra localizado en un 99 % en Tucumán, Salta y Jujuy, y en

1 % en Misiones y Santa Fe, con una superficie total implantada de más de 344 mil hectáreas (ha) (datos provistos por el Ministerio de Economía y Finanzas Públicas de la Nación Argentina en el año 2011).

En el cultivo de caña de azúcar se producen pérdidas de materia prima que se clasifican como pérdidas de pre cosecha (principalmente debido a la incidencia de caña caída antes de la cosecha) y pérdidas de cosecha (caña trozada caída de la máquina cosechadora o soplada por el extractor de la máquina). Cada ejemplar de la plantación de caña de azúcar está constituido de manera diferente y manifiesta de manera única los estímulos externos que recibe. Cuando la planta es joven y se ha desarrollado bajo las mejores condiciones, alcanza cierta altura y por su propio peso se comienza a inclinar, pudiéndose quebrar. También colaboran en el vuelco el viento, granizo u otros fenómenos ambientales.

Cuando al cosecharse la caña existe incidencia de caña caída, junto con la materia útil se recolecta materia extraña, material no molible (vegetal o mineral) que acompaña a los tallos maduros. Cuando esta materia extraña ingresa al ingenio representa una importante pérdida de eficiencia en el proceso de manufactura del azúcar y afecta su calidad.

En la actualidad, para minimizar la introducción de materia extraña al ingenio, se envían evaluadores que recorren los campos por vía terrestre o con aviones para estimar la incidencia del vuelco, información que luego se utiliza para organizar el proceso de cosecha de la caña de forma diferenciada, según se trate de caña en pie o de caña caída. La caña también se suele lavar al llegar al ingenio para eliminar la materia extraña. La cuantificación de la caña caída en cuadros productivos es un proceso costoso e ineficiente, por lo que se consideró adecuado profundizar en nuevas técnicas para obtener información sobre el estado del cultivo.

3. Sensoramiento Remoto

El sensoramiento remoto permite obtener información de la superficie terrestre a lo largo de un perfil unidimensional o bidimensional (imágenes). Las imágenes pueden ser satelitales o aéreas, y se diferencian por las características del instrumento de adquisición utilizado: resolución espacial, espectral, radiométrica y temporal.

La curva de respuesta espectral o firma espectral de la vegetación muestra valores bajos en las longitudes de onda correspondientes al color rojo y al azul (espectro visible), con un pico menor en la región del verde. Estos picos y valles son causados por la absorción de la luz azul y roja por parte de la clorofila y otros pigmentos.

La respuesta o firma espectral de la caña varía de acuerdo al estado y las condiciones del cultivo. En las bandas visibles del espectro electromagnético, correspondientes al color verde y rojo, la reflectancia de la cubierta vegetal es menor que la del suelo descubierto; en la banda del infrarrojo cercano, la vegetación y el suelo descubierto tienen reflectancias muy diferentes, y son similares en el infrarrojo medio. La banda del infrarrojo medio es importante

para separar residuos de otros estados del cultivo. Desde el punto de vista fotométrico, el Índice de Diferencia Normalizada (NDVI) indica, en general, vegetación sana si toma valores altos y valores próximos a cero indican la existencia de suelo desnudo y vegetación seca. El NDVI se calcula de la siguiente forma: $NDVI = (NIR - Rojo) / (NIR + Rojo)$. Donde NIR es la fracción de radiación reflejada correspondiente al infrarrojo cercano y $Rojo$ es la fracción de radiación reflejada en la banda del rojo.

Para el presente trabajo, el área de estudio fue la Finca “Cedro Solo” del Ingenio San Martín de Tabacal (Orán, Salta), con una superficie de 5000 ha (56 cuadros productivos de 35 a 110 ha). Un vuelo se realizó el 5 de Mayo de 2008 con un avión Sky Arrow 650 TCNS ERA montado con una cámara Geospatial MS4100, con una resolución de 1920x1080 píxeles en cada canal de adquisición: verde (530-580nm), rojo (650-685nm) e infrarrojo cercano (770-830nm). Con el total de imágenes adquiridas se confeccionó un mosaico de la finca. Se seleccionó un tamaño de píxel de 0,7 m, lo que determinó una altura de vuelo de 1200 m sobre el nivel del terreno.

4. Enfoque propuesto

Para llevar a cabo la identificación de regiones, se propuso la aplicación de una serie de métodos computacionales sobre las imágenes para realizar su adecuación y la extracción de información, para poder identificar regiones de caña caída y regiones de caña en pie.

Por las características de la tarea a realizar y la información disponible, se propuso abordar el problema mediante técnicas de procesamiento de imágenes y métodos de *machine learning*.

5. Métodos

5.1. Conformación del conjunto de imágenes etiquetadas

En primer lugar, contando con la asistencia de un Ingeniero Agrónomo, se realizó el etiquetado de las imágenes aéreas multiespectrales en las clases de interés. Para ésto se utilizó la aplicación Label Me, desarrollada por el Instituto Tecnológico de Massachusetts [19].

El proceso de etiquetado consistió en delimitar en las imágenes polígonos que encerraban porciones representativas de las clases identificadas por el experto: Caña en Pie (CP), Caña Caída en Forma de Parches (CCP), Caña Caída en Áreas Grandes (CCA), Caña Caída con Fototropismo (CCF) y Corridas o áreas de suelo descubierto (C).

A los efectos prácticos de identificar regiones de caña en pie y regiones de caña caída, todos los subtipos de caña caída se integraron en una única clase de Caña Caída (CC). De esta forma se conformó un conjunto de subimágenes correspondientes a cada una de las clases indicadas (CP y CC).

5.2. Preprocesamiento

Si bien durante la adquisición, se buscó que la iluminación de la zona fotografiada sea lo más homogénea posible (las imágenes se tomaron durante el mediodía solar), se buscó también algún método que permita estandarizar las imágenes antes de llevar a cabo su análisis.

Pensando en dicha estandarización, las subimágenes se preprocesaron con el algoritmo *Texture + Cartoon*, que permitió descomponer cada imagen en una componente geométrica (patrones de baja frecuencia) y en una componente de texturas (patrones oscilatorios o de alta frecuencia) [6].

El algoritmo se caracteriza por la aplicación de un par de filtros pasa bajos-pasa altos no lineales. Para cada punto de la imagen se debe tomar la decisión de si éste pertenece a la parte geométrica o a la de texturas. La parte geométrica mantiene los valores originales de la imagen en los puntos definidos como no-textura. En los puntos identificados como textura, la parte geométrica toma el valor filtrado. En los puntos donde la decisión sea ambigua, se toma un promedio pesado de ambos. La parte de texturas es la diferencia entre la imagen original y la parte geométrica.

5.3. Extracción de características

En el campo de análisis de imágenes aplicado a la agricultura es habitual que se utilicen índices de vegetación basados en características fotométricas (relacionadas con la intensidad de luz detectada). El índice más utilizado es el NDVI.

Este tipo de índices proporcionan información relevante en relación al contenido de vegetación en una zona píxel a píxel pero no informan sobre las relaciones espaciales existentes entre los píxeles en una localización espacial dada.

Estudiando el caso particular de la caña de azúcar, se puede determinar que tiene pronunciadas alteraciones en la distribución espacial. Esta característica puede ser observada en las imágenes aéreas multiespectrales de los cuadros productivos de caña y se hace más evidente en las zonas afectadas por caña caída. Es por esto que en el presente trabajo, y en concordancia con Melchiori et al. [14], se propone abordar el problema utilizando características de textura en las imágenes.

Obteniendo las características de textura se propone caracterizar las variaciones en la distribución espacial en las distintas regiones de los campos cultivados con caña de azúcar con el objetivo de poder luego identificar las regiones de interés. Particularmente interesa poder diferenciar las zonas afectadas con caña caída de las zonas con caña en pie.

Melchiori et al. [14] han reportado que la Entropía de Shannon, el cual es un característico de textura de tipo estadístico comúnmente utilizado en agricultura, provee insuficiente información para distinguir los diferentes estados de la caña. En este trabajo se propone completar el conjunto de característicos de textura incorporando otros característicos estadísticos provenientes de analizar los diferentes canales de las imágenes.

Se estudiaron distintas combinaciones de descriptores:

- Media, Desvío Estándar y Entropía
- Varianza, Suavidad, Uniformidad y Entropía
- Contraste, Energía y Homogeneidad de la matriz de co-ocurrencia

En el apéndice A (sección 9.1) se realiza una definición matemática de cada uno de los descriptores considerados.

Para la extracción de descriptores, se aplicó el algoritmo de preprocesamiento sobre los canales IR, R y V de las imágenes y se calculó también el NDVI. Ambas componentes de cada canal (componente geométrica y componente de texturas) y la imagen NDVI fueron recorridas por ventanas cuadradas a partir de las cuales se calcularon los distintos conjuntos de descriptores. Se determinó que el tamaño más adecuado para las ventanas era 11x11 píxeles, lo que en el campo corresponde a un área cuadrada de 7,7 metros de lado (60m²).

Los vectores formados por los descriptores extraídos de cada ventana se asociaron con la etiquetas correspondientes a las imágenes de las cuales se extrajeron, para luego realizar el entrenamiento de los modelos y su validación.

5.4. Modelos de Clasificación

Los métodos de *machine learning* mas utilizados para clasificar imágenes multiespectrales, son *Random Forest* (RF), *Bagging*, *Boosting*, Árboles de Decisión, Redes Neuronales Artificiales, Máquinas de Soporte Vectorial (SVM) y K vecinos más cercanos (KNN) [1]. Sin embargo, en varios estudios ([24,11,22,16,23]) se comparan los métodos basados en árboles, y en particular Random Forest, con otros métodos basados en aprendizaje automático y resulta que en general RF tiene un desempeño superior en las tareas de clasificación para este tipo de imágenes.

Se evaluó el desempeño de los Arboles de Decisión, entrenados con el algoritmo conocido como CART y luego en forma de ensamble formando el método denominado *Random Forests*.

Árboles de Decisión Los árboles de decisión son modelos de predicción basados en inferencia inductiva, que permiten aproximar funciones que toman valores discretos o continuos, para los cuales la función entrenada es representada mediante una estructura en forma de árbol. Los árboles entrenados pueden representarse también como conjuntos de reglas “si-entonces” (*if-then*) para mejorar su entendimiento por parte del usuario.

Los árboles de decisión clasifican instancias ordenándolas desde el llamado nodo raíz (primer nodo del árbol) hasta algún nodo hoja, el cual determina la clase a la que pertenece cada instancia.

El algoritmo CART (*Classification and Regression Trees*) fue publicado por Breiman et al. [4] en 1984. Permite el crecimiento de árboles de decisión binarios, construidos mediante la división de un nodo en dos nodos hijos, en forma repetida, comenzando en un nodo raíz.

El árbol comienza a crecer empezando por el nodo raíz y repitiendo los siguientes pasos en cada nodo:

1. Encontrar la mejor división para cada atributo:

Para cada atributo continuo u ordinal, ordenar primero de menor a mayor todos los valores. Luego examinar cada punto de división candidato, v , para encontrar el mejor, es decir, el que maximiza el criterio de división. Dado v , si el valor del atributo es $x \leq v$, el caso va al nodo hijo de la izquierda, en otro caso va hacia el de la derecha.

Para cada atributo nominal hay que examinar subconjuntos posibles de categorías para encontrar la mejor división. Dado un subconjunto A , si $x \in A$, el caso va hacia el nodo hijo de la izquierda, en otro caso, va hacia el de la derecha.

2. Encontrar la mejor división para el nodo.

Entre las mejores divisiones encontradas para cada atributo en el paso 1, elegir la que maximice el criterio de división.

3. Dividir el nodo de acuerdo a la mejor división encontrada en el paso 2, si la condición de parada no se satisface.

El **criterio de división** más común es la **medida de impureza de Gini**. Ésta es una medida de cuan a menudo un elemento elegido al azar de un conjunto sería clasificado incorrectamente si fuera etiquetado al azar de acuerdo a la distribución de etiquetas en el subconjunto.

Los criterios de parada para los cuales al árbol deja de crecer son:

- El nodo es puro, todos los casos tienen la variable dependiente con idéntico valor.
- Todos los casos en el nodo tienen idéntico valor de los atributos.
- Si la profundidad actual del árbol alcanza el límite máximo especificado por el usuario.
- Si para la mejor división la mejora es menor que el valor mínimo de mejora especificado por el usuario.

Random Forests Método de ensamble que permite entrenar un clasificador que consiste en una colección de predictores del tipo árboles de decisión, tal que cada árbol depende de un conjunto de vectores elegidos al azar, de forma independiente y con igual distribución para cada árbol. Además cada árbol emite un voto para decidir cual es la clase más popular o más votada para un vector (ejemplo) de entrada x [5].

Los *random forests* se pueden construir mediante una selección aleatoria de atributos, una selección aleatoria de ejemplos de entrenamiento, o una combinación de ambas. Cualquier combinación de estas fuentes de diversidad va a permitir la conformación de un *random forest*. En caso de muestrear el conjunto de atributos y las instancias de entrenamiento, la construcción del modelo va a consistir en la concatenación de dos muestreos de tipo bootstrap, uno del conjunto de ejemplos de entrenamiento y otro del conjunto de atributos [12].

La selección aleatoria de atributos se realiza en cada nodo del árbol. Se acotan los atributos que pueden analizarse en cada nodo al momento de decidir la división del nodo. [12]

Para realizar estimaciones del error de generalización, partiendo de un conjunto de ejemplos de entrenamiento T , se forman una serie de conjuntos de entrenamiento T_k mediante un muestreo aleatorio con reemplazo. Para cada T_k se construye un clasificador $h(\mathbf{x}, T_k)$ y se le permite votar para formar el predictor de tipo ensamble. Para cada (y, \mathbf{x}) del conjunto de entrenamiento, se suman los votos provenientes únicamente de los clasificadores para los cuales su correspondiente conjunto T_k no contiene a (y, \mathbf{x}) . Éste se denomina clasificador *out-of-bag*. La estimación del **error out-of-bag** es la tasa de error del clasificador *out-of-bag* utilizando el conjunto de entrenamiento.

5.5. Determinación del desempeño de los modelos

Se llevó a cabo un proceso **Validación Cruzada** (*cross-validation* en inglés) del modelo, técnica utilizada para evaluar los resultados de un análisis estadístico y garantizar que son independientes de la partición entre datos de entrenamiento y validación.

Para implementar validación cruzada, primero hay que dividir aleatoriamente el conjunto de m vectores de datos etiquetados disponibles en k subconjuntos, donde cada uno será de tamaño m/k . El procedimiento de validación cruzada se corre k veces, tomando uno de los subconjuntos k_i , con $i = 1, \dots, k$, como conjunto de validación, y combinar los restantes $(k-1)$ subconjuntos para formar el conjunto de entrenamiento. Así cada dato es utilizado una vez para validación y $(k-1)$ veces para entrenamiento. En cada iteración, luego de entrenar se utiliza el conjunto de validación para determinar la tasa de éxito del modelo. Luego de las k iteraciones, el resultado final es la media aritmética de todos los valores de desempeño obtenidos. Lo más habitual, y lo que se utilizó en este trabajo, es tomar una valor $k = 10$, lo que se conoce como *10-fold-cross-validation*.

Conjuntos de Evaluación se utilizan para obtener otro valor de desempeño del modelo. En este caso, se quiere simular un escenario de la vida real, ya que el conjunto de evaluación se conforma con datos que no son utilizados para entrenar el modelo, son datos nunca vistos por el algoritmo de clasificación durante el entrenamiento. La tasa de éxito del modelo se determina con el conjunto de evaluación luego de entrenar el modelo con el conjunto de entrenamiento. En este trabajo, del total de datos etiquetados disponibles se separó aleatoriamente un 20% para formar parte del conjunto de evaluación, y el restante 80% se utilizó para realizar la validación cruzada y entrenar finalmente el modelo.

Otro recurso muy utilizado para obtener información relativa al proceso de clasificación es la **Matriz de Confusión**. Cada columna de la matriz representa el número de predicciones de cada clase realizadas por el modelo, mientras que cada fila representa las instancias reales de cada clase, dadas por las etiquetas del conjunto de evaluación. Si consideramos un escenario de dos clases a identificar, llamamos clase positiva a la que se desea identificar (caña caída, CC) y clase negativa a la otra clase (caña en pie, CP). Para este caso la matriz resultante se puede observar en el Cuadro 1.

TP (*true positive*) es el número de datos de la clase positiva que fueron correctamente clasificados por el modelo, FN (*false negative*) es la cantidad de

datos que pertenecen a la clase de interés pero que fueron etiquetados como clase negativa, TN (*true negative*) es el número de datos de la clase negativa que fueron clasificados correctamente y FP (*false positive*) es el número de datos que pertenecen a la clase negativa pero que fueron etiquetados como de clase positiva.

A partir de éstas cantidades es posible obtener una serie de índices o métricas simples. Se analizaron las siguientes:

- Tasa de ejemplos que fueron correctamente clasificados como clase positiva, conocida como **sensibilidad**:

$$\text{Sensibilidad} = \frac{TP}{TP + FN} \quad (1)$$

- Tasa de ejemplos que fueron correctamente clasificados como clase negativa, conocida como **especificidad**:

$$\text{Especificidad} = \frac{TN}{TN + FP} \quad (2)$$

- Valor predictivo positivo, fracción de ejemplos clasificados como clase positiva que son correctos, parámetro conocido como **precisión**:

$$\text{Precisión} = \frac{TP}{TP + FP} \quad (3)$$

5.6. Segmentación y postprocesamiento

Luego de determinar cual es el mejor modelo de clasificación, a partir de su desempeño, se lo utilizó para llevar a cabo la segmentación de las fotografías de cuadros productivos de caña de azúcar. Para esto se recorren las imágenes con ventanas del tamaño adecuado, se extraen los característicos correspondientes y se utiliza el modelo seleccionado para predecir a que clase pertenece esa porción de la imagen. Se obtiene una nueva imagen que muestra de forma diferenciada a que clase corresponde cada porción de la imagen.

Pensando en que los productores puedan extraer información relevante para ser utilizada en un proceso de toma de decisiones, se propuso la implementación de un algoritmo de postprocesamiento sobre las imágenes segmentadas. El objetivo fue eliminar de la segmentación pequeñas regiones dispersas o integrarlas a regiones más grandes y también que las regiones de tamaño considerable contengan dentro de sus límites píxeles clasificados como de la misma clase. Se quiso lograr que las regiones clasificadas tanto como Caña Caída como Caña en

		Clases predichas	
		CC	CP
Clases reales	CC	TP	FN
	CP	FP	TN

Cuadro 1: Matriz de Confusión.

Pie, sean regiones homogéneas, de estructura uniforme, que realmente puedan ser administradas de forma diferencial.

Se utilizó el método de **crecimiento de regiones** o *region growing*, en inglés, el cual es un procedimiento que agrupa píxeles o subregiones en regiones más grandes basándose en criterios predefinidos. El enfoque básico consiste en comenzar con un conjunto de puntos “semilla” y a partir de ellos empezar a formar regiones agregando a las semillas aquellos píxeles vecinos que tengan propiedades similares.

Para obtener los resultados deseados se propuso aplicar iterativamente este algoritmo en distintos puntos semilla. Para los puntos semillas se propuso crear una grilla sobre la imagen, con puntos equidistantes tanto en la coordenada x como en la coordenada y , y así, para cada punto (x, y) , se lleva a cabo el crecimiento de regiones. Si se detecta que un punto (x, y) ya pertenece a una región identificada en una iteración anterior, no se vuelve a aplicar el método.

La distancia entre los puntos de la grilla, en ambas coordenadas (Δx y Δy), define de alguna manera el mínimo tamaño de las regiones que se van a poder identificar. Dichas distancias dependerán de cada caso y esta es la parte del proceso que necesita asistencia por parte del usuario. Para analizar esto se hicieron pruebas con distintos valores de Δx y Δy hasta encontrar los óptimos para cada imagen en estudio en función de los tamaños ensayados.

6. Resultados

De los ensayos con árboles de decisión, se determinó que el conjunto de descriptores que permitió el mejor desempeño de clasificación fue el conjunto Media, Desvío Estándar y Entropía, con 14 % de error de validación cruzada, menor que para los otros conjuntos. Además, los canales con mayor aporte de información fueron el Rojo y el Infrarrojo. Respecto a los descriptores, el que mostró mayor aporte de información fue la entropía, en los casos en los que formaba parte del conjunto utilizado.

Luego, respecto a los Árboles de Decisión entrenados con los mismos conjuntos de característicos, con los modelos Random Forest se produjo un descenso del error de validación cruzada. El modelo que ofreció mejor desempeño de clasificación fue el Random Forest entrenado con los característicos Media, Desvío Estándar y Entropía, con un error de validación cruzada de 7,3 %, una Sensibilidad del 92 % y una Especificidad del 94 %, valores también superiores que los de los otros modelos entrenados.

Se hace hincapié en la importancia de que estas medidas tomen valores altos ya que dan información sobre que tan bueno es el modelo de clasificación utilizado para identificar tanto los ejemplos de caña caída como de caña en pie. Es importante que el modelo pueda identificar con alta tasa de éxito caña caída en ejemplos de caña caída (alta sensibilidad), y caña en pie en ejemplos de caña pie (alta especificidad). Sin embargo, a los efectos de la utilización que podrían hacer los productores de la información provista por las imágenes segmentadas, es más importante que el modelo tenga alta sensibilidad. Es deseable que el modelo se

confunda con baja probabilidad al clasificar ejemplos que son de caña caída, ya que si los clasifica erróneamente como caña en pie le estaría dando información errónea al productor. Son precisamente la regiones con caña caída las que le interesa conocer para poder administrar de forma diferencial el cultivo. En el caso contrario, si el modelo confunde ejemplos de caña en pie clasificándolos como caña caída, el impacto que esto conlleva sobre la pérdidas que podría tener el productor son menores.

El modelo Random Forest con mejor desempeño se utilizó para realizar la segmentación de las imágenes de los cuadros productivos de caña de azúcar, para diferenciar las áreas afectadas por la incidencia de vuelco de la caña respecto de las áreas de caña en pie.

Una evaluación global de la segmentación, a partir de las imágenes etiquetadas, determinó un desempeño global de 89% de píxeles correctamente segmentados, según la etiqueta asignada durante la segmentación de las subimágenes etiquetadas.

Luego, para permitir que las imágenes resultantes permitan a los productores extraer información relevante y poder tomar decisiones, de forma fácil y rápida, se implementó el método de crecimiento de regiones. El objetivo es que el productor, al observar las imágenes, pueda analizar los datos de forma coherente con las decisiones que el puede tomar. Necesita conocer que regiones del campo puede cosechar normalmente (regiones de caña en pie) y en que regiones la cosecha se debería realizar de forma mas cuidadosa para evitar levantar materia extraña junto con los tallos de caña. El hecho de cosechar de una forma u otra debe justificarse también con el tamaño de las parcelas, con su ubicación y con las características de la técnica de cosecha.

Con esto en mente, se construyeron grillas de puntos semilla para al algoritmo, con una distancia fija tanto en el eje x (Δx) como en el eje y (Δy). Se ensayaron distancias equivalentes a 25 m, 50 m, 75 m y 100 m.

Los resultados indicaron, para distintas imágenes, una degradación de la segmentación entre 5% y 16%, al homogeneizar las regiones. Además se calcularon, para las distintas imágenes, la superficie de caña caída y la superficie de caña en pie.

En la Figura 1 se muestran una serie de imágenes correspondientes a uno de los cuadros productivos de caña de azúcar fotografiados, denominado k31. La imagen 1a muestra la imagen original, representada en formato RGB, pero en la cual el canal R fue reemplazado por el canal Infrarrojo Cercano de las imágenes aéreas, el canal G por Rojo y el B por el canal Verde. La imagen 1b es el resultado del proceso de segmentación. Se puede observar en ella la existencia de gran cantidad de pequeñas regiones de caña en pie (verdes) y de caña en caída (azules), dispersas en la imagen. Las imágenes 1c, 1d, 1e y 1f surgen del postprocesamiento de la imagen segmentada con los distintos tamaños de grilla.

En el Cuadro 2 se muestran las superficies de las distintas regiones, dadas en hectáreas.

En el Apéndice B (9.2) se muestran otros resultados de segmentación.

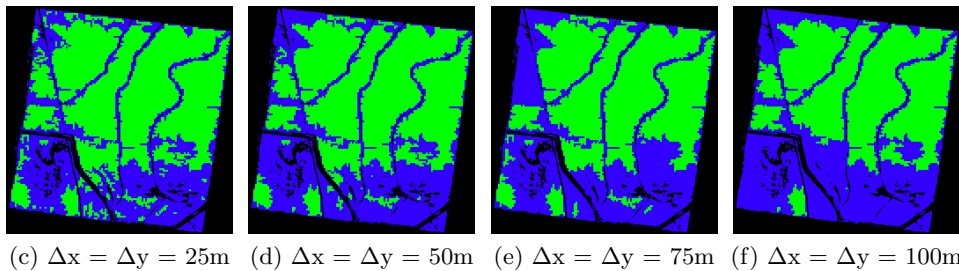



Figura 1: Resultados obtenidos de aplicar el procedimiento propuesto sobre la imagen k31.

7. Análisis Económico

La materia extraña, que se provee junto con la caña, incorpora componentes de origen orgánico y no orgánico al proceso industrial. Éstos implican en muchos casos un significativo incremento de los costos de elaboración de azúcar, disminuyendo con ellos los rendimientos industriales (kilogramos de azúcar por tonelada de caña) [15].

La materia extraña no contiene sacarosa, y además, en su pasaje por los molinos, tiene la capacidad de embeberse de jugo de los tallos y, en consecuencia, a la salida de los molinos extrae sacarosa, aumentando así las pérdidas de la misma. Además, su presencia aumenta el desgaste de los rodillos, trapiche, calderas, bombas; se reduce la extracción de sacarosa y la tasa de molienda, y se disminuye el poder calorífico del bagazo [3]. Existe entonces un valor monetario no percibido por causa del azúcar que no se fabricó debido a la presencia de la materia extraña.

La tierra como componente de la materia extraña es mucho más perjudicial en sus efectos que el material vegetal. Causa desgaste en los rodillos del molino, tuberías, martillos trituradores, tubos de la caldera, y equipamiento de reco-

Grilla	Superficie de CP	Superficie de CC
25m	43ha	28ha
50m	42ha	30ha
75m	39ha	32ha
100m	37ha	34ha

Cuadro 2: Superficies de caña caída y caña en pie en las imágenes postprocesadas del cuadro k31.

lección de cenizas. Además, la presencia de tierra en el bagazo afecta su valor calorífico y sus cualidades de combustión [8].

Por otro lado, debido a la presencia de la materia extraña, hay un efecto importante por concepto del costo económico incurrido en virtud de tener que cortar, cargar y transportar material vegetal no azucarado [18].

Dada la posibilidad de realizar una cosecha más eficiente al conocer con mayor precisión las zonas afectadas por vuelco, es posible levantar menor cantidad de materia extraña. En algunos casos se puede incluso decidir trozar la caña en pedazos más pequeños para maximizar el llenado de los camiones con producto útil.

A partir del conocimiento del estado del cultivo (zonas con caña caída) y combinándolo con información de otras fuentes, como estimaciones de rendimiento, se podría llegar a diseñar cronogramas de utilización de distintos recursos. La optimización de cronogramas de cosecha permitiría recuperar más azúcar de los campos, directamente aumentando el azúcar recuperada de los ingenios [20].

En varios ingenios se realizan inversiones significativas para la instalación de mesas lavadoras de caña necesarias para remover el contenido de tierra y otras materias extrañas mediante grandes cantidad de agua. Para esto se necesita dinero para invertir, y se producen mayores costos por la potencia requerida, el agua necesarias y la maquinaria adicional; disponibilidad de terreno para instalar decantadores de arena y barros para poder reusar el agua y no devolverla así a los causes incrementando la contaminación. Además [7] encontró que durante el lavado se producen pérdidas de sacarosa del orden del 1-2%.

Aquellas intervenciones en el proceso de cosecha que aporten a levantar menor cantidad de materia extraña durante las tareas de cosecha, considerando un caudal fijo, redundarán en un tiempo de lavado menor, y por lo tanto, disminuirán las pérdidas de sacarosa por arrastre con el agua, además de tener un flujo de caña limpia mayor.

Luego de realizar un análisis económico de las pérdidas, y los costos y beneficios adicionales incluidos al utilizar el software desarrollado, se determinó que es viable su implementación para un área de cobertura de 1000 hectáreas o más. Esto no significa que sólo los productores que tengan un establecimiento de dicho tamaño son los únicos usuarios posibles, sino también que las cooperativas que agrupen varios productores podrían adquirir y utilizar el software de análisis.

8. Conclusiones

Se realizó un estudio de cómo a partir de la adquisición de información relacionada con la radiación electromagnética proveniente de la superficie terrestre se puede determinar el estado de la vegetación que se encuentra en ella. En particular para el cultivo de la caña de azúcar, se determinó como su respuesta espectral varía según el estado del cultivo.

Recordando que el objetivo principal del trabajo era la identificación de regiones homogéneas en las imágenes aéreas multiespectrales de los cuadros productivos de caña de azúcar, se considera que los resultados en este sentido fueron satisfactorios. Se consideran adecuados tanto los resultados del proceso de segmentación como los del proceso de postprocesamiento.

El descriptor con mayor aporte fue la entropía de Shannon. Esta idea está en conformidad con las conclusiones extraídas por Melchiori et al. [14] respecto al uso de la entropía, y al obtenerse mejores resultados agregando otros estadísticos de primer orden, se refuerza la idea de que la entropía no era suficiente para lograr una adecuada identificación de CC y CP, al igual de que no era suficiente la sola utilización de índices fotométricos.

Referencias

1. Ozlem Akar and Ogur Gungor. Classification of multispectral images using random forest algorithm. *Journal of Geodesy and Geoinformation*, (2):105–112, 2012.
2. Ángel Ruiz Alonso. Comportamiento y análisis de descriptores de texturas en imágenes MODIS, 2011.
3. L. S. Birkett. The influence of tops and trash on the economics of sugar production. In *ISSCT Puerto Rico*, volume 12, pages 1632–1642, 1965.
4. L. Breiman, J. H. Friedman, R. Olshen, and C. J. Stone. *Classification and Regression Tree*. Wadsworth and Brooks/Cole Advanced Books and Software, 1984.
5. Leo Breiman. Random forests. *Machine Learning*, 45:5–32, 2001.
6. Antoni Buades, Triet M. Le, Jean Michel Morel, and Luminita A. Vese. Fast cartoon + texture image filters. *IEEE Transactions on Image Processing*, 19(8), 2010.
7. S J Clarke. Losses associated with cane yard operations and cane washing. *Proceedings of The South African Sugar Technologists' Association*, pages 139–144, 1991.
8. W B Clarke, M R Player, and G H Weiss. Effect of extraneous matter on millers' and growers' costs. *Proceedings of Australian Society of Sugar Cane Technologists*, pages 39–46, 1988.
9. José Alexandre Melo Demattê, José Luiz Iorette Demattê, Evandro Roberto Alves, Roberto Negr ao Barbosa, and Jorge Luis Morelli. Precision agriculture for sugarcane management: a strategy applied for brazilian conditions. In *Actas Scientiarum Agronomy*, volume 36, 2004.
10. Lênio Soares Galvao, Antônio Roberto Formaggio, and Daniela Arnold Tisot. Discrimination of Sugarcane Varieties in Southeastern Brazil with E0-1 Hyperion Data. *Remote Sensing of Environment*, (94):523–534, 2005.

11. Steven Jay, Rick Lawrence, Kevin Repasky, and Charlie Keith. Invasive species mapping using low cost hyperspectral imagery. In *ASPRS Annual Conference*, 2009.
12. Ludmila I. Kuncheva. *Combining Pattern Classifiers: Methods and Algorithms*. John Wiley and Sons, 1 edition, 2004.
13. Valentine Lebourgeois, Agnes Begue, Pascal Degenne, and Eric Bappel. Improving harvest and planting monitoring for smallholders with geospatial technology: the reunion island experience. *International Sugar Journal*, 109(1298):109–119, 2010.
14. Arturo E. Melchiori, Alejandra Kemerer, Ricardo J.M. Melchiori, and Martín Bellomo. Utilización de fotografías aéreas multiespectrales de alta resolución para la cuantificación de caña de azúcar caída. In *I Congreso Argentino de Agroinformática*. Sociedad Argentina de Informática (Mar del Plata, Argentina), 2009.
15. Marvin Oviedo and Marco Chaves. Determinación de la cantidad y calidad de la materia extraña presente en las entregas comerciales de caña de azúcar (*saccharum spp*) en el ingenio la argentina, grecia, costa rica. In *Congreso de ATACORI “Ing. Agr. José Luis Corrales Rodríguez”*, volume 15, pages 183–189. Asociación de Técnicos Azucareros de Costa Rica, 2003.
16. Anantha M. Prasad, Louis R. Iverson, and Andy Liaw. Newer classification and regression tree techniques: Bagging and random forests for ecological prediction. *Ecosystems*, (2):181–199, 2006.
17. Noé Aguilar Rivera, Guadalupe Galindo Mendoza, and Javier Fortanelli Martínez. Evaluación agroindustrial del cultivo de caña de azúcar (*saccharum officinarum l.*) mediante imágenes spot 5 hrv en la huasteca México. *Revista de la Facultad de Agronomía*, 111(2), 2012.
18. Eduardo Raúl Romero, Patricia Andrea Digonzelli, and Jorge Scandaliaris. *Manual del Cañero*. Estación Experimental Agroindustrial Obispo Colombes, 1 edition, 2009.
19. Bryan C. Russel, Antonio Torralba, Kevin P. Murphy, and William T. Freeman. Labelme: a database and web-based tool for image annotation. *International Journal of Computer Vision*, (1–3):157–173, 2008.
20. Michael E. Salassi, Lonnie P. Champagne, and Benjamin L. Legendre. Maximizing economic returns from sugarcane production through optimization of harvest schedule. *Bulletin of Louisiana State University Agricultural Center*, 868, December 1999.
21. Prasad S. Thenkabail, Ronald B. Smith, and Eddy De Pauw. Hyperspectral vegetation indices and their relationships with agricultural crop characteristics. *Remote Sensing of Environment*, 71(2):158–182, 2000.
22. Bjorn Waske and Matthias Braun. Classifier ensembles for land cover mapping using multitemporal sar imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, (5):450–457, 2009.
23. Bjorn Waske, Vanessa Heinzl, Matthias Braun, and Gunter Menz. Random forests for classifying multi-temporal sar data. In *Envisat Symposium*, Montreux, Suiza, 2007.
24. J. D. Watts and R. L. Lawrence. Merging random forest classification with an object-oriented approach for analysis of agricultural lands. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, pages 578–582, 2008.

9. Apéndices

9.1. Apéndice A

Los descriptores de naturaleza estadística se basan en la descripción de las texturas utilizando momentos estadísticos del histograma de niveles de gris de una región en una imagen bajo estudio. Supongamos que z es una variable aleatoria que denota los niveles de intensidad en la imagen y sea $p(z_i)$, con $i = 0, 1, 2, \dots, L - 1$, el histograma correspondiente, donde L es el número de niveles de intensidad distintos. Para las imágenes disponibles L toma el valor de 256.

La **media** m de la variable z , es decir, el nivel de gris promedio de la región considerada, se define como:

$$m = \sum_{i=0}^{L-1} z_i * p(z_i) \quad (4)$$

Luego, el n -ésimo momento de z sobre la media m será:

$$\mu_n(z) = \sum_{i=0}^{L-1} (z_i - m)^n * p(z_i) \quad (5)$$

El segundo momento es conocido como **varianza**:

$$\sigma^2 = \mu_2(z) = \sum_{i=0}^{L-1} (z_i - m)^2 * p(z_i) \quad (6)$$

Es una medida del contraste en niveles de grises.

Otro descriptor de textura ampliamente utilizado es el **desvío estándar** σ . Se calcula como la raíz cuadrada de la varianza. Es una medida de dispersión de los valores de la variable z y tiende a ser más intuitivo que la varianza.

Un par de descriptores adicionales que resultan útiles para analizar texturas y se basan en el histograma son la medida de **uniformidad** y la **entropía promedio**. La uniformidad se define como:

$$U = \sum_{i=0}^{L-1} p^2(z_i) \quad (7)$$

U es máxima cuando todos los pixeles tienen la misma intensidad. La entropía promedio es una medida del grado de desorden de un conjunto de valores y se define como:

$$e = - \sum_{i=0}^{L-1} p(z_i) * \log_2 p(z_i) \quad (8)$$

e es nula cuando todos los valores son iguales, es decir, la región considerada es constante.

Medidas de textura obtenidas unicamente a partir de histogramas no contienen información relativa a la posición de cada píxel respecto a los demás. Esto es importante al describir texturas, ya que no solo tienen en cuenta la distribución de intensidades sino también la posición relativa de los píxeles en la imagen.

Para explicar este nuevo enfoque, se define Q como un operador que especifica la posición de dos píxeles relativa a cada uno, y se considera una imagen f con L posibles niveles de intensidad. Sea \mathbf{G} una matriz cuyos elementos g_{ij} representan la cantidad de veces que un par de píxeles con intensidades z_i y z_j se encuentran en la figura f en la posición especificada por Q , donde $1 \leq i, j \leq L$. La matriz \mathbf{G} formada de esta forma se conoce como matriz de co-ocurrencia de niveles de intensidad o simplemente **matriz de co-ocurrencia**.

La cantidad de niveles de intensidad posibles en la imagen determina el tamaño de la matriz \mathbf{G} . Si $L = 256$, \mathbf{G} será de 256×256 . En general, para reducir la carga computacional y hacer más manejables las matrices, se suelen cuantizar los niveles en una pocas bandas. Por ejemplo, en el caso de 256 niveles, se podrían igualar a cero los 32 primeros niveles de intensidad, hacer 1 los siguientes 32, 2 los 32 siguientes y así sucesivamente. De esta forma los 256 niveles se transformarían a 8 niveles y la matriz de co-ocurrencia quedará de 8×8 .

La cantidad total n de pares de píxeles que satisfacen Q es igual a la suma de los elementos de \mathbf{G} . Luego, la cantidad definida por:

$$p_{ij} = \frac{g_{ij}}{n} \quad (9)$$

es una estimación de la probabilidad de que un par de puntos que satisfacen Q tengan valores (z_i, z_j) .

A continuación se presentan algunos descriptores que permiten caracterizar la matriz \mathbf{G} , de tamaño $K \times K$:

Contraste:

$$\sum_{i=1}^K \sum_{j=1}^K (i-j)^2 * p_{ij} \quad (10)$$

Es una medida de la diferencia de intensidades entre un píxel y su vecino. Se calcula la sumatoria para todos los píxeles de la imagen. Toma valor 0 para imágenes con valores constantes y se hace exponencialmente grande a medida que aumenta la diferencia de intensidad.

Homogeneidad:

$$\sum_{i=1}^K \sum_{j=1}^K \frac{p_{ij}}{1 + |i-j|} \quad (11)$$

Puede tomar valores entre 0 y 1. Su valor aumenta cuando el contraste entre pares de píxeles desciende. Es alta cuando \mathbf{G} se concentra a lo largo de su diagonal. Esto ocurre cuando la matriz es localmente homogénea, de acuerdo a la

relación dada por Q .

Energía:

$$\sum_{i=1}^K \sum_{j=1}^K p_{ij}^2 \quad (12)$$

Toma valores entre 0 y 1, siendo 1 para una imagen de valores constantes.
Es una medida de uniformidad de la imagen.

9.2. Apéndice B




Figura 3: Resultados de aplicar el procedimiento propuesto sobre la fotografía k46

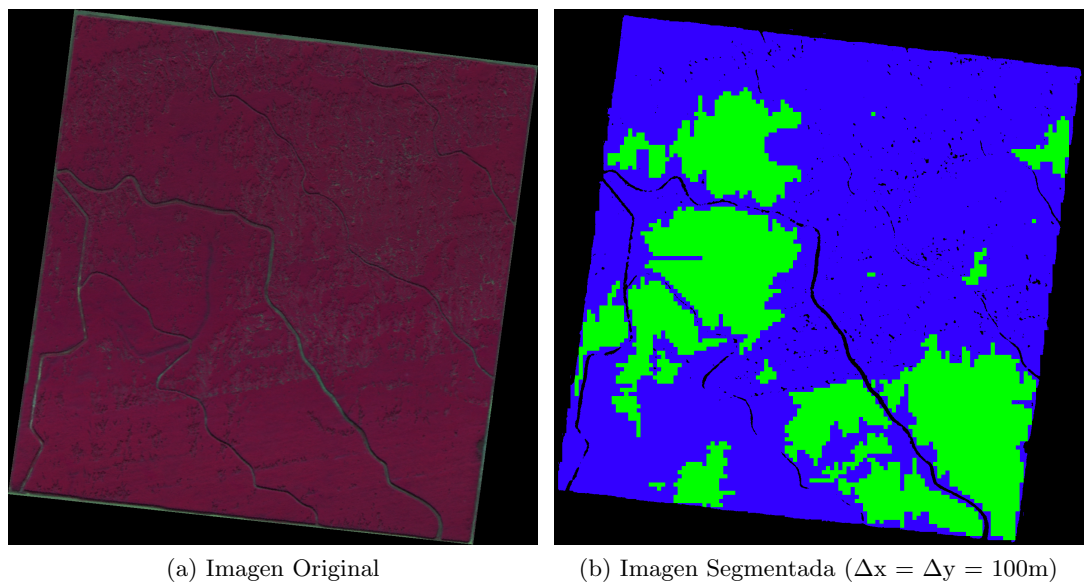


Figura 4: Resultados de aplicar el procedimiento propuesto sobre la fotografía k27

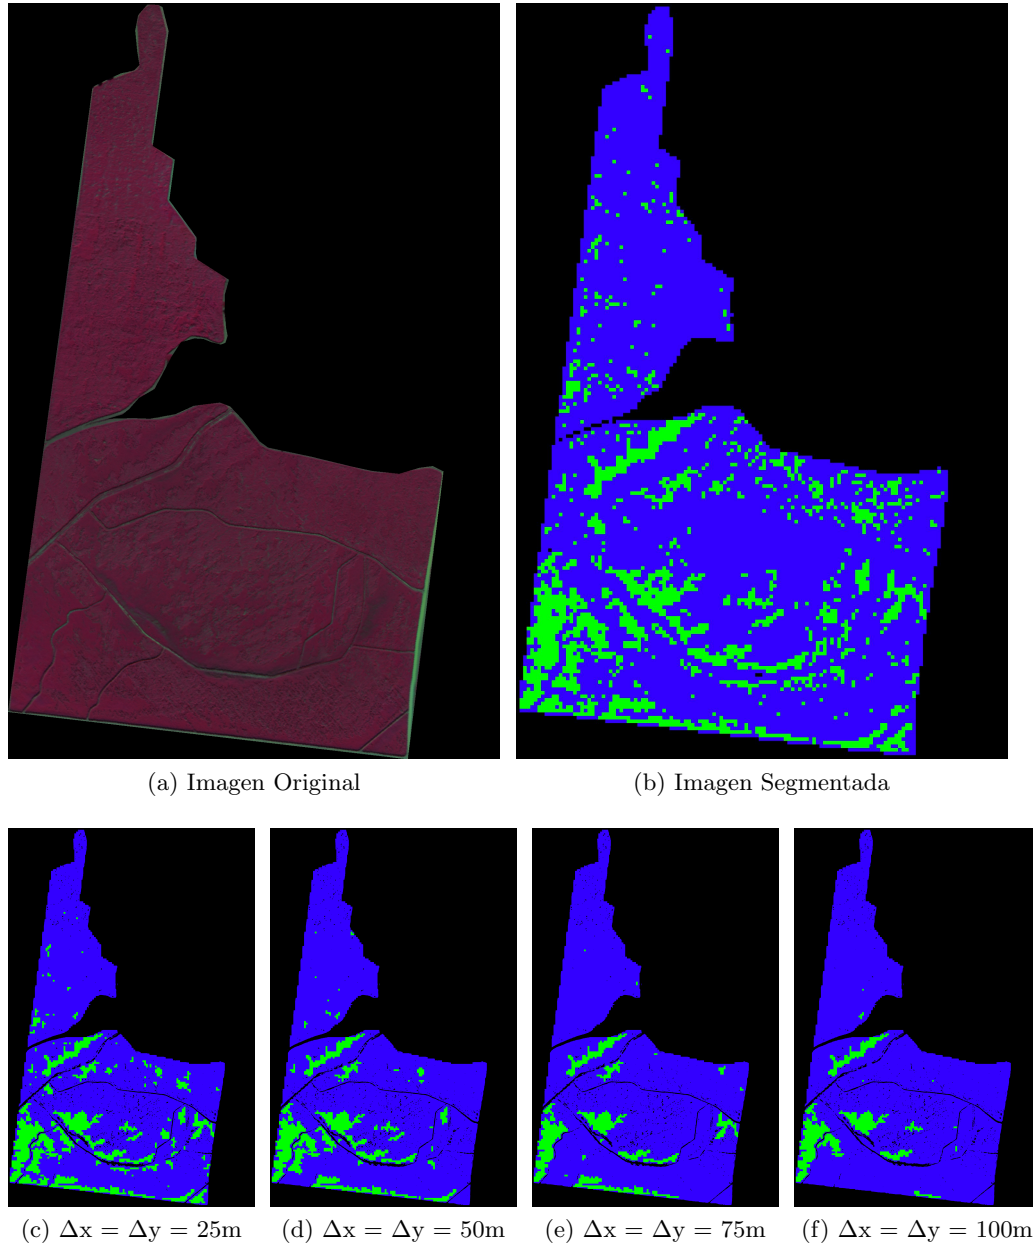


Figura 2: Resultados obtenidos de aplicar el procedimiento propuesto sobre la imagen k09.