



# UNIVERSIDAD DEL PAPALOAPAN

---

Campus Loma Bonita

## INGENIERÍA EN COMPUTACIÓN

APLICACIÓN DE UN SISTEMA DE INFERENCIA PARA EL  
RECONOCIMIENTO DE OBJETOS EN IMÁGENES DIGITALES

### TESIS

QUE PARA OBTENER EL TÍTULO DE:  
INGENIERA EN COMPUTACIÓN

### PRESENTA:

LEYDY HERNÁNDEZ YESCAS

### ASESOR DE TESIS:

D.R. EDUARDO SÁNCHEZ SOTO

LOMA BONITA, OAXACA.

2016



# UNIVERSIDAD DEL PAPALOAPAN

---

## INGENIERÍA EN COMPUTACIÓN

LA PRESENTE TESIS TITULADA “**APLICACIÓN DE UN SISTEMA DE INFERENCIA PARA EL RECONOCIMIENTO DE OBJETOS EN IMÁGENES DIGITALES**” PRESENTADA POR LA SUSTENTANTE DE LICENCIATURA **C. LEYDY HERNÁNDEZ YESCAS** BAJO LA DIRECCIÓN DEL **DR. EDUARDO SÁNCHEZ SOTO**, HA SIDO REVISADA Y ACEPTADA POR EL COMITÉ EXAMINADOR PARA SER DEFENDIDA EN EL EXAMEN PROFESIONAL Y OBTENER EL TÍTULO DE INGENIERA EN COMPUTACIÓN.

**DR. EDUARDO SÁNCHEZ  
SOTO  
ASESOR**

**M.C. RAFAEL F. GONZÁLEZ  
ZÁRATE  
PRESIDENTE**

**M.C. EDUARDO ORTIZ  
HERNÁNDEZ  
SECRETARIO**

**M.C. ALMA ALHELÍ PEDRO  
PERÉZ  
VOCAL**

*Dedicado a  
mi padre y a mi madre*

# Índice general

<b>Agradecimientos</b>	<b>IV</b>
<b>Resumen</b>	<b>V</b>
<b>Abstract</b>	<b>VI</b>
<b>Índice de figuras</b>	<b>VII</b>
<b>Índice de tablas</b>	<b>IX</b>
<b>1. Introducción</b>	<b>1</b>
1.1. Problemática . . . . .	3
1.2. Justificación . . . . .	3
1.3. Objetivos . . . . .	3
1.3.1. Objetivo general . . . . .	3
1.3.2. Objetivos específicos . . . . .	4
1.4. Hipótesis . . . . .	4
<b>2. Estado del arte</b>	<b>5</b>
2.1. Comportamiento y análisis de descriptores de texturas en imágenes MODIS . . . . .	5
2.2. Caracterización de texturas naturales . . . . .	6
2.3. Corrección de artefactos en estudios de perfusión miocárdica en SPECT utilizando herramientas de procesamiento digital de imágenes e inteligencia artificial . . . . .	7
2.4. Análisis de imágenes mediante texturas: aplicación a la clasificación de unidades de vegetación . . . . .	9
2.5. Segmentación de imágenes utilizando la transformada Watershed: obtención de marcadores mediante lógica difusa . . . . .	10

<i>ÍNDICE GENERAL</i>	III
<b>3. Marco teórico</b>	<b>12</b>
3.1. Textura . . . . .	12
3.1.1. Enfoques de estudio de la textura . . . . .	13
3.2. Descriptores de textura . . . . .	14
3.2.1. Descriptores de primer orden . . . . .	14
3.2.2. Descriptores de segundo orden . . . . .	15
3.3. Sistema de inferencia . . . . .	17
3.3.1. Reconocer . . . . .	17
3.4. Base del conocimiento . . . . .	18
3.5. Operaciones morfológicas . . . . .	18
<b>4. Creación de la base del conocimiento</b>	<b>20</b>
4.1. Características y formato de las imágenes . . . . .	21
4.1.1. Cielo . . . . .	21
4.1.2. Edificio . . . . .	22
4.1.3. Vegetación . . . . .	22
4.2. Administración de la base de datos . . . . .	23
4.3. Parámetros que representan una imagen . . . . .	24
4.3.1. Parámetros seleccionados . . . . .	24
4.3.2. Cálculo de parámetros . . . . .	25
4.3.3. Análisis de datos . . . . .	31
4.3.4. Cálculo de los modelos . . . . .	32
<b>5. Clasificación de objetos</b>	<b>36</b>
5.1. Clasificación con un parámetro . . . . .	37
5.2. Análisis de datos . . . . .	40
5.3. Filtro para reducir el "ruido" . . . . .	41
5.4. Clasificación basada en la fusión de información . . . . .	44
5.5. Fusión de clasificadores (alto nivel) . . . . .	48
<b>6. Resultados</b>	<b>51</b>
<b>7. Conclusiones</b>	<b>58</b>
<b>Bibliografía</b>	<b>62</b>

# Agradecimientos

Quiero dar gracias a mi madre Roberta Yescas y mi padre Norberto Hernández por todo el esfuerzo que han hecho por sacarme adelante, por su apoyo incondicional y la confianza que han puesto en mí. Son la inspiración que tengo para salir adelante, también agradezco a mis hermanos por el esfuerzo y paciencia que han tenido en este tiempo, los quiero mucho.

Gracias a Dios por cada día de vida.

Gracias a mi director de tesis el Dr. Eduardo Sánchez Soto por la atención y tiempo que me brindó durante este periodo y por el presente trabajo. Por la confianza que me tuvo y por ser como un amigo para mí, gracias, lo estimo mucho.

Gracias a mis abuelos Virginia, Anastacia y Vicente por darme un lugar en su hogar y en su corazón. A todos mis primos y tíos por su cariño.

Gracias a mis compañeros y amigos por el tiempo que compartimos juntos, las experiencias vividas y los trabajos en equipo. Les agradezco su apoyo y comprensión: Carmen, Zuleima, Marleny, Kike, Genaro, José Luis, Arturo, Alex, Ezequiel, Christian y Nieto. Gracias a Francisco Márquez por ser mi compañero y amigo desde que lo conocí, por motivarme y por el cariño que me ha brindado.

Gracias a mis revisores el profesor M.C. Eduardo Ortiz Hernández, M.C. Rafael Fernando González Zárate y la profesora M.C. Alma Alhelí Pedro Pérez por tomarse el tiempo de leer el presente trabajo y realizar críticas constructivas que ayudaron a mejorar el trabajo de investigación realizado.

# Resumen

El procesamiento en las imágenes digitales es la técnica aplicada para obtener o facilitar la búsqueda de información en ella. Una de las técnicas en el procesamiento digital es la segmentación, la cual se encarga de reconocer o clasificar patrones con características similares; por ejemplo en este trabajo, los edificios. Las características que diferencian al edificio de las otras partes (clases) que componen a la fotografía son muchas, sin embargo, en este trabajo se utilizó la textura y a partir de ella se realiza la clasificación. La textura de las diferentes regiones de la imagen fue utilizada para detectar la ubicación de un edificio del campus de nuestra Universidad. Este proceso se realizó aplicando un sistema de inferencia que indica si el pixel pertenece a la región de interés, en nuestro caso el edificio.

Existen muchas maneras de describir la textura y en las pruebas realizadas enfocadas a la segmentación se utilizaron: la entropía, contraste, correlación, homogeneidad y gradiente. La primera prueba utilizó la entropía, seguida de operaciones morfológicas y reducción de "ruido". Posteriormente se enfocó el proceso en la fusión de información obtenida a partir de los otros parámetros relacionados también con la textura (entropía, contraste, gradiente y homogeneidad). Los procesos realizados en este trabajo ayudaron a localizar la zona donde se encuentra el objeto de interés. Es importante mencionar que el proceso realizado con la entropía tiene menor error de clasificación en los bordes. Esto se debe a que los procesos realizados, operaciones morfológicas, toman en cuenta de mejor manera las condiciones en que se adquirieron las fotografías (luminosidad, iluminación, posición, etc.) y por lo tanto el error de clasificación también es diferente.

Los resultados obtenidos muestran que los parámetros finalmente seleccionados en este trabajo ayudaron a detectar la ubicación del edificio. Como fue especificado desde los objetivos de este trabajo, la técnica propuesta puede ser usada en aplicaciones donde el poder de cómputo es una restricción.

**Palabras clave:** *Textura, segmentación, sistema de inferencia y fusión de información.*

# Abstract

The processing of digital images is the technique used to obtain or facilitate the search for information on it. One of the techniques in image processing segmentation which is responsible for recognizing or classifying patterns with similar characteristics; for example, in this investigation the technique was used for recognizing buildings. The texture of the different regions of the image was used to detect the location of one of the buildings of our university. This process is performed by applying an inference system that indicates whether or not the pixel belongs to the region of interest, in our case the building.

There are many ways to measure the texture the test realized focused on the segmentation used: the entropy, contrast, homogeneity and gradient. The first test used the entropy, following the morphological operations and noise reduction. Subsequently the process is focused on the fusion of information obtained from the other parameters related with the texture (entropy, contrast, gradient and homogeneity).

The processing carried out in this investigation helped to locate the area where the object of interest is located. It is important to mention that the processing with the entropy has a lower error of classification around the borders than the other. The processing realized took better account of the conditions of the photograph acquisition (brightness, illumination, position, etc.), therefore the error of classification is also different.

The results obtained show that the parameters selected in this investigation helped to detect the buildings location. As specified from the objectives of this investigation, the proposed technique can be used in applications where computing power is restricted.

**Key words:** *Texture, segmentation, inference system and information fusion.*

# Índice de figuras

1.1. Ejemplo de segmentación. . . . .	2
2.1. Resultado de la segmentación de texturas naturales. . . . .	7
2.2. Aplicación de la transformada de Watershed con sus centros de masa (A), Objetos segmentados (B), identificación y selección de la imagen cardiaca (C). . . . .	8
2.3. Ventanas de filtros de tres vecindarios: media ponderada (L), gradiente (E), forma (S), ondulación (W), rugosidad (R) y oscilación (O). . . . .	9
2.4. Resultado de la clasificación a unidades de vegetación. . . . .	10
2.5. Resultado de la segmentación al aplicar la transformada Watershed. . . . .	11
3.1. Matriz de co-ocurrencia. . . . .	15
3.2. Dilatación. . . . .	18
3.3. Erosión. . . . .	19
3.4. Apertura. . . . .	19
3.5. Cierre. . . . .	19
4.1. Fotografías capturadas. . . . .	20
4.2. Fotografías del Cielo. . . . .	21
4.3. Fotografías del Edificio. . . . .	22
4.4. Fotografías de la Vegetación. . . . .	23
4.5. Estructura de la base de datos. . . . .	24
4.6. Representación de los tamaños de ventanas. . . . .	26
4.7. Modelo de los parámetros con ventanas de tamaño $N \times N$ . . . . .	27
4.8. Proceso para el cálculo de parámetros. . . . .	29
4.9. Representación de datos calculados Entropía y Energía. . . . .	32
4.10. Ejemplo de imágenes recortadas. . . . .	32

4.11. Proceso para el cálculo del modelo de cada clase. . . . .	33
4.12. Gaussiana de cada clase para la Entropía y Energía. . . . .	35
5.1. Diagrama de flujo para la clasificación con el parámetro entropía. . . . .	39
5.2. Resultados de aplicar el umbral cielo-edificio y cielo-vegetación. . . . .	40
5.3. Resultado de aplicar el umbral cielo-edificio y cielo-vegetación a una imagen homogenea. . . . .	41
5.4. Resultado de aplicar el umbral edificio-vegetación para extraer la clase vegetación (b). . . . .	41
5.5. Resultado de la fusión de la clase cielo y vegetación (c). . . . .	42
5.6. clasificación manual: el área blanca representa el objeto de interés (edificio). . . . .	43
5.7. Resultados de ventanas analizadas. . . . .	43
5.8. Diagrama de flujo para la clasificación basada en la fusión de información. . . . .	45
5.9. Representación de los umbrales de decisión. . . . .	46
5.10. Etapas de la fusión. . . . .	49
5.11. Representación de la selección del pixel. . . . .	50
6.1. Parámetros calculados . . . . .	52
6.2. Resultados de la prueba realizada con el parámetro entropía. . . . .	53
6.3. Resultados de la prueba dos al aplicar una fusión de clasificadores. . . . .	54
6.4. Clasificación de cada parámetro. . . . .	55
6.5. Resultado de las pruebas realizadas variando los pesos y parámetros. . . . .	56
6.6. Resultado final de la fusión de clasificadores. . . . .	57

# Índice de tablas

4.1. Filtro de 3x3. . . . .	28
4.2. Parámetros clase cielo. . . . .	30
4.3. Parámetros clase edificio. . . . .	30
4.4. Parámetros clase vegetación. . . . .	31
4.5. Resultado de los modelos. . . . .	34
5.1. Resultado al aplicar ventanas de $N \times N$ para el filtrado de la imagen. . . . .	42
5.2. Umbral para cada parámetro. . . . .	46

# Capítulo 1

## Introducción

Hoy en día el procesamiento de una imagen digital es muy importante con ella podemos encontrar información que se puede analizar, modelar o tratar. Una imagen puede ser definida matemáticamente como una función bidimensional,  $f(x, y)$ , donde  $x$  y  $y$  son coordenadas espaciales (en un plano), y  $f$  es la intensidad o nivel de gris de la imagen en esa coordenada. Cuando los valores  $f(x, y)$  son cantidades finitas y discretas, decimos que la imagen es una imagen digital. Estos elementos son llamados pels, o píxeles [24].

La información obtenida en una imagen digital se utiliza para detectar objetos, a esta técnica se le conoce como segmentación de imágenes [4]; esto permite diferenciar objetos de interés del resto de la imagen, porque se particiona dicha imagen en patrones parecidos que permiten obtener características o información de las regiones segmentadas. Los métodos más comunes de segmentación se basan en las variaciones de la intensidad de los niveles de escala de grises, es decir, de esta forma se miden las diferencias de textura o colores entre vecindades de píxeles o los cambios drásticos en las intensidades de ciertas regiones de la imagen. Otra técnica que permite detectar objetos de interés en una imagen es la transformada Watershed [9], a partir de marcadores detecta los objetos de interés en la imagen.

Este tipo de técnicas nos permiten tener información del objeto y de esta forma poder utilizarla para clasificar objetos de acuerdo a su tamaño, forma o color. El reconocimiento de objetos o reconocimiento de patrones en imágenes digitales cada vez se vuelve más importante, porque nos permite trabajar con la información segmentada y eliminar información que no es necesaria, es por eso que en este trabajo se plantea utilizar un sistema de inferencia, que nos permita reconocer la zona en la que se encuentra el objeto de interés en una imagen digital.

Los sistemas de inferencia han tenido mucho éxito y han sido utilizados en sistemas de reconocimiento de escritura, mejoras en imágenes médicas (ajustando el contraste en los bordes) y trabajos en ascensores (reduce el tiempo de espera a partir del número de personas) [16].

En la Figura 1.1 se muestra la imagen principal y sus segmentos, al aplicar un sistema de inferencia éste detectará la zona o ubicación del objeto de interés, en este caso el edificio. El sistema de inferencia detecta la zona de interés con la ayuda de modelos que representan el cielo, edificio y vegetación, es decir, se realizará el entrenamiento del sistema con información a priori de cada clase o patrón.



Figura 1.1: Ejemplo de segmentación.

## **1.1. Problemática**

La detección de objetos en una imagen digital, no es una tarea fácil, el problema se presenta por las limitaciones de la computadora para diferenciar objetos del resto de la imagen como lo hace el ser humano. A partir de una imagen se puede obtener información relevante si se realiza un buen procesamiento que devuelva la información esencial para la detección de los objetos. El problema principal es encontrar un proceso que proporcione información que sea analizada para diferenciar los objetos presentes en la imagen digital.

## **1.2. Justificación**

La detección de objetos en una imagen digital requiere de un proceso que proporcione información relevante, con un mínimo error en el reconocimiento. Aplicar un proceso correcto es de gran importancia puesto que si es eficiente y se encuentra la ubicación del objeto de interés podrá ser utilizado para alguna aplicación en la que se requiera proporcionar información de la ubicación del objeto.

Es necesario detectar la información que se encuentra en las imágenes, principalmente la que se puede utilizar para la búsqueda del objeto.

Detectar la ubicación del objeto de interés también permitirá dar información de las características que tenga el objeto.

## **1.3. Objetivos**

### **1.3.1. Objetivo general**

Detectar la ubicación del objeto de interés (edificio) en una imagen digital a partir de los descriptores de textura aplicando un sistema de inferencia.

### **1.3.2. Objetivos específicos**

Los objetivos específicos que permitirán lograr el objetivo general se describen a continuación:

- Revisar el estado el arte.
- Tomar fotografías en la zona de interés.
- Seleccionar los descriptores de textura.
- Realizar el análisis de textura a las imágenes.
- Crear los modelos de cada clase.
- Aplicar un sistema de inferencia que reconoce el objeto de interés (edificio).
- Fusionar la información obtenida con los descriptores de textura.

### **1.4. Hipótesis**

Utilizar un sistema de inferencia permitirá reconocer la ubicación de los objetos de interés de una imagen digital, a partir de la información a priori analizada con los descriptores de textura para cada imagen digital.

## Capítulo 2

# Estado del arte

### 2.1. Comportamiento y análisis de descriptores de texturas en imágenes MODIS

La extracción de información sobre la cobertura vegetal a través de los denominados índices de vegetación, proponen el estudio de descriptores para el análisis de imágenes obtenidas por medio de la plataforma MODIS (Moderate Resolution Imaging Spectroradiometer), instalada a bordo de dos satélites espaciales, Terra y Aqua de la NASA. Dado el vuelo periódico de los satélites es posible obtener imágenes de la misma zona espaciadas en el tiempo.

El objetivo es analizar la variación de ciertas regiones de la imagen en el tiempo. Esto se conoce como análisis temporal, las imágenes utilizadas corresponden a la Comunidad Foral de Navarra procedentes de entornos rurales agrícolas y forestales. En este tipo de texturas la evolución temporal sólo es apreciable transcurridos largos periodos de tiempo, habitualmente años, siendo ésta la unidad temporal para el análisis [1].

Los enfoques para analizar textura son los siguientes: métodos estructurales, métodos estadísticos, métodos basados en el modelo y Métodos basados en una transformada. Este trabajo aplica los métodos estadísticos. El objetivo consiste en describir la evolución temporal de las texturas existentes en una determinada región espacial de la imagen de la cual se ha extraído información sobre la cobertura vegetal a través de los índices de vegetación [1].

Los descriptores de textura que se seleccionaron de acuerdo al enfoque estadístico son los siguientes: varianza, suavidad, uniformidad y entropía. Los descriptores de textura son capaces de capturar las diferentes variaciones de textura en función de la vegetación existente. ENVI [22] realiza la pertenencia de los píxeles a la región de interés.

## 2.2. Caracterización de texturas naturales

En este trabajo el propósito es encontrar los métodos que ayuden a caracterizar de forma correcta paisajes naturales. Las clases a segmentar en este trabajo son las siguientes: árbol, arena, cielo, montaña y nubes. Para crear su base de conocimiento se usan imágenes recolectadas de internet [14] [15] [12].

A continuación se enlistan algunos descriptores de textura propuestas por Haralick [10] calculadas a partir de la matriz de co-ocurrencia: probabilidad máxima, momento de distinción de elementos de orden  $k$ , momento inverso de distinción de elementos de orden  $k$ , entropía, uniformidad, correlación, contraste, homogeneidad y tendencia de clúster.

En este trabajo seleccionan los parámetros con ayuda de la herramienta See5 [17] la cual selecciona las siguientes variables con base en la información procesada: momento de distinción de elementos de orden  $k$ , momento inverso de distinción de elementos de orden  $k$ , entropía, uniformidad, correlación, homogeneidad y tendencia de clúster. En la Figura 2.1 se muestra el resultado de una de las imágenes segmentadas en el trabajo citado.



Figura 2.1: Resultado de la segmentación de texturas naturales.

### **2.3. Corrección de artefactos en estudios de perfusión miocárdica en SPECT utilizando herramientas de procesamiento digital de imágenes e inteligencia artificial**

El objetivo del presente trabajo es el análisis y corrección de los artefactos producidos por la hiper captación hepática en los estudios de PM realizados con  $^{99m}\text{Tc}$ -MIBI en esfuerzo y reposo en SPECT. Para ello, utiliza técnicas de procesamiento digital de imágenes (PDI) e inteligencia artificial (IA) para remover la actividad hepática, reemplazándola por los valores correspondientes a la actividad de fondo, con el fin de eliminar las causas que dificultan la evaluación clínica de la perfusión del músculo cardíaco [8].

Para llevar a cabo el objetivo utilizan la entropía, la transformada Watershed y operaciones morfológicas a las imágenes. De esta forma tratan de reducir la aparición de artefactos en las imágenes de perfusión miocárdica en SPECT (Single Photon Emission Computed Tomography).

La reducción de la actividad hepática inicia con la aplicación de la entropía local sobre el conjunto de cortes coronales. La entropía mide la textura pasando una matriz de  $9 \times 9$  elementos sobre la imagen. Esta matriz define el valor de entropía ( $H$ ) del pixel central de acuerdo a la definición de Shannon [11], ecuación 2.1.

$$H = - \sum_i p_i \log p_i \quad (2.1)$$

donde  $p_i$  es la probabilidad de las cuentas del pixel central en el conjunto de la matriz.

Para reducir el tamaño de las estructuras de bordes presentes en la imagen obtenida se aplicaron técnicas de erosión. La imagen obtenida fue sometida a un proceso de binarización (reducción de información de una imagen digital a dos valores, 0 (negro) y 255 (blanco)) por umbral (valor límite que determina si un pixel será de color blanco o negro), utilizando para ello un valor de umbral de 0.15. En el siguiente paso se segmentó la imagen utilizando la transformación de Watershed [9]. Así, son identificados los objetos correspondientes al ventrículo izquierdo, procediendo luego al reconocimiento de las estructuras hepáticas a partir de las relaciones geométricas establecidas previamente entre los objetos.

Para resolver problemas de subsegmentación de objetos, aparición de surcos o agujeros en los mismos, y con el fin de reparar espacios con falta de continuidad se emplearon técnicas morfológicas de dilatación, erosión, apertura y cierre [8]. En la Figura 2.2 se muestra el resultado a la aplicación de las técnicas mencionadas.



Figura 2.2: Aplicación de la transformada de Watershed con sus centros de masa (A), Objetos segmentados (B), identificación y selección de la imagen cardiaca (C).

La utilización de las herramientas propuestas permiten elaborar procedimientos que son aplicados satisfactoriamente, demostrando la posibilidad de automatización y adaptabilidad de los mismos para corregir las causas de la generación de artefactos, permitiendo una evaluación más certera de los estudios clínicos [8].

## 2.4. Análisis de imágenes mediante texturas: aplicación a la clasificación de unidades de vegetación

Este trabajo detalla el proceso realizado sobre imágenes pancromáticas [20] digitalizadas a 60cm y 2m por pixel, con el fin de analizar las diferentes posibilidades de trabajo de las variables de textura en la caracterización de unidades de vegetación. Se ha trabajado sobre dos ámbitos geográficos diferentes para resaltar las diferencias de resultados entre la vegetación influenciada por la acción humana y aquella que lo está en menor medida. Sobre las imágenes digitalizadas se extraen las zonas de ensayo sobre las que se calcularon variables de textura a partir de la matriz de co-ocurrencia de niveles de gris, con un vecindario óptimo de 21x21 píxeles y a partir de filtros de energía de 7x7.

El objetivo de aplicar las ventanas de filtro (Figura 2.3) a las imágenes es para obtener características texturales como la forma, ondulación, rugosidad, gradiente, etc. . Este método es llamado energía textural. Consiste en la convolución de la imagen con varios filtros, produciendo tantas imágenes como convoluciones realizadas. Si llamamos  $I$  a la imagen inicial y  $g_1, \dots, g_n$  a los respectivos filtros, una imagen genérica resultante de la convolución vendrá definida por la expresión:  $J_n = I * g_n$  [20].

3 x 3	5 x 5	7 x 7
L = [ 1 2 1 ]	L = [ 1 4 6 4 1 ]	L = [ 1 6 15 20 15 6 1 ]
E = [ -1 0 1 ]	E = [ -1 -2 0 2 1 ]	E = [ -1 -4 -5 0 5 4 1 ]
S = [ -1 2 -1 ]	S = [ -1 0 2 0 -1 ]	S = [ -1 -2 1 4 1 -2 -1 ]
	W = [ -1 2 0 -2 1 ]	W = [ -1 0 3 0 -3 0 1 ]
	R = [ 1 -4 6 -4 1 ]	R = [ 1 -2 -1 4 -1 -2 1 ]
		O = [ -1 6 -15 20 -15 6 -1 ]

Figura 2.3: Ventanas de filtros de tres vecindarios: media ponderada (L), gradiente (E), forma (S), ondulación (W), rugosidad (R) y oscilación (O).

Calculadas las características de las imágenes, el proceso de clasificación se basó en la regla de decisión de Bayes. Las reglas y las características calculadas fueron útiles en la clasificación porque los resultados obtenidos fueron satisfactorios. En la Figura 2.4 se muestran los resultados de este trabajo.




Figura 2.4: Resultado de la clasificación a unidades de vegetación.

## 2.5. Segmentación de imágenes utilizando la transformada Watershed: obtención de marcadores mediante lógica difusa

Esta transformada es fácilmente adaptable a los diferentes tipos de imágenes y es capaz de distinguir objetos sumamente complejos que no pueden ser analizados correctamente mediante algoritmos convencionales. Este es el caso de las imágenes biomédicas, las cuales están compuestas por objetos con alto contenido de textura y una amplia variabilidad de formas, tamaños e intensidades [9]. Para llevar a cabo la segmentación realizan el análisis de textura del cual calculan los siguientes descriptores de textura: contraste, valor máximo, energía, valor medio, gradiente.

A través de su gradiente, se obtiene una imagen donde los niveles de los contornos de los objetos a segmentar representan una zona de elevada intensidad de gris. Las zonas de baja intensidad de gris darán lugar a las vasijas o "basins" por donde fluirá el agua e inundará la topografía de la imagen [9].

Calculados los descriptores de textura, utilizan un sistema de inferencia difuso que determina si el pixel pertenece al fondo o al objeto de interés. Esto se logró mediante funciones de pertenencia de tipo trapezoidales. El éxito de esta transformada depende de la elección de marcadores unívocos para cada uno de objetos de interés que eviten la sobresegmentación que presentan las imágenes de alto contenido de textura [9]. Estos marcadores fueron obtenidos después de aplicar el sistema de inferencia difuso ya que la defuzzificación dio los valores de 0 y 1. De esta manera la información fue reducida e indicaba que los valores próximos a cero pertenecían al fondo.

Para elegir correctamente los marcadores de la imagen binaria, se aplicaron las siguientes operaciones morfológicas, una apertura para eliminar pequeñas componentes conectadas pertenecientes al fondo y a objetos irrelevantes. Luego se le aplicó un cerramiento para unir componentes conectadas cercanas seguidas de una erosión con un elemento de 3x3 para que los marcadores no excedan el tamaño real del objeto [9]. En la Figura 2.5 se muestra la imagen segmentada después de usar la transformada Watershed.




Figura 2.5: Resultado de la segmentación al aplicar la transformada Watershed.

## Capítulo 3

# Marco teórico

### 3.1. Textura

Cuando los humanos observamos una imagen, procesamos dos tipos de información: el tono (aplicado a nuestro caso, el nivel de gris) y la textura, es decir, la relación que tienen entre sí los distintos elementos de la imagen: si describen algún patrón, si el aspecto es liso, rugoso, granulado, homogéneo o heterogéneo.

La textura es una característica importante para el análisis de imágenes, es la repetición de un patrón o patrones en una región. El patrón puede ser repetido exactamente o con variaciones de él mismo. Algunos autores como Sonka [23] han denominado téxel (de "textural element" y por analogía a pixel, de "picture element") a la unidad mínima de la textura.

El tono estará relacionado con la variación de los niveles de gris de los píxeles y la textura lo estará con la distribución espacial de los niveles de gris [18].

### 3.1.1. Enfoques de estudio de la textura

Los enfoques utilizados para analizar las texturas son muy diversos, y difieren entre ellos principalmente en el método utilizado para extraer las características de la textura. Se identifican cuatro categorías:

**Métodos estadísticos:** están divididos en métodos estadísticos de primer y segundo orden.

- Los de primer orden calculan sus variables (media, varianza, entre otras.) a partir del histograma de la imagen.
- Los de segundo orden calculan sus variables (contraste, correlación, energía, entre otras.) a partir de la matriz de co-ocurrencia.

**Métodos estructurales:** se trata de técnicas que describen las texturas como la composición de elementos de textura bien definidos, tales como líneas paralelas regularmente espaciadas, o concatenaciones de figuras geométricas de formas conocidas tales como pentágonos u otras formas geométricas [1].

**Métodos basados en el modelo:** estas técnicas se fundamentan en la construcción de un modelo empírico de cada pixel en la imagen basado en una suma ponderada de las intensidades de los pixeles en la vecindad del primero. Los parámetros estimados de los modelos así generados se utilizan como descriptores de las características de la textura. Ejemplos de este tipo de descriptores son los modelos auto regresivos, los campos aleatorios de Markov o los modelos fractales [1].

**Métodos basados en una transformada:** estas técnicas convierten la imagen en una nueva forma o espacio utilizando las propiedades de frecuencia espacial de las variaciones de intensidad de los pixeles [1].

## 3.2. Descriptores de textura

Los descriptores de textura enfocados a métodos estadísticos son de primer y segundo orden. Los de primer orden calculan los descriptores a partir del histograma y los de segundo orden con la matriz de co-ocurrencia.

### 3.2.1. Descriptores de primer orden

Una variable aleatoria  $z$  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 y por tanto en el caso que nos ocupa y en la representación de byte,  $L$  toma el valor de 256 [1].

**Media:** el valor medio  $m$  de  $z$ , es el nivel medio de intensidad en una región caracterizada por sus valores de intensidad  $z_i$  con sus correspondientes probabilidades  $p(z_i)$  [1]. Ecuación 3.1.

$$m = \sum_{i=0}^{L-1} z_i p(z_i) \quad (3.1)$$

**Varianza:** representa las desviaciones con respecto de la media de los valores de intensidad en una región dada. Por consiguiente, mide el contraste de los valores de intensidad en esa región. Así, una región homogénea donde todos los píxeles poseen el mismo valor de intensidad la varianza será nula, mientras que en regiones con elevados contrastes la varianza será alta [1]. Ecuación 3.2.

$$\mu_n(z) = \sum_{i=0}^{L-1} (z_i - m)^n p(z_i) \quad (3.2)$$

### 3.2.2. Descriptores de segundo orden

La matriz de co-ocurrencia es una matriz de frecuencias con la que un pixel con un nivel de gris ( $i$ ) aparece en una relación de espacio específica con otro pixel de nivel de gris ( $j$ ). Las matrices de co-ocurrencia son medidas de segundo orden porque consideran parejas de píxeles vecinos, separados a una distancia  $d$  y en un determinado ángulo. Por tanto, las matrices de co-ocurrencia pueden revelar ciertas propiedades sobre la distribución espacial de los grises en la textura de la imagen [18], ver Figura 3.1. A partir de la matriz de co-ocurrencia se pueden calcular los siguientes descriptores de textura:




Figura 3.1: Matriz de co-ocurrencia.

**Uniformidad:** la uniformidad  $U$  será máxima si todos los niveles de gris de la imagen son iguales, y decrecerá cuando los valores de los niveles de gris dejen de ser iguales [1]. Ecuación 3.3.

$$\sum_i \sum_j C_{i,j}^2 \tag{3.3}$$

**Probabilidad máxima:** provee información sobre la frecuencia más grande de un par de píxeles en la matriz de co-ocurrencia. Este descriptor es útil para percibir la predominación de un color en la textura, por lo tanto para una textura fina su valor será cercano a 1 [2].

$$\max_{i,j}(C_{i,j}) \quad (3.4)$$

**Momento de distinción de elementos de orden k:** este descriptor aumenta su valor cuando los elementos de la matriz se encuentran alejados de la diagonal principal, cuando k es igual a 2 brinda la misma información que el descriptor de contraste. Para una textura rugosa el valor de este descriptor es cercano a 1 [2].

$$\sum_i \sum_j (i-j)^k c_{i,j} \quad (3.5)$$

**Momento inverso de distinción de elementos de orden k:** proporciona información sobre la distribución de la matriz, lo cual da una idea de la variación de colores de la textura. Por lo tanto para una textura fina con una variación suave de colores, el valor de este descriptor es cercano a 0 [2].

$$\frac{\sum_i \sum_j c_{i,j}}{(i-j)^k} \quad i \neq n \quad (3.6)$$

**Correlación:** mide la relación entre las diferentes intensidades de los colores.

$$\frac{\sum_i \sum_j (i - \mu_x)(j - \mu_y)c_{i,j}}{(\sigma_x \sigma_y)} \quad (3.7)$$

**Contraste:** el contraste de una textura proporciona información acerca de las variaciones bruscas de color en la imagen.

$$\sum_i \sum_j (i-j)^2 c_{ij} \quad (3.8)$$

**Homogeneidad:** este descriptor proporciona información sobre la irregularidad local de la textura.

$$\sum_i \sum_j \frac{1}{1 + (i-j)^2} c_{ij} \quad (3.9)$$

**Tendencia de clúster:** se puede inferir que este descriptor aumentará su valor a medida que la media de los valores esté más cercana al valor mínimo [2].

$$\sum_{i,j} (i + j - 2\mu)^k c_{i,j} \quad (3.10)$$

### 3.3. Sistema de inferencia

El sistema de inferencia proporciona una manera de obtener una conclusión a partir de información de entrada vaga, ambigua, imprecisa, con ruido o incompleta. Un sistema de inferencia imita la forma en que una persona toma decisiones basada en información con las características mencionadas. Una de las ventajas es su implementación en sistemas tanto en hardware como en software o en combinación de ambos [3].

#### 3.3.1. Reconocer

Será un atributo básico del ser humano así como de otros organismos vivientes. En nuestra vida pasamos todo el tiempo reconociendo, reconocemos la cara de un amigo entre una multitud de gente, reconocemos los objetos que están alrededor de nosotros y actuamos y nos movemos con relación a lo que reconocemos. Reconocemos firmas, voces, podemos leer escritos, analizar huellas digitales, distinguimos sonrisas de gestos de miedo. Reconocemos que alguien tiene razón, reconocemos una solución a un problema, construcciones mentales equivocadas. Podemos reconocer mapas, imágenes, electrocardiogramas, firmas espectrales, series de tiempo. Entonces, podemos distinguir entre dos tipos de reconocimiento: reconocimiento de objetos concretos que involucran un reconocimiento sensorial que se realiza por medio de la vista y del oído y el reconocimiento abstracto [19].

### 3.4. Base del conocimiento

La base del conocimiento es un término que considera dos palabras importantes para su definición: conocimiento y razonamiento. Es decir para que una persona o sistema pueda tomar una decisión debe tener un conocimiento previo a la decisión que va tomar, esto es razonar la acción con base al conocimiento que se tiene [19].

### 3.5. Operaciones morfológicas

La morfología matemática se basa en operaciones de teoría de conjuntos. En el caso de imágenes binarias, los conjuntos tratados son subconjuntos de  $Z^2$ . Las operaciones morfológicas simplifican imágenes y conservan las principales características de forma de los objetos. Un sistema de operadores de este tipo y su composición, permite que las formas subyacentes sean identificadas y reconstruidas de forma óptima a partir de sus formas distorsionadas y ruidosas.

Las operaciones morfológicas que se aplican a las imágenes binarias son la dilatación, erosión, apertura y cierre.

Las aplicaciones que se tienen son extracción de fronteras y componentes conexas, rellenado de regiones, adelgazamiento, engrosamiento y esqueleto [5].

**Dilatación:** la dilatación se refiere a agregar pixeles al contorno del objeto presente en la imagen.

Figura 3.2.




Figura 3.2: Dilatación.

**Erosión:** la erosión elimina pixeles del contorno de objetos presente en la imagen. Figura 3.3.




Figura 3.3: Erosión.


**Apertura:** consiste en realizar una erosión seguida de una dilatación, utilizando el mismo elemento estructural en ambas operaciones. Figura 3.4.



(a) original - apertura

Figura 3.4: Apertura.

**Cierre:** consiste en realizar una dilatación seguida de una erosión, utilizando el mismo elemento estructural en ambas operaciones. Figura 3.5.



(a) original - cerradura

Figura 3.5: Cierre.

## Capítulo 4

# Creación de la base del conocimiento

En este trabajo se requiere una base de datos para crear la base del conocimiento que ayudará a entrenar el sistema para segmentar una imagen. Una base de datos es un conjunto de información almacenada de la cual se puede extraer información.

Dado que se interesa en tres tipos de "cosas" dentro de las imágenes (cielo, edificio y vegetación), se tiene que disponer de esos elementos en la base de datos. Para crearla se tomaron fotografías del cielo, del edificio de agroingeniería de la universidad del Papaloapan y de la vegetación presente alrededor del edificio. Estas fotografías se tomaron con una cámara digital Panasonic Lumix DMC-FS3 con un sensor de resolución de 8,1 MP configurado en modo automático; esto es, la abertura del diafragma y el tiempo de exposición lo decide automáticamente la cámara. En la Figura 4.1 se muestra un ejemplo de las fotografías capturadas para crear la base de datos.



Figura 4.1: Fotografías capturadas.

## 4.1. Características y formato de las imágenes

El formato de las imágenes esta en jpeg(Joint Photographic Experts Group), con profundidad de 24 bits y representación de color en RGB(Red, Green y Blue) [21]. Para determinar la cantidad de imágenes a incluir en la base de datos se apoyo en el teorema del límite central y en el hecho de que los parámetros se proponen que sean modelados utilizando gaussianas. Estos modelos, que ayudarán en la toma de decisiones, requieren de una muestra lo bastante grande como mínimo  $n > 30$ , sea cual sea la distribución de la variable de interés; la distribución de la media muestral será aproximadamente una normal [6] como ya se mencionó. Es por lo anterior que se tomaron 100 fotografías de cada clase para el entrenamiento, 50 de cada clase para la prueba. También se tomaron 50 fotografías en las que aparecen las tres clases. A continuación se mencionan las categorías de elementos que tienen las fotografías capturadas.

### 4.1.1. Cielo

Estas fotografías fueron capturadas sin considerar las condiciones climáticas; días calurosos, nublados o soleados. Los días calurosos se establecieron cuando la temperatura ambiente era superior a los 32, y los días nublados con temperatura de 27. Bajo estas condiciones el cielo no presentaba mucha luminosidad pero si nubosidad. En la Figura 4.2 se muestran ejemplos de la clase cielo.




Figura 4.2: Fotografías del Cielo.

### 4.1.2. Edificio

Las fotografías del edificio fueron tomadas en días calurosos y nublados con temperatura similares a las mencionadas en la categoría cielo. También fueron tomadas a distintos ángulos y distintas distancias para tener una mejor representación en la base del conocimiento. En la Figura 4.3 se muestran ejemplos de la clase edificio.



Figura 4.3: Fotografías del Edificio.

### 4.1.3. Vegetación

Las fotografías de la vegetación tienen temperaturas similares a las mencionadas en las categorías anteriores. Las fotografías en la que mejor se aprecian las formas de la vegetación son en los días calurosos, en los días nublados las fotografías son muy oscuras y no se apreciaba bien la forma de las hojas o plantas presentes en la vegetación. Sin embargo, los cambios en las tonalidades aún se perciben bien. En la Figura 4.4 se muestran ejemplos de la clase vegetación.



Figura 4.4: Fotografías de la Vegetación.

## 4.2. Administración de la base de datos

Para calcular los parámetros en las imágenes se requirió una base de datos estructurada, debido a que los parámetros calculados se guardan en su directorio correspondiente dependiendo a la clase que pertenezca. En la Figura 4.5 se muestra la estructura en la que están jerarquizados los directorios de interés (cielo, edificio y vegetación) tanto para la fase de entrenamiento como para la fase de prueba.

La base de datos se administró de la siguiente manera:

- Tesis es la carpeta raíz.
- BaseDeDatos contiene las carpetas de Entrenamiento y Prueba.
- La carpeta de Entrenamiento contiene las carpetas de Cielo, Edificio y Vegetación, dentro de cada una de estas carpetas están las fotografías pertenecientes al cielo, edificio y vegetación que servirán para la fase de entrenamiento del sistema.
- En la carpeta Prueba están las imágenes que se utilizarán para la fase de prueba.

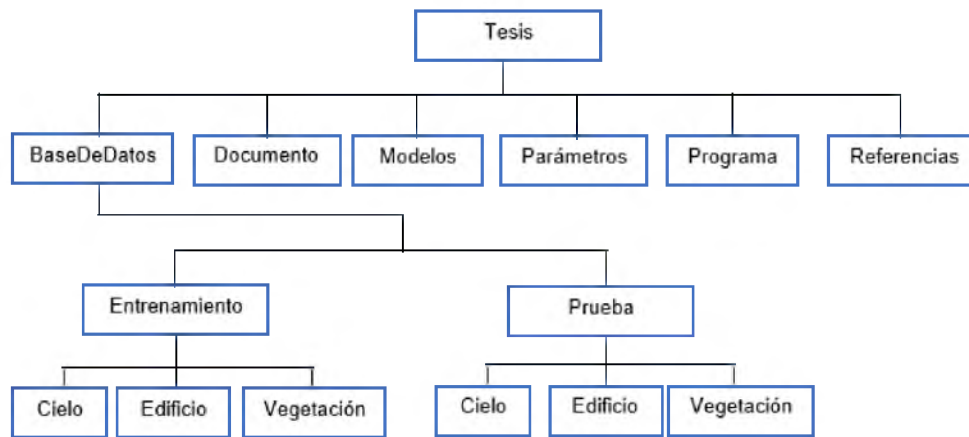


Figura 4.5: Estructura de la base de datos.

### 4.3. Parámetros que representan una imagen

#### 4.3.1. Parámetros seleccionados

Con base en la revisión del estado del arte expuesto en el capítulo 2 se seleccionaron los siguientes parámetros para representar el cielo, edificio y la vegetación:

- **Entropía:** este parámetro es de interés porque cuando los píxeles vecinos presentan un gran desorden entre ellos nos indica una textura rugosa, es decir, varios cambios de tonos de la vecindad. Cuando la vecindad tiene tonos de gris muy constantes la entropía es cero, por lo tanto nos ayudará a diferenciar entre las texturas que tenemos presentes (cielo, edificio y vegetación).
- **Contraste:** es un parámetro que mide los cambios en una imagen. Este parámetro resulta de interés debido a que nos ayuda a representar las variaciones de los tonos de gris en cada clase (cielo, edificio y vegetación).
- **Correlación:** este parámetro mide la relación entre las diferentes intensidades de los colores; nos interesa porque así notaremos la relación que existe entre el píxel de interés y sus vecinos con base a los niveles de intensidad de gris.

- **Uniformidad/Energía:** este parámetro disminuye o baja, cuando los valores de intensidad de los pixeles son diferentes en una región. Resulta de interés para las 3 clases puesto que presentan texturas diferentes.
- **Homogeneidad:** también es de interés debido a que este parámetro nos informa la irregularidad local de la textura, es decir, que tan constante son los valores de los pixeles vecinos, por lo tanto dará un valor bajo para zonas en las que los pixeles vecinos no es constante.
- **Gradiente:** Las derivadas de primer orden de una imagen digital están basadas en aproximaciones del gradiente 2-D. El gradiente de una imagen  $f(x, y)$  en un punto  $(x, y)$  se define como el vector

$$\nabla = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} \quad (4.1)$$

el cual apunta en la dirección de máxima tasa de cambio de  $f$  en las coordenadas  $(x, y)$  [7].

El gradiente se calcula con la operación de convolución a través de un filtro. Los valores altos son para áreas de la imagen con mucha pendiente y valores bajos para pendientes igual a cero.

#### 4.3.2. Cálculo de parámetros

En esta sección se describe el proceso para calcular los parámetros seleccionados. En el paso 4(b) se realizó el análisis con una ventana de 301 porque al calcular los parámetros contraste, correlación, energía, homogeneidad y el gradiente con ventanas de diferente tamaño, el valor que se generó para cada parámetro no se puede comparar con los generados en el modelo. Esto se debe a que los rangos en los que se encuentran los valores no son iguales, hay un problema de normalización.

Es necesario mencionar que el análisis se lleva a cabo con ventanas de diferentes tamaños. Con cada uno de estos tamaños se barre toda la imagen. Posteriormente se define una imagen mayor y de nuevo se realiza el proceso al barrer la imagen con esta última ventana. Esto se lleva a cabo hasta que el tamaño de la ventana cubre un cuarto del tamaño original de la imagen. La ventana más pequeña solo cubre un 10 % de un cuarto de la imagen; la ventana siguiente se obtiene aumentado en 10 píxeles a la anterior, Figura 4.6.

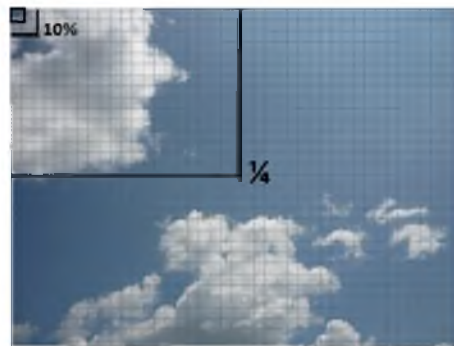


Figura 4.6: Representación de los tamaños de ventanas.

En la Figura 4.7 se muestran los resultados para los parámetros con los diferentes tamaños de ventanas mencionados en el párrafo anterior. Como se podrá observar, entre más grande es la ventana, los valores decrecen, Figura 4.7 inciso (a)(c)(e) y en otros los valores aumentan, inciso (b) y (d). Con base en los resultados se seleccionó la ventana de 301 porque a partir de esa ventana se muestran cambios de una clase a otra.

El proceso que se realizó para calcular los parámetros es el siguiente:

1. El programa lee la imagen y la carga en memoria.
2. La imagen se convierte a escala de grises.
3. Ecuilizar la imagen, es decir, extender todo el rango de niveles de gris en la imagen.

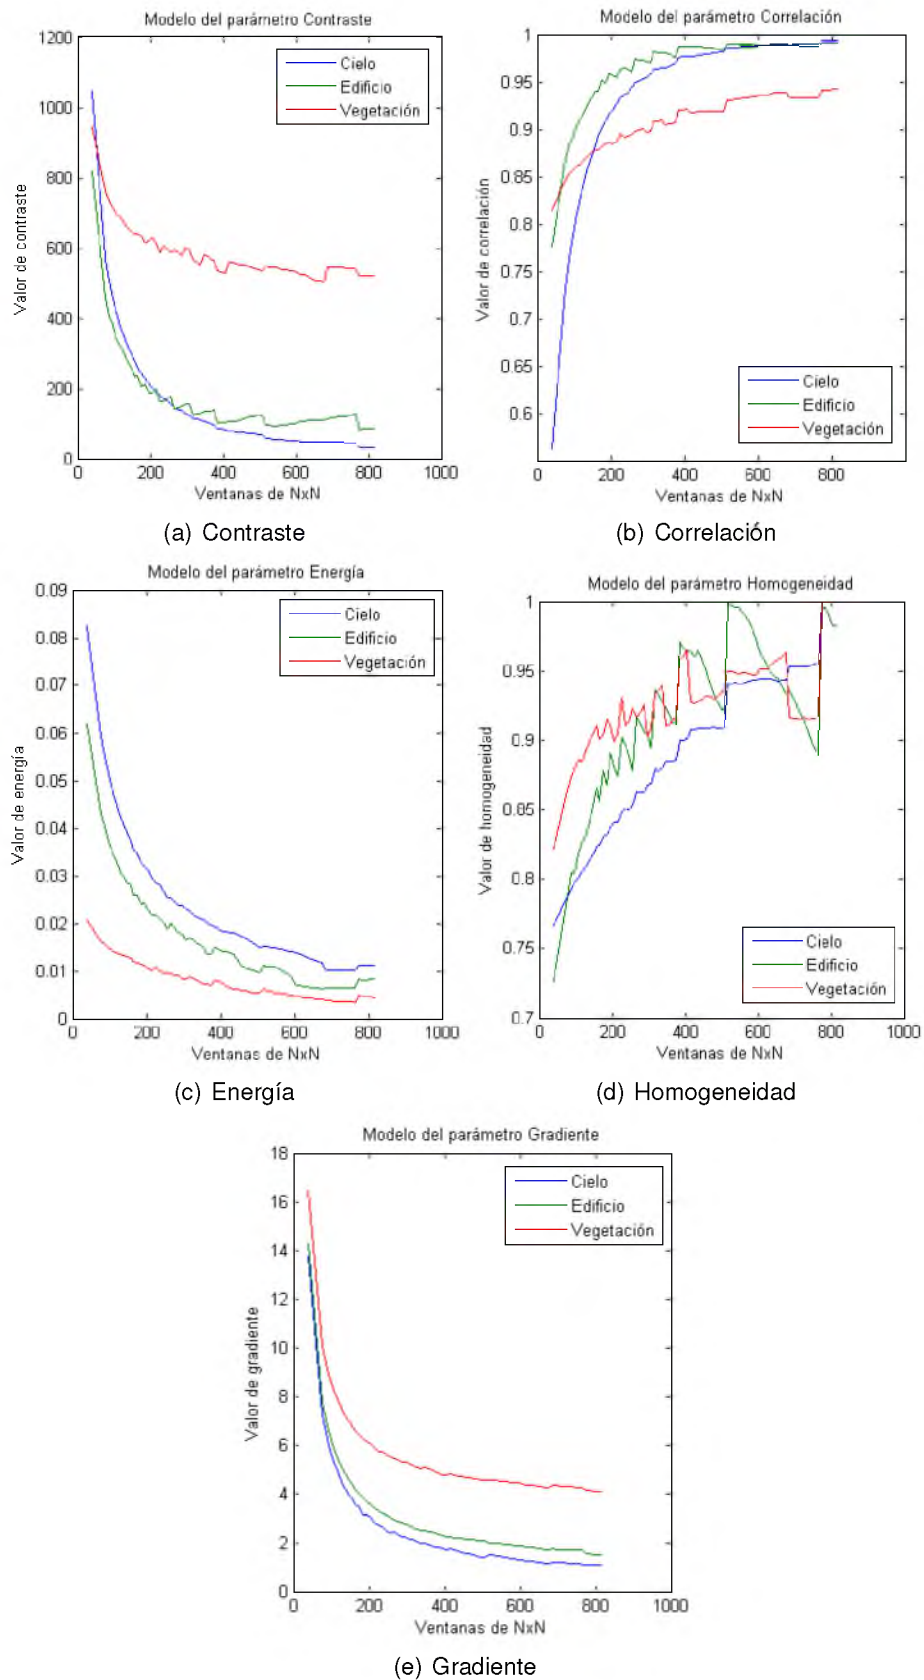


Figura 4.7: Modelo de los parámetros con ventanas de tamaño  $N \times N$ .

4. Se procede a calcular los parámetros entropía, contraste, correlación, energía, homogeneidad y gradiente de la imagen.

a) La forma de calcular la entropía para obtener las texturas presentes en la imagen se describe en el estado del arte sección 2.3.

$$H = - \sum_i p_i \log p_i$$

Para representar numéricamente la entropía de la imagen en un solo vector, se tomó cada columna por separado y se concatenaron. El valor final que representa la entropía de la imagen es la media del vector concatenado.

b) Los parámetros contraste, correlación, energía y homogeneidad se calculan a partir de la matriz de co-ocurrencia con 255 niveles de codificación para tomar en cuenta todos los valores en la imagen. Se eligió una distancia igual a 1 (número de operaciones para realizar todas las combinaciones).

c) Para el gradiente se realizó una convolución con un filtro de 3x3 (Tabla 4.1), el resultado para el pixel de referencia se redondeó hacia abajo.

Para representar el gradiente de la imagen se realizó el mismo cálculo de la entropía.

-1	-1	-1
-1	0	1
1	1	1

Tabla 4.1: Filtro de 3x3.

El resto de los parámetros se calculan como se citan en la sección 2.2 en el capítulo 2. Por claridad se repiten las ecuaciones en esta sección:

$$\sum_{i,j=0}^{N-1} P_{i,j} (i - j)^2$$

*contraste*

$$\sum_{i,j=0}^{N-1} P_{i,j} \frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i \sigma_j)}}$$

*correlación*

$$\sum_{i,j=0}^{N-1} P_{i,j}^2$$

*Uniformidad*

$$\sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i - j)^2}$$

*Homogeinidad*

5. Una vez que se calcularon los parámetros de la imagen se guardan en un vector llamado "parametros" con dimensión de 6,  $R^6$ . Cada dimensión pertenece a cada uno de los parámetros (entropía, contraste, correlación, energía, homogeneidad y gradiente). En la Figura 4.8 se muestra el procedimiento que se realizó para obtener los parámetros de cada clase.

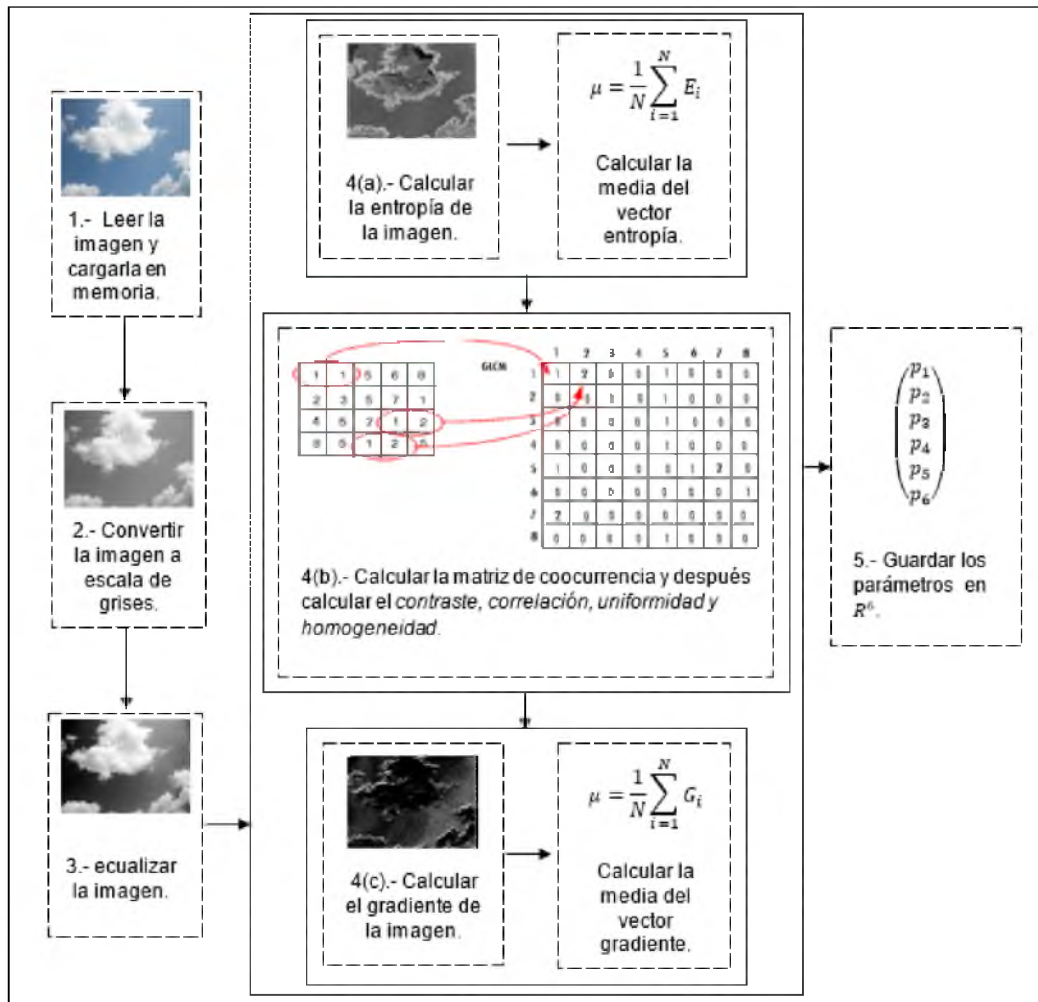


Figura 4.8: Proceso para el cálculo de parámetros.

Los resultados obtenidos en el cálculo de parámetros se muestran a continuación, únicamente se muestran los resultados para ocho imágenes de cada clase, dado que el espacio no es suficiente para mostrar todos:

**Clase cielo**

En la Tabla 4.2 se puede observar como la entropía muestra valores casi parecidos dentro del rango [0.3460,0.4029]. Para una imagen con mayor variación de niveles de gris la entropía aumenta (imagen 7). Los parámetros contraste, correlación, energía, homogeneidad y gradiente también se encuentran dentro de un rango diferente en cada parámetro.









								
Entropía	0.3682	0.3947	0.3460	0.3963	0.3460	0.3741	0.6785	0.4029
Contraste	102.3543	69.5114	71.6148	76.7384	71.6148	61.3914	277.8161	104.5888
Correlación	0.9749	0.9804	0.9850	0.9741	0.9850	0.9828	0.9232	0.9684
Energía	0.0144	0.0116	0.0125	0.0117	0.0125	0.0124	0.0111	0.0136
Homogeneidad	0.4499	0.4511	0.4753	0.4294	0.4753	0.4769	0.3466	0.4503
Gradiente	1.9985	1.9449	1.7617	2.0243	1.7617	1.9190	2.5167	2.0273

Tabla 4.2: Parámetros clase cielo.

**Clase edificio**

En la Tabla 4.3 se puede observar como los valores de la entropía también se encuentra en un rango parecido y distintos al de la clase cielo. A pesar de tener una diferencia de valores de un parámetro a otro, el contraste entre el cielo y el edificio son muy parecidos. Para los otros parámetros si hay diferencia de una clase a otra. Cabe mencionar que aunque las imágenes se parezcan, se tomaron a distinta distancia, presentan cambios de iluminación, contraste, enfoque además de la presencia de sombra en las imágenes. Las imágenes contienen parte de otras clases por lo que la información es global.









								
Entropía	0.4862	0.4639	0.4775	0.5183	0.4937	0.4963	0.4872	0.5060
Contraste	128.5288	84.7961	91.9417	155.0544	93.6487	81.7409	117.3777	97.8657
Correlación	0.9596	0.9858	0.9841	0.9784	0.9861	0.9878	0.9806	0.9894
Energía	0.0128	0.0240	0.0230	0.0111	0.0138	0.0139	0.0099	0.0101
Homogeneidad	0.4647	0.5678	0.5613	0.4820	0.5273	0.5317	0.5078	0.4887
Gradiente	2.8044	2.4248	2.4699	2.8733	2.4825	2.4401	2.4705	2.6131

Tabla 4.3: Parámetros clase edificio.

**Clase vegetación**

La Tabla 4.4 pertenece a la clase vegetación. Se puede notar como la entropía muestra una notable diferencia de una clase a otra, al igual que los demás parámetros. En la clase vegetación también están contenidas otras clases y sin embargo los valores de esta textura son diferentes de la textura cielo y edificio. Es decir, esta textura presenta diferencias por las tonalidades y valores de pixeles no constantes.










									
Entropía	0.7823	0.8270	0.8270	0.8029	0.7546	0.8075	0.8292	0.8447	0.8447
Contraste	382.6761	327.4942	1354.5911	1540.8594	642.7209	639.9623	909.6468	1379.5364	1379.5364
Correlación	0.9393	0.9666	0.8257	0.8232	0.8831	0.8914	0.8474	0.7883	0.7883
Energía	0.0014	0.0004	0.0006	0.0007	0.0099	0.0019	0.0003	0.0004	0.0004
Homogeneidad	0.2172	0.2040	0.1450	0.1418	0.2530	0.2181	0.1474	0.1349	0.1349
Gradiente	5.1738	6.0586	7.4266	6.6642	4.8988	5.3067	6.4360	7.1743	7.1743

Tabla 4.4: Parámetros clase vegetación.

En resumen, por cada imagen se genera un vector de  $R^6$ , donde cada una de las dimensiones representa a cada parámetro de cada clase. En la Figura 4.9 se muestra el resultado para dos parámetros (entropía y energía) pertenecientes a cada clase. Posteriormente, cada imagen genera un vector como el ya mencionado. Este conjunto de vectores se utilizara para generar los modelos como se explica en la siguiente sección.

**4.3.3. Análisis de datos**

Uno de los problemas que presenta la clasificación de imágenes mediante información o variables de textura es la presencia de errores significativos en las zonas frontera entre clases, debido precisamente a que el valor de cada pixel depende de la distribución de valores de su vecindario [20]. Con base en este problema de clasificación se selecciona la información de las imágenes para reducir el contenido de otras clases, Figura 4.10. De esta manera se tendrá una mejor representación en la base del conocimiento.

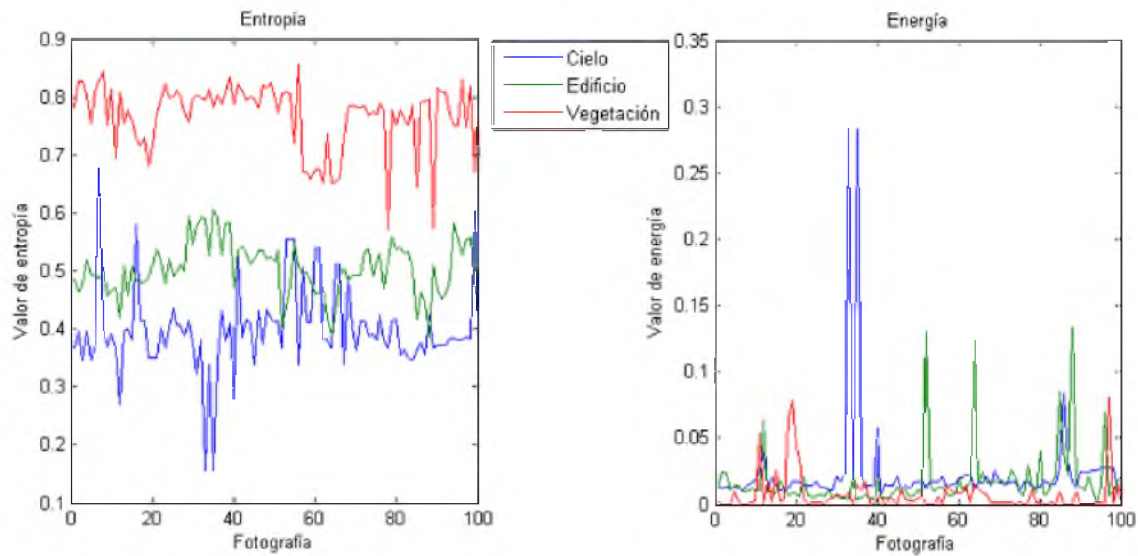


Figura 4.9: Representación de datos calculados Entropía y Energía.



Figura 4.10: Ejemplo de imágenes recortadas.

#### 4.3.4. Cálculo de los modelos

El cálculo de los modelos se realiza a partir de los parámetros calculados en la sección 4.3.2 y servirán para representar cada clase (cielo, edificio y vegetación). Para representar estos parámetros se utiliza una distribución Gaussiana. Por lo tanto, es necesario calcular la media  $\mu$  y la varianza  $\sigma^2$  de cada clase. A continuación se describe el proceso realizado.

1. Se leen los parámetros y se cargan en memoria.
2. Se calcula el promedio de los valores de los parámetros.

$$\mu = \frac{1}{N} \sum_{i=1}^N P_i$$

3. Se calcula la varianza de los valores de los parámetros.

$$\sigma^2 = \frac{1}{N-1} \sum_{i=1}^n (P_i - \mu)^2$$

4. Ya calculada la media y la varianza, se guardan en un vector llamado "modelo" con dimensión 12,  $R^{12}$ , este vector guarda la media y varianza de cada parámetro por clase. En la Figura 4.11 se muestra el procedimiento que se realizó para obtener el modelo de cada clase.




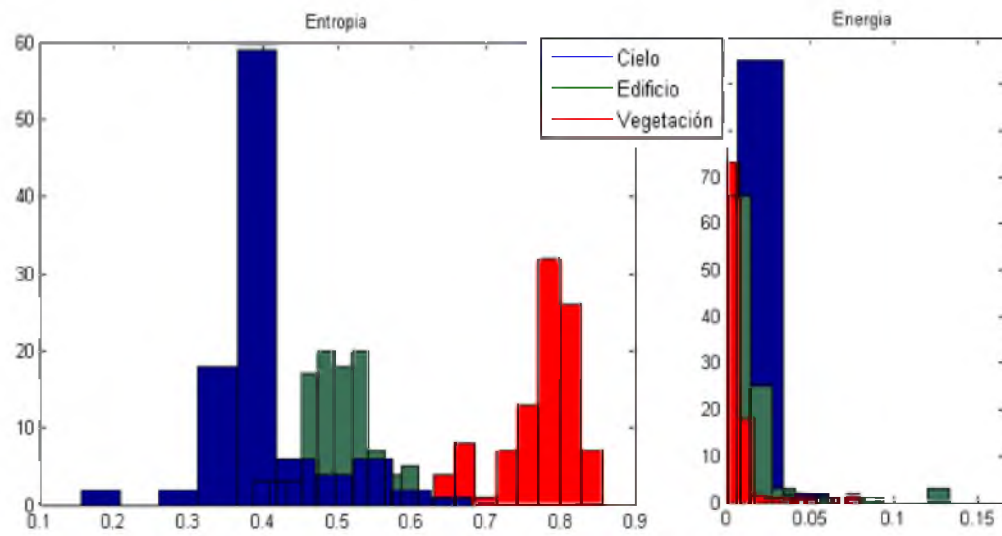
Figura 4.11: Proceso para el cálculo del modelo de cada clase.

Realizado el cálculo de los parámetros de los modelos con base en la información procesada, los resultados muestran diferencias de una clase a otra, ver Tabla 4.5. Con base a los cálculos la gaussiana para la entropía y la energía se representa en la Figura 4.12.

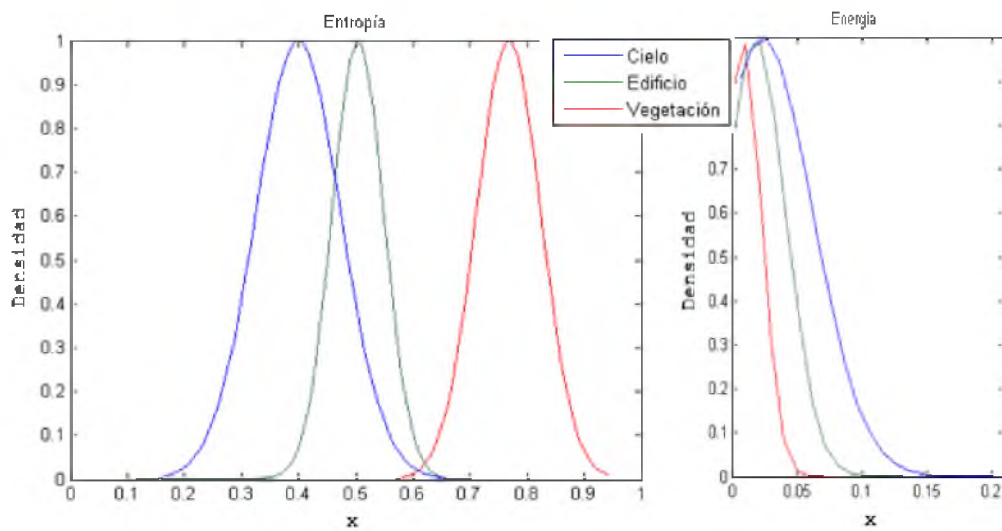
	Parámetro	Modelo		
		Cielo	Edificio	Vegetación
Media	Entropía	0.3993	0.5037	0.7676
	Contraste	127.3486	141.7589	610.4840
	Correlación	0.9564	0.9765	0.8969
	Energía	0.0235	0.0178	0.0076
	homogeneidad	0.4605	0.4865	0.2126
	Gradiente	2.1860	2.7969	5.3508
Varianza	Entropía	0.0056	0.0020	0.0032
	Contraste	3859.7055	3968.0273	69190.2054
	Correlación	0.0008	0.0002	0.0017
	Energía	0.0015	0.0005	0.0002
	homogeneidad	0.0040	0.0045	0.0020
	Gradiente	0.0458	0.1040	0.4408

Tabla 4.5: Resultado de los modelos.

El parámetro energía se descartará porque no presenta mucha diferencia de una clase a otra, es decir se encuentran en el mismo rango de valores, ver Figura 4.9 y 4.12.



(a) Histograma en base a los datos procesados, entropía-energía.



(b) Gaussiana en base al cálculo de los modelos, entropía-energía.

Figura 4.12: Gaussiana de cada clase para la Entropía y Energía.

## Capítulo 5

# Clasificación de objetos

De acuerdo a lo obtenido en la sección 4.3.2 y 4.3.4, los resultados del cálculo pueden ser modelados como Gaussianas (Figura 4.12); donde cada Gaussiana representa cada clase (cielo, edificio y vegetación) para cada parámetro. Los datos serán modelados de esta forma porque es la manera más sencilla para una distribución de datos (teorema del límite central [6]).

A partir de las Gaussianas que representan a cada clase se calcularon umbrales de decisión para determinar a qué clase pertenecen los píxeles presentes en la imagen y de esta manera llevar a cabo la clasificación. Los umbrales se calculan con la ecuación 5.1, donde la media es obtenida por los modelos generados con el programa en la sección 4.3.4. Es importante mencionar que se hizo la suposición  $\sigma_1 = \sigma_2$  basados en los resultados mostrados en el Tabla 4.5. De esta tabla es fácil ver que las varianzas no son tan importantes debido a que el valor es muy pequeño si se compara con las medias. Los cálculos se realizan en pares, es decir, para 2 medias de distinta clase.

$$\begin{aligned}
\frac{1}{\sqrt{2\pi}} e^{-\frac{(x-\mu_1)^2}{2\sigma^2}} &= \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-\mu_2)^2}{2\sigma^2}} \\
2\sigma^2 \left( -\frac{(x-\mu_1)^2}{2\sigma^2} \right) &= \left( -\frac{(x-\mu_2)^2}{2\sigma^2} \right) 2\sigma^2 \\
-(x-\mu_1)^2 &= -(x-\mu_2)^2 \\
-(x^2 - 2x\mu_1 + \mu_1^2) &= -(x^2 - 2x\mu_2 + \mu_2^2) \\
-x^2 + 2x\mu_1 - \mu_1^2 &= -x^2 + 2x\mu_2 - \mu_2^2 \\
\mu_2^2 - \mu_1^2 &= \cancel{x^2} + 2x\mu_2 - \cancel{x^2} - 2x\mu_1 \\
\mu_2^2 - \mu_1^2 &= 2x\mu_2 - 2x\mu_1 \\
\mu_2^2 - \mu_1^2 &= 2x(\mu_2 - \mu_1) \\
\frac{\mu_2^2 - \mu_1^2}{\mu_2 - \mu_1} &= 2x \\
\frac{1}{2} \left( \frac{\mu_2^2 - \mu_1^2}{\mu_2 - \mu_1} \right) &= x
\end{aligned} \tag{5.1}$$

Donde:

$x$ : Representa el umbral de decisión entre las dos clases.

$\mu_1$ : es la media de una de las clases.

$\mu_2$ : es la segunda media del par de clases para el cálculo.

Con esta suposición los cálculos se reducen y es más rápida la toma de decisiones entre los píxeles pertenecientes a cada clase. El umbral es sólo función de las medias para determinar a qué clase pertenecen los valores de píxeles.

## 5.1. Clasificación con un parámetro

La clasificación se lleva a cabo con el parámetro entropía. A partir de las medias del modelo Gaussiano propuesto para este parámetro se calcula el umbral para decidir la textura de cada

clase presente en la imagen: ya sea textura del cielo, edificio o vegetación. Es decir, con ayuda de los umbrales se realiza la segmentación de la imagen. Una vez segmentada la imagen se procede a aplicar operaciones morfológicas (erosión, dilatación y cerradura) con el fin de que cada componente de la imagen sea más compacto y posteriormente se reduce el ruido en la imagen procesada para disminuir los píxeles mal clasificados. En la Figura 5.1 se muestra el diagrama de flujo que representa el proceso realizado.

1. El programa lee la imagen y la carga en memoria.
2. La imagen se convierte a escala de grises.
3. Se ecualiza la imagen.
4. Se calcula la entropía de la imagen.
5. Binarizar la imagen con el umbral calculado entre la clase cielo y vegetación.
6. Aplicar cerradura a la imagen.
7. Rellenar las áreas internas de la imagen.
8. Crear una copia de la imagen en escala de grises y sobreponer los píxeles negros de la imagen binarizada.
9. Calcular la entropía a la copia de la imagen en escala de grises.
10. Binarizar la imagen con un umbral definido por la media de la clase edificio y vegetación.
11. Aplicar cerradura a la imagen.
12. Rellena las áreas internas de la imagen.
13. Con la imagen binarizada en el paso 6 y la imagen binarizada en el paso 11 se procede a realizar la operación lógica AND entre las dos imágenes.

14. Utilizar la copia de la imagen creada en el paso 7 y sobreponer los pixeles negros de la imagen generado en el paso 12.
15. A la imagen del paso 13 se le aplica un filtro para reducir el ruido de la imagen con una ventana de 151.

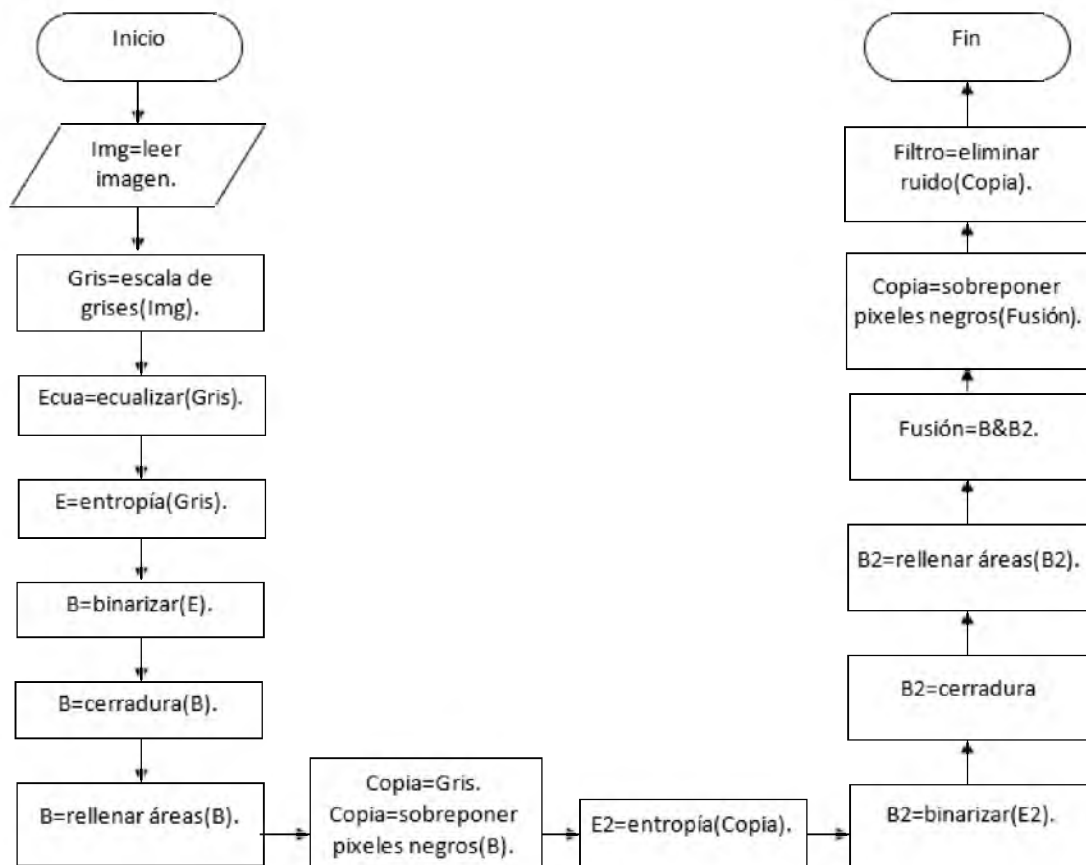


Figura 5.1: Diagrama de flujo para la clasificación con el parámetro entropía.

## 5.2. Análisis de datos

En el paso 4 se calculó el umbral entre el cielo y vegetación porque al calcularlo entre el cielo y edificio el umbral de decisión reconocía las imágenes con nubes como parte del edificio. Esta clasificación errónea se debe a que la entropía de los píxeles del edificio es muy parecida a la correspondiente de las nubes. Por ejemplo, la entropía para los píxeles del cielo en ciertas áreas se encuentra entre 0.46 y 0.50 y conforme al modelo calculado en la sección 4.3.4 estos valores se encuentran en un rango que pertenece al edificio. El umbral calculado fue de 0.4222 para el cielo y edificio. Al calcular el umbral entre cielo y vegetación el resultado fue de 0.5427.

Los resultados al utilizar los umbrales mencionados en el párrafo anterior y después de haber aplicado la cerradura y rellenar las áreas internas de las imágenes binarizadas se muestran en la Figura 5.2.




Figura 5.2: Resultados de aplicar el umbral cielo-edificio y cielo-vegetación.

En la Figura 5.3 se muestran los resultados para una imagen con el cielo más homogéneo, donde aparentemente no hay diferencia en el resultado utilizando ambos umbrales. Hay una diferencia de píxeles clasificados dependiendo del umbral utilizado; en apariencia no son notables, sin embargo, al contar los píxeles clasificados se puede ver que hay una diferencia de 982 Píxeles.



Figura 5.3: Resultado de aplicar el umbral cielo-edificio y cielo-vegetación a una imagen homogénea.

En el paso 9, se calculó el umbral con la vegetación y el edificio por que los valores entre estas dos clases son mayores en valor a las de la clase cielo y entre ellas sus medias son más cercanas. Los resultados se muestran en la Figura 5.4. Como se podrá notar en la imagen calculada con la entropía, los bordes del edificio tienen semejanza con la clase vegetación. Se aplicó la cerradura y se rellenaron las áreas internas para eliminar un poco de píxeles mal clasificados.




Figura 5.4: Resultado de aplicar el umbral edificio-vegetación para extraer la clase vegetación (b).

### 5.3. Filtro para reducir el "ruido"

La fusión de la clase cielo y vegetación da como resultado la clase sobrante, es decir, el edificio. El resultado de "unir" las dos clases se obtiene de aplicar una operación lógica AND (dado que las imágenes son binarias). En la Figura 5.5(c) se muestra el resultado de la unión.




Figura 5.5: Resultado de la fusión de la clase cielo y vegetación (c).

La imagen obtenida de la fusión de las clases se filtro usando una ventana de  $151 \times 151$ . Esta ventana fue la que proporcionó menos error en la clasificación final (ver Tabla 5.1). La operación que se realiza para reducir el ruido en la imagen es la mediana, se aplica para evitar valores de pixeles no existentes en la imagen original. Los tamaños de las ventanas utilizadas para el filtrado de la imagen se muestran en la siguiente tabla:

Tamaño de ventana	Pixeles bien clasificados	Pixeles mal clasificados
17	92.93 %	5.98 %
21	92.98 %	5.57 %
31	92.81 %	4.78 %
37	93.51 %	4.81 %
41	93.55 %	4.81 %
61	93.90 %	4.27 %
71	94.65 %	4.27 %
101	95.40 %	4.25 %
151	96.39 %	4.15 %
181	96.80 %	4.53 %

Tabla 5.1: Resultado al aplicar ventanas de  $N \times N$  para el filtrado de la imagen.

Para calcular el porcentaje de pixeles bien clasificados y los mal clasificados, fue necesario clasificar los pixeles de una imagen de forma manual, Figura 5.6.



Figura 5.6: clasificación manual: el área blanca representa el objeto de interés (edificio).

Las imágenes cuyos resultados se expresan en la Tabla 5.2 son las que se muestran en la Figura 5.7. Como se observa al analizar la imagen con distintos tamaños de ventanas la reducción de "ruido" ayuda a obtener una mejor clasificación. También se puede observar que al procesar la imagen con la ventana más grande (181) la información contenida en los píxeles se modifica de manera evidente, aumentando también el error en los píxeles clasificados.




Figura 5.7: Resultados de ventanas analizadas.

## 5.4. Clasificación basada en la fusión de información

En esta sección se describe el proceso para clasificar los píxeles de acuerdo a los parámetros gradiente y los calculados a partir de la matriz de co-ocurrencia (contraste, correlación y homogeneidad).

Esta clasificación básicamente se encarga de determinar a que clase pertenece el píxel central de la ventana de análisis. Para clasificar este píxel se utilizará la ventana de 301x301 y de acuerdo a los modelos de cada parámetro se asignará tal píxel a la clase correspondiente.

El proceso realizado es el siguiente:

1. Cargar los umbrales de decisión de los parámetros para cada clase previamente calculados en la fase de aprendizaje.
2. Leer la imagen y cargarla en memoria.
3. Convertir la imagen a escala de grises.
4. Ecuilizar la imagen.
5. Calcular los parámetros seleccionados.
6. Decidir a qué clase pertenece el píxel en cada parámetro basado en los umbrales calculados para cada parámetro.
7. Seleccionar la clase correspondiente a los umbrales de cada parámetro.
8. Clasificar el píxel fusionando la información de todos los parámetros.

En la Figura 5.8 se muestra el diagrama de flujo para clasificar el píxel que permitirá realizar la segmentación y detección del objeto deseado.

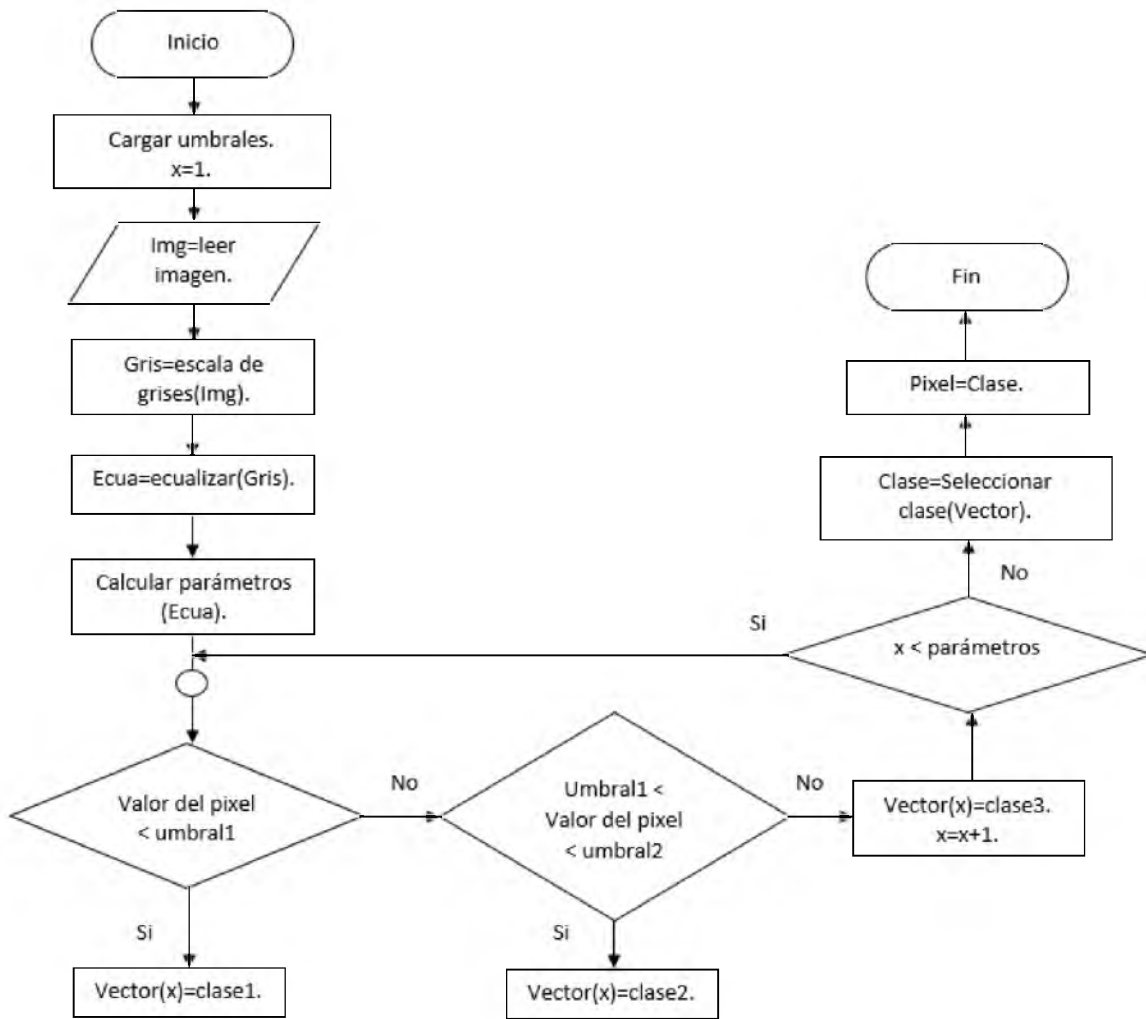


Figura 5.8: Diagrama de flujo para la clasificación basada en la fusión de información.

Los umbrales utilizados en el paso 1 y en el paso 6 fueron calculados con la ecuación 5.1. Esto se llevó a cabo para cada parámetro de acuerdo al modelo generado en la sección 4.3.4. Los umbrales que determinan a que clase pertenece el pixel se muestran en la Tabla 5.2, en la Figura 5.9 se representan los umbrales para el contraste y el gradiente. Las reglas generadas para cada parámetro son las siguientes:

Parámetro	Umbral1	Umbral2
Entropía	0.4515	0.6356
Contraste	134.5537	376.1215
Correlación	0.9266	0.9664
Homogeneidad	0.3365	0.4735
Gradiente	2.4914	4.0738

Tabla 5.2: Umbral para cada parámetro.

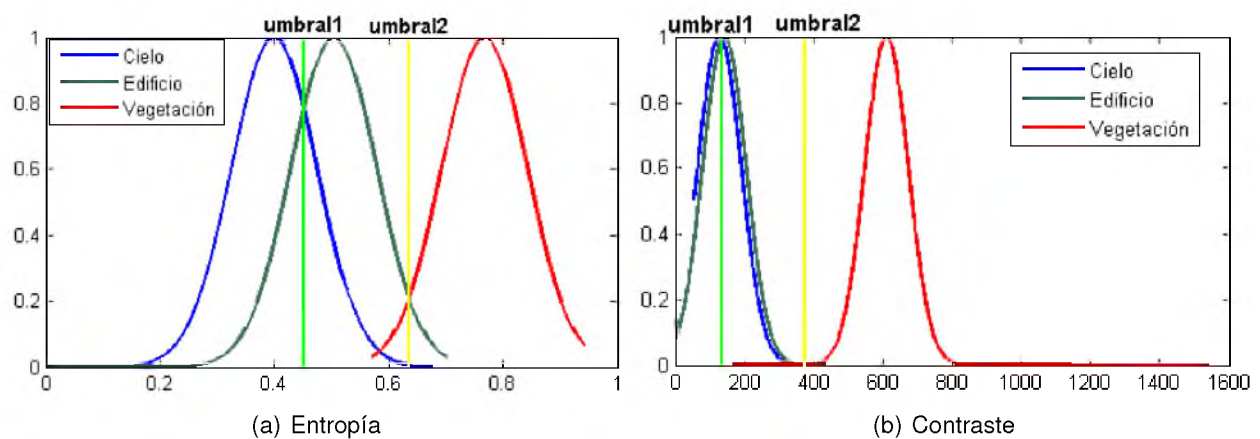


Figura 5.9: Representación de los umbrales de decisión.

### Entropía

- Si la entropía del pixel es menor que el umbral1 entonces el pixel pertenece a la clase cielo.
- Si la entropía del pixel es mayor que el umbral1 y menor que el umbral2 entonces el pixel pertenece a la clase edificio.
- Si la entropía del pixel es mayor que el umbral2 entonces el pixel pertenece a la clase vegetación.

### Contraste

- Si el contraste del pixel es menor que el umbral1 entonces el pixel pertenece a la clase cielo.
- Si el contraste del pixel es mayor que el umbral1 y menor que el umbral2 entonces el pixel

pertenece a la clase edificio.

- Si el contraste del pixel es mayor que el umbral2 entonces el pixel pertenece a la clase vegetación.

### **Correlación**

- Si la correlación del pixel es menor que el umbral1 entonces el pixel pertenece a la clase vegetación.
- Si la correlación del pixel es mayor que el umbral1 y menor que el umbral2 entonces el pixel pertenece a la clase cielo.
- Si la correlación del pixel es mayor que el umbral2 entonces el pixel pertenece a la clase edificio.

### **Homogeneidad**

- Si la homogeneidad del pixel es menor que el umbral1 entonces el pixel pertenece a la clase vegetación.
- Si la homogeneidad del pixel es mayor que el umbral1 y menor que el umbral2 entonces el pixel pertenece a la clase cielo.
- Si la homogeneidad del pixel es mayor que el umbral2 entonces el pixel pertenece a la clase edificio.

### **Gradiente**

- Si el gradiente del pixel es menor que el umbral1 entonces el pixel pertenece a la clase cielo.
- Si el gradiente del pixel es mayor que el umbral1 y menor que el umbral2 entonces el pixel pertenece a la clase edificio.
- Si el gradiente del pixel es mayor que el umbral2 entonces el pixel pertenece a la clase vegetación.

## 5.5. Fusión de clasificadores (alto nivel)

La fusión de información se encarga de "mezclar" datos de diferentes fuentes de información y a partir de tal mezcla se intenta mejorar el desempeño de cada una de las fuentes por separado. La fusión se puede hacer a diferentes niveles; se puede fusionar sólo los parámetros de cada fuente (fusión a bajo nivel), también se pueden fusionar las decisiones generadas al final del proceso (fusión a alto nivel) o inclusive se pueden mezclar de manera intermedia a través de modelos 4.3.2. En este trabajo se utiliza la fusión a alto nivel de la siguiente manera, para decidir la pertenencia de cada pixel a una de las clases (cielo, edificio y vegetación) se necesitan tres etapas:

1. Transformar las medidas (parámetros) de tal manera que se combinen; es decir, se necesita normalizarlos. Esta etapa es la primera parte de la modelización del problema en el que se tiene que elegir un marco teórico con propiedades aceptables para nuestro problema, y dentro de este marco una representación conveniente de los datos (por ejemplo, dentro de la teoría de probabilidades se modela la señal como un proceso de Markov Gaussiano) [13].  
En este trabajo, esta etapa se realiza la normalización de los parámetros contraste, correlación, homogeneidad y gradiente. La normalización se realizó para poder representar los parámetros mencionados y unirlos con el parámetro entropía.
2. Combinar los datos para ser transformados de acuerdo con las reglas permitidas para el marco teórico elegido (por ejemplo la regla de Bayes) [13].  
En la etapa 2 la combinación de los parámetros: entropía, contraste, correlación, homogeneidad y gradiente se comportan como una distribución gaussiana según el análisis de los datos, sección 4.3.2. Las reglas generadas para los parámetros ayudarán en la decisión del pixel.
3. A partir de la combinación resultante se toma una decisión de acuerdo con el modelo y en las características del problema. Una vez más, muchas reglas son posibles (por ejemplo, se puede preferir el máximo a posteriori, o el máximo de verosimilitud) [13]. De acuerdo a la etapa 1 y

2 la decisión se realizará seleccionando la clase que más se repite en la toma de decisión de cada parámetro.

En la Figura 5.10 se muestran las etapas correspondientes para llevar a cabo la clasificación.

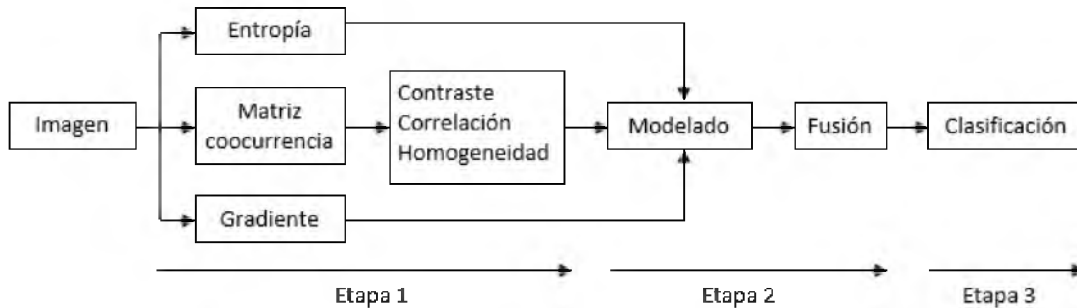


Figura 5.10: Etapas de la fusión.

Para seleccionar la clase final a la que pertenece el pixel se asignó un peso a cada parámetro, es decir, se pondera según la importancia, el valor que tiene el parámetro para poder asignar el pixel a algunas de las clases, ecuación 5.2.

$$C = \{C_1, C_2, C_3, \dots, C_n\}$$

$$\tilde{C}_i = \alpha \tilde{C}_i^k + \beta \tilde{C}_i^j + \dots + \gamma \tilde{C}_i^l \quad (5.2)$$

Donde:

$\tilde{C}_i^k$ : representa la clase ( $i$ ) seleccionada por uno de los parámetros ( $k$ ).

$C$ : son las clases (cielo, edificio y vegetación).

$k, j, l$ : son los parámetros (entropía, contraste, correlación, homogeneidad y gradiente).

$\alpha, \beta, \gamma$ : pesos asignados a los parámetros.

El parámetro contraste, correlación, homogeneidad y gradiente tendrán un peso de uno. Se seleccionó este valor de acuerdo a que los resultados obtenidos muestran poca diferencia de una clase a otra. En cambio el parámetro entropía con base a los cálculos del modelo muestra un mejor desempeño 4.3.2. Es decir, la clasificación obtenida con este parámetro da mejores resultados, por lo que a este parámetro se le asignó un peso de tres. La razón por la que se asignó ese peso, es para poder seleccionar la clase cuando los parámetros se presenten en un caso donde los pesos sean iguales entre las clases o cause confusión en la selección. Por lo tanto, el parámetro entropía por tener el mayor peso seleccionará la clase, Figura 5.11.

Por ejemplo, como se muestra en la Figura 5.11, el parámetro entropía clasificó el pixel como parte del cielo, el parámetro contraste también clasificó el pixel como parte del cielo, la correlación clasificó el pixel como parte del edificio, la homogeneidad como vegetación y el gradiente como edificio. En base a esta clasificación el parámetro entropía y contraste muestran el mismo resultado, la correlación y el gradiente muestran el mismo resultado para una clase diferente a la entropía y contraste. Por lo tanto la entropía selecciona la clase final.

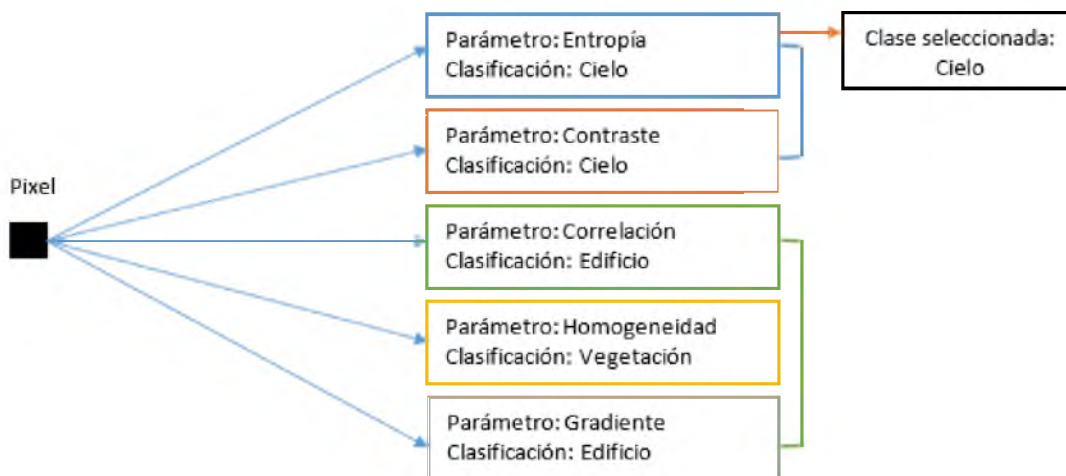


Figura 5.11: Representación de la selección del pixel.

## Capítulo 6

# Resultados

En esta sección se describen los resultados obtenidos a las dos pruebas realizadas en este trabajo de investigación. Una realizada con el parámetro entropía y la otra fusionando la información de los cuatro parámetros (entropía, contraste, homogeneidad y gradiente).

En la Figura 6.1 se muestra el resultado a los parámetros mencionados en la sección 4.3.2. Como se podrá observar los parámetros muestran diferencia de una clase a otra, en particular la clase vegetación siempre muestra diferencia con respecto a la clase cielo y a la clase edificio. De acuerdo a los parámetros seleccionados en la sección 4.3.1 la clase vegetación presenta mayor diferencia por las variaciones entre los pixeles vecinos, es decir, los valores de pixeles no son constantes como en la clase cielo y edificio. Como se mencionó la clase cielo y edificio presentan valores de pixeles vecinos más constantes, por lo que estas dos clases muestran mayor similitud. El parámetro energía, a pesar de haber sido calculada, no mostró un valor discriminante entre las clases por lo que no fue tomado en cuenta, inciso (d).

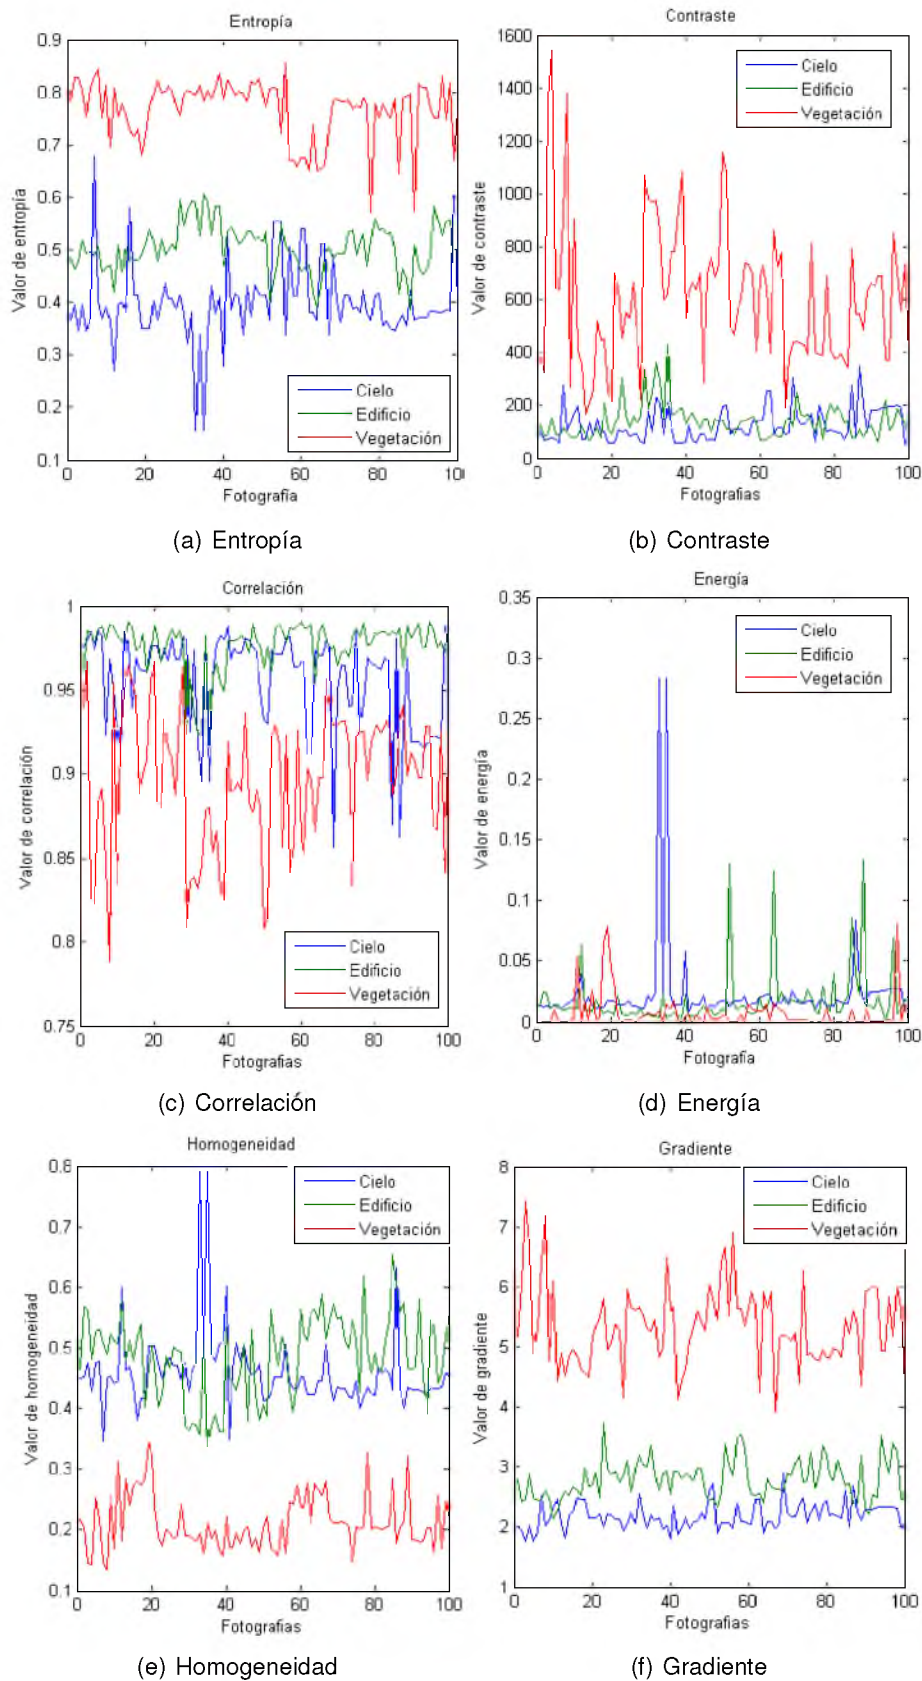


Figura 6.1: Parámetros calculados

Con base en los parámetros y los modelos de estos (sección 4.3.4) se realizó la primera prueba con el parámetro entropía. En la Figura 6.2 se muestra el resultado de aplicar el proceso realizado en la sección 5.1, donde la segmentación del edificio está representada por el área blanca.



(a) Imagen uno: original - resultado



(b) Imagen dos: original - resultado



(c) Imagen tres: original - resultado



(d) Imagen cuatro: original - resultado

Figura 6.2: Resultados de la prueba realizada con el parámetro entropía.

En la segunda prueba se aplicó la fusión de clasificadores (entropía, contraste, correlación, homogeneidad y gradiente). La fusión se llevó a cabo con los resultados de la entropía (calculado a partir de la imagen), contraste, correlación, homogeneidad y gradiente (procesados con la ventana de 301, sección 5.4). No se aplicó ningún filtro para eliminar el ruido y tampoco se aplicaron operaciones morfológicas como en la prueba realizada para un parámetro, por lo tanto la fusión es solo el resultado de las clasificaciones parciales, realizadas con cada parámetro.

Los resultados obtenidos en la segunda prueba con los pesos asignados en la sección 5.4 se muestran en la Figura 6.3. Como se podrá observar los bordes del edificio se notan pero la clasificación no es muy clara, debido a que se encuentran presentes las 3 clases en el área del edificio de manera dispersa.

La franja color negro que se observa alrededor de la imagen se debe a los problemas de bordes causados por utilizar una ventana de 301, donde 150 píxeles son los que se quedan sin resultado. La clase cielo es representada por el color gris fuerte, la clase edificio por el gris claro y la clase vegetación por el color blanco.




Figura 6.3: Resultados de la prueba dos al aplicar una fusión de clasificadores.

Dado que los resultados mostrados anteriormente tienen presente las tres clases (cielo, edificio y vegetación) de manera dispersa en el objeto de interés (edificio), se procedió a analizar los resultados de los 5 parámetros (entropía, contraste, correlación, homogeneidad y el gradiente) y se seleccionaron visualmente los que indicarán mejor la ubicación del edificio.

Es necesario recordar que el objetivo de este trabajo fue determinar dónde se encuentra el edificio dentro de la imagen, por lo que la selección de los parámetros se realizó con base en un análisis visual y no a través de una medida basada en el cálculo de píxeles mal clasificados según la clasificación manual (Figura 5.6).

Llevar a cabo las clasificaciones manualmente de los píxeles en sus tres clases principales es una tarea muy ardua y tomaría demasiado tiempo. En la Figura 6.4 se muestran los resultados de clasificación para cada uno de los parámetros de una de las imágenes.

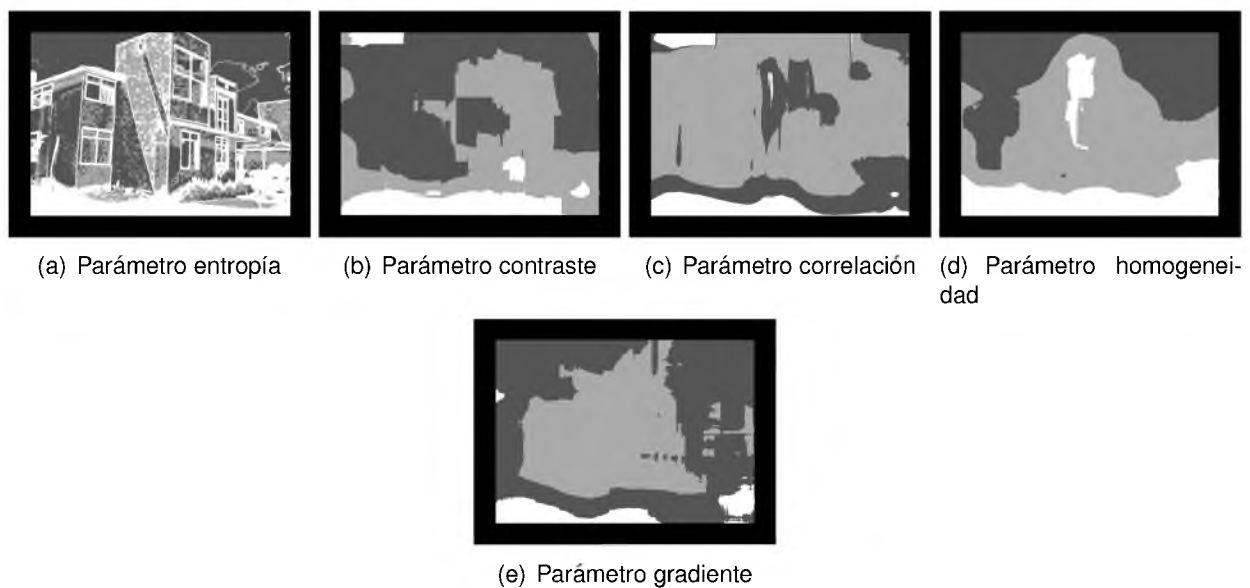



Figura 6.4: Clasificación de cada parámetro.

Los resultados que se muestran en la Figura 6.5 se obtuvieron realizando pruebas con los parámetros y variando los pesos principalmente a la homogeneidad y al gradiente (por ser los que visualmente detectan la ubicación del edificio). También se realizaron pruebas tomando en cuenta solo algunos parámetros, por ejemplo: la fusión con los parámetros entropía, homogeneidad y gradiente, la fusión con la entropía, correlación, homogeneidad y gradiente y la fusión con la entropía, contraste, homogeneidad y gradiente. Como se podrá observar las regiones de cada clase se mezclan menos entre ellas si se compara con los resultados mostrados en la Figura 6.3.



(a) Clasificación con los parámetros: entropía, homogeneidad y gradiente con mayor peso en la homogeneidad




(b) Clasificación con los parámetros: entropía, contraste, homogeneidad y gradiente con mayor peso en el gradiente



(c) Clasificación con los parámetros: entropía, correlación, homogeneidad y gradiente con mayor peso en el gradiente

Figura 6.5: Resultado de las pruebas realizadas variando los pesos y parámetros.

Los parámetros que se seleccionaron y que visualmente detectan mejor la ubicación del edificio son el contraste, homogeneidad y gradiente. Al fusionarlos con la entropía y reasignar los pesos (entropía peso de 1, contraste peso de 1, gradiente peso de 1 y homogeneidad peso de 3) se obtuvieron los resultados mostrados en la Figura 6.6.



(a) Imagen uno: fusión - resultado



(b) Imagen dos: fusión - resultado



(c) Imagen tres: fusión - resultado



(d) Imagen cuatro: fusión - resultado

Figura 6.6: Resultado final de la fusión de clasificadores.

## Capítulo 7

# Conclusiones

El procesamiento de imágenes no es tan sencillo como pudiera pensarse, por ejemplo las imágenes en este trabajo tienen muchas variaciones que dificultan la clasificación. Las imágenes mencionadas presentan sombras, unas son más claras que otras, se tiene la presencia de nubes en algunas imágenes e inclusive la luminosidad y la iluminación no son las mismas. Esto se debe en buena medida a que algunas fotografías fueron tomadas en días soleados y otras en días nublados y desde diferentes posiciones. Es decir, las fotografías no presentan las mismas características y sin embargo, la ubicación del edificio se pudo detectar.

Otras de las dificultades encontradas radican en la complejidad del procesamiento de la imagen y en la necesidad de una máquina con alto poder de cómputo. Esto último se debe al gran tamaño de la imagen a procesar y al tamaño de ventana seleccionado para analizar la misma, sección 4.3.2. Para reducir los cálculos y llevar acabo rápidamente, tal cual se deseaba, la toma de decisiones entre los pixeles pertenecientes a cada clase se aproximó cada modelo de cada clase a una distribución Gaussiana. Se crearon modelos sencillos utilizando el promedio de los parámetros seleccionados.

También se observó de manera clara que el uso de varios parámetros presenta mejor resultado que usar solo uno de ellos en la fusión realizada por la segunda prueba, sección 5.4. En la Figura 6.4, se puede observar como la clasificación realizada por cada parámetro proporciona diferente información de uno a otro. Por lo tanto, la fusión entre estos es mejor porque cada parámetro aporta información del objeto de interés que el utilizar sólo uno de estos.

En cuanto a las pruebas realizadas en este trabajo logran detectar la zona de interés; la primera utilizando la entropía y la segunda empleando todos los demás parámetros además de la entropía (contraste, correlación, homogeneidad y gradiente). A pesar de que en la primera prueba solo se utiliza un parámetro al final se realizan más procesos que en la prueba dos debido a las operaciones morfológicas dado que simplifican y conservan las características de forma de los objetos (edificio).

La segunda prueba, detecta la zona de interés aunque con mayor número de errores de clasificación en los bordes, esto se debe a que la textura entre el cielo y el edificio presentan regiones más constantes o parecidas que la vegetación al igual que las características mencionadas anteriormente. Considerando que se utilizan distribuciones Gaussinas para modelar las clases existen pixeles que por su valor se encontrarían dispersos en la región de decisión, el umbral, y muchos de ellos se clasifican como la clase opuesta. Sin embargo, la reasignación de pesos realizada durante la fusión de parámetros logró una mejoría perceptible en la clasificación.

Finalmente, los parámetros seleccionados ayudaron a detectar de mejor manera la ubicación del edificio presente en las imágenes. Los modelos y el sistema de inferencia ayudaron a decidir la pertenencia de los pixeles en las imágenes digitales. No se realizó una segmentación completa, que abarcara todo el edificio, puesto que el objetivo de este trabajo fue el de detectar la ubicación del edificio para poder ser utilizada en otras aplicaciones.

# Bibliografía

- [1] Ángel Ruiz Alonso. Comportamiento y análisis de descriptores de texturas en imágenes modis. Master's thesis, Facultad de informática, Universidad Complutense de Madrid, 2011.
- [2] Diana Avellaneda Avellaneda. Caracterización de texturas naturales. Master's thesis, Centro Nacional de Investigación y Desarrollo Tecnológico, 2009.
- [3] Maribel Johana Rodríguez Castillo. Sistema de inferencia difusa de mamdani. Technical report, Fundación Universitaria Konrad Lorenz, 2015.
- [4] Jorge Lira Chavéz. *Introducción al tratamiento digital de imágenes*. Fondo de cultura económica, 2002.
- [5] Grupo de Topología Computacional y Matemática Aplicada. Morfología. <http://alojamientos.us.es/gtocom/pid/tema5-1.pdf>, Noviembre 2015.
- [6] Carles Rovira Escofet. Teorema del límite central. <http://www.calidad.com.mx/articulos.php>, Enero 2016.
- [7] Verónica Facello, Mónica Larese, and Milton Spada. Detección de bordes por derivadas primera y segunda. <http://pdi-fich.wikidot.com/tpsaplicacion>, Noviembre 2015.
- [8] Roberto Galli, Amalia M. Pérez, Rosa Piotrkowski, and Fernando J. Peña. Corrección de artefactos en estudios de perfusión miocárdica en spect utilizando herramientas de procesamiento digital de imágenes e inteligencia artificial. Technical report, Escuela de Ciencia y Tecnología, Universidad Nacional de San Martín, 2008.
- [9] Mariela Azul González and Virginia Laura Ballarin. Segmentación de imágenes utilizando la transformada watershed: obtención de marcadores mediante lógica difusa. *IEEE LATIN AMERICA TRANSACTIONS*, 6(2):223–228, 2008.

- [10] Robert M. Haralick and K. Shanmugam. Textural features for image classification. *IEEE LATIN AMERICA TRANSACTIONS*, 6:610–621, 1973.
- [11] Simon Haykin. *Sistemas de comunicación*. Limusa Wiley, 2008.
- [12] Banco imágenes 360. Banco de imágenes. <http://bancoimagenes360.com/>, Noviembre 2015.
- [13] Henri Maitre and Isabelle Bloch. Image fusion. *Pergamon*, 41:329–335, 1997.
- [14] Department of Statistics Eberly College of Science. Prof. jia li. <http://sites.stat.psu.edu/jia-li/index.download.html>, Noviembre 2015.
- [15] Pasarlascanutas. [Pasarlascanutas.com](http://www.pasarlascanutas.com/). <http://www.pasarlascanutas.com/>, Noviembre 2015.
- [16] Rosanna Pérez Pueyo. *Procesado y Optimización de Espectros Raman mediante Técnicas de Lógica Difusa: Aplicación a la identificación de Materiales Pictóricos*. PhD thesis, Universitat Politècnica de Catalunya, 2004.
- [17] Rulequest Research. Data mining tools see5 and c5.0. <http://www.rulequest.com/see5-info.html>, Noviembre 2015.
- [18] José Ríos-Díaz, Jacinto Javier Martínez-Payá, and Ma. Elena del Baño Aledo. El análisis textural mediante las matrices de co-ocurrencia (glcm) sobre imagen ecográfica del tendón rotuliano es de utilidad para la detección cambios histológicos tras un entrenamiento con plataforma de vibración. *CCD*, 5:91–102, 2009.
- [19] Stuart Russell and Peter Norvig. *Inteligencia artificial un enfoque moderno*. Pearson educación, 2004.
- [20] Alfonso Fernández Sarría, Jorge Recio Recio, and Luis Angel Ruiz Fernández. Análisis de imágenes mediante texturas: aplicación a la clasificación de unidades de vegetación. *REVISTA INTERNACIONAL DE CIENCIA Y TECNOLOGÍA DE LA INFORMACIÓN GEOGRÁFICA*, 3:143–159, 2003.
- [21] Dra. Nora La Serna, Mg. Luzmila Pro Concepción, and Lic. Carlos Ya nez Durán. Compresión de imágenes: Fundamentos, técnicas y formatos. *Revista de Ingeniería de Sistemas e Informática*, 6:21–29, 2009.
- [22] Exelis Visual Information Solutions. Envi. <http://www.harrisgeospatial.com>, Noviembre 2015.

- [23] Milan Sonka, Vlacav Hlavac, and Roger Boyle. *Image processing, analysis and machine vision 2nd ed.* Thomson, 1998.
- [24] José Ramón Mejía Vilet. Apuntes de procesamiento digital de imágenes. Technical report, Universidad Autónoma de San Luis Potosí, 2005.