



UNIVERSIDAD NACIONAL AUTÓNOMA
DE MÉXICO

FACULTAD DE INGENIERÍA

“ANÁLISIS BAYESIANO PARA LA SEGMENTACIÓN
SEMISUPERVISADA DE IMÁGENES DE PERCEPCIÓN REMOTA”

TESIS

QUE PARA OBTENER EL TÍTULO DE:
INGENIERA EN TELECOMUNICACIONES
P R E S E N T A :
ARIANA DEL CARMEN MORENO BAUTISTA

DIRECTOR DE TESIS:
DR. MIGUEL MOCTEZUMA FLORES



MEXICO, D.F.,

JUNIO 2004



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

ESTA TESIS NO SALE
DE LA BIBLIOTECA

DEDICATORIA

A las personas que más quiero y que son lo más importante en mi vida, mis padres: Gloria Bautista Ortega y Raúl Moreno Rodríguez y mis hermanos: Raúl Moreno Bautista y Oscar A. Moreno Bautista, porque gracias a su apoyo, consejos y amor he cumplido una de mis mayores metas. Al Ingeniero Edgar Ulises Ledesma Rojas, por su comprensión, cariño y apoyo en todo momento. A Dios, por guiarme siempre en mi camino y a las personas que me enseñaron a amarlo: mi abuelita Carmen Rodríguez y mi maestra Carmelita Fuentes. A toda mi familia materna y paterna que siempre creyó en mí.

Ariana del Carmen Moreno Bautista

Autorizo a la Dirección General de Bibliotecas de la UNAM a difundir en formato electrónico e impreso el contenido de mi trabajo recepcional.

NOMBRE: Ariana del Carmen
Moreno Bautista

FECHA: 15/ Junio / 2004

FIRMA: 



AGRADECIMIENTOS

Agradezco a todas las personas que directa o indirectamente intervinieron en la realización de esta tesis.

Especialmente:

Al Doctor Miguel Moctezuma Flores, quien me brindó su apoyo y amistad.

A la Facultad de Ingeniería y a todos mis maestros por contribuir en mi formación profesional y personal.

A la Universidad Nacional Autónoma de México por ser mi segundo hogar y permitirme ser orgullosamente parte de su comunidad.

A todos mis verdaderos amigos por creer siempre en mí: Edgar, Jaime, Saraid, Eira y Araceli.





UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

FACULTAD DE INGENIERÍA

**“Análisis Bayesiano para la segmentación
semisupervisada de imágenes de percepción remota”**

Ariana del Carmen Moreno Bautista

Director de Tesis: Dr. Miguel Moctezuma Flores

Junio 2004



ÍNDICE GENERAL

	<i>PÁGINA</i>
RESUMEN	VIII
GLOSARIO	IX
1. INTRODUCCIÓN	1
1.1. <i>Objetivo</i>	1
1.1.1. <i>Antecedentes del tema</i>	1
1.1.2. <i>Definición del problema</i>	2
1.1.3. <i>Metodología empleada</i>	3
2. FUNDAMENTOS DE PERCEPCIÓN REMOTA	4
2.1. <i>Descripción General</i>	4
2.2. <i>Principios y fundamentos</i>	5
2.2.1. <i>Conceptos Fundamentales</i>	6
2.2.1.1. <i>Sensores Activos</i>	6
2.2.1.2. <i>Sensores Pasivos</i>	6
2.2.1.3. <i>Escala</i>	6
2.2.1.4. <i>Resolución</i>	6
2.2.1.5. <i>Contraste de imágenes</i>	7
2.2.1.6. <i>Marco del tiempo</i>	8
2.2.1.7. <i>Imágenes y mapas de percepción remota</i>	8
2.2.1.8. <i>Formatos de Productos</i>	8
2.2.2. <i>Agencia Espacial Europea</i>	9
2.2.3. <i>NASA</i>	11
2.3. <i>Aplicaciones</i>	15
2.3.1. <i>Evaluación de peligros naturales</i>	15
2.3.1.1. <i>Inundaciones</i>	16
2.3.1.2. <i>Huracanes</i>	17
2.3.1.3. <i>Terremotos</i>	18
2.3.1.4. <i>Erupciones volcánicas y peligros asociados</i>	19
2.3.1.5. <i>Deslizamientos de tierra</i>	21
2.3.1.6. <i>Desertificación</i>	23
2.3.2. <i>Fotografía aérea</i>	25
2.3.3. <i>Imágenes Multiespectrales</i>	27
2.3.4. <i>Imágenes SAR</i>	28
3. PRINCIPALES SATELITES DE PERCEPCION REMOTA	30
3.1. <i>ENVISAT</i>	30
3.2. <i>LANDSAT</i>	35
3.2.1. <i>ERTS-1, LANDSAT-2, LANDSAT-3</i>	35
3.2.2. <i>LANDSAT-4, LANDSAT-5</i>	37
3.2.3. <i>LANDSAT-6, LANDSAT-7</i>	37
3.3. <i>SPOT</i>	41
3.3.1. <i>SPOT-1, SPOT-2, SPOT-3</i>	43
3.3.2. <i>SPOT-4</i>	44



3.3.3. SPOT-5	45
3.4. IKONOS	48
4. ANÁLISIS BAYESIANO	51
4.1. Fundamentos	51
4.1.1. Probabilidad Condicional	51
4.1.2. Regla de multiplicación	51
4.1.3. Probabilidad total	52
4.1.4. Regla de Bayes	52
4.1.5. Funciones de pérdida	54
4.1.6. Criterio de Máxima Verosimilitud	56
4.1.7. Probabilidad de error	59
4.2. Distribuciones gaussianas	63
4.3. Función de segmentación óptima	65
4.4. Clase de rechazo	70
5. CAMPOS ALEATORIOS DE MARKOV	72
5.1. Sistemas de Vecinos y tipos de Cliques asociados	75
5.2. Campos Aleatorios de Markov y Distribución de Gibbs	79
5.2.1. Campos Aleatorios de Markov (CAM)	79
5.2.2. Distribución de Gibbs	80
5.3. Modelos de Campos Aleatorios de Markov	82
5.3.1. Auto-Modelos	82
5.3.2. Modelo Logístico Multinivel (MLL)	83
5.3.3. Ejemplo de Modelo CAM para segmentación de imágenes	85
6. ESQUEMA MIXTO DE SEGMENTACIÓN: ANÁLISIS BAYESIANO Y CAMPOS ALEATORIOS DE MARKOV	86
6.1. Segmentación con Análisis Bayesiano	87
6.2. Segmentación con Campos Aleatorios de Markov	89
6.2.1. Recocido Simulado (Simulated Annealing)	91
7. RESULTADOS DE SEGMENTACIÓN	95
7.1. Regiones urbanas del Distrito Federal	95
7.1.1. Segmentación con Análisis Bayesiano	95
7.1.1.1. Imagen DF1_PRI.RAW	95
7.1.1.2. Imagen DF1IZQ.RAW	97
7.1.1.3. Imagen DF3_512.RAW	99
7.1.2. Segmentación con Campos Aleatorios de Markov	101
7.1.2.1. Imagen DF1_PRI.RAW	101
7.1.2.2. Imagen DF1IZQ.RAW	109
7.1.2.3. Imagen DF3_512.RAW	117
8. CONCLUSIONES	125
9. BIBLIOGRAFÍA	128
APÉNDICES	131



ÍNDICE DE FIGURAS

	<i>PÁGINA</i>
2. FUNDAMENTOS DE PERCEPCIÓN REMOTA	4
Figura 2 – 1 Esquema operativo de un satélite de observación	4
Figura 2 – 2 Esquema de comportamiento de la energía	5
Figura 2 – 3 Comportamiento de la energía	6
Figura 2 – 4 Regiones espectrales comunes en percepción remota	7
Figura 2 – 5 Deep Space-1	12
Figura 2 – 6 Sonda miniatura de la misión Deep Space 2	13
Figura 2 – 7 Antes del tornado, 24/04/02	13
Figura 2 – 8 Después del tornado, 1/05/02	13
Figura 2 – 9 Concepto artístico del Satélite de la misión EO3	14
Figura 2 – 10 Conceptos artísticos de la misión ST5	14
Figura 2 – 11 Concepto artístico de la tecnología Sciencecraft	15
Figura 2 – 12 Concepto artístico de la tecnología Compass	15
Figura 2 – 13 Indicadores LANDSAT de llanuras de inundación	17
Figura 2 – 14 Ejemplo de Imagen multiespectral	28
3. PRINCIPALES SATÉLITES DE PERCEPCIÓN REMOTA	30
Figura 3 – 1 Satélite ENVISAT en órbita	30
Figura 3 – 2 Antena del Sistema DORIS del ENVISAT	31
Figura 3 – 3 Instrumentos del ENVISAT	32
Figura 3 – 4 Primera Imagen del ENVISAT	33
Figura 3 – 5 Mosaico del Mundo	34
Figura 3 – 6 Huracán Isabel	34
Figura 3 – 7 Bagdad, Irak	39
Figura 3 – 8 Ciudad de México	39
Figura 3 – 9 Cancún Quintana Roo, México	40
Figura 3 – 10 Ubicación orbital de los satélites del programa SPOT	41
Figura 3 – 11 Cronología de los satélites del programa SPOT	41
Figura 3 – 12 Modelo de los satélites SPOT 1,2 y 3	43
Figura 3 – 13 Modelo del satélite SPOT 4	44
Figura 3 – 14 Modelo del satélite SPOT 5	45
Figura 3 – 15 Paris, Francia	46
Figura 3 – 16 India	47
Figura 3 – 17 Toulouse, Francia	47
Figura 3 – 18 Monumento Jefferson, Estados Unidos	49
Figura 3 – 19 Roma, Italia	50
Figura 3 – 20 Beijing, China	50
4. ANÁLISIS BAYESIANO	51
Figura 4 – 1 Esquema ilustrativo de la probabilidad total	52
Figura 4 – 2 Probabilidad de error en el caso de dos clases	59
Figura 4 – 3 Ejemplo del histograma de una imagen comparado...	64
Figura 4 – 4 Ejemplo de Caso 1	69



5. CAMPOS ALEATORIOS DE MARKOV	72
Figura 5 – 1 Vecinos en una rejilla regular S	76
Figura 5 – 2 Cliques en una rejilla regular S	78
Figura 5 – 3 Tipos de cliques y parámetros potenciales asociados...	84
6. ESQUEMA MIXTO DE SEGMENTACIÓN: ANÁLISIS BAYESIANO Y CAMPOS ALEATORIOS DE MARKOV	86
Figura 6 – 1 Diagrama de segmentación mixta	86
Figura 6 – 2 Diagrama de bloques del proceso de Segmentación...	87
Figura 6 – 3 Términos de probabilidad condicional o conjunta	88
Figura 6 – 4 Términos de energía $U(X \omega_i)$	90
Figura 6 – 5 Algoritmo de recocido simulado	91
7. RESULTADOS DE SEGMENTACIÓN	95
Figura 7 – 1 Imagen Original DF1_PRI.RAW	95
Figura 7 – 2 Resultados de Análisis Bayesiano	96
Figura 7 – 3 Imagen Original DF1IZQ.RAW	97
Figura 7 – 4 Resultados de Análisis Bayesiano	98
Figura 7 – 5 Imagen Original DF3_512.RAW	99
Figura 7 – 6 Resultados de Análisis Bayesiano	100
Figura 7 – 7 Funciones de energía para DF1_PRI.RAW	101
Figura 7 – 8 Píxeles de rechazo clasificados con Markov	102
Figura 7 – 9 Histograma de la imagen anterior	102
Figura 7 – 10 Imagen con segmentación mixta	103
Figura 7 – 11 Histograma de la imagen anterior	103
Figura 7 – 12 20 Iteraciones	104
Figura 7 – 13 30 Iteraciones	105
Figura 7 – 14 40 Iteraciones	105
Figura 7 – 15 60 Iteraciones	106
Figura 7 – 16 80 Iteraciones	106
Figura 7 – 17 100 Iteraciones	107
Figura 7 – 18 Función de energía a posteriori	107
Figura 7 – 19 Comparación final	108
Figura 7 – 20 Funciones de energía para DF1IZQ.RAW	110
Figura 7 – 21 Píxeles de rechazo clasificados con Markov	110
Figura 7 – 22 Histograma de la imagen anterior	111
Figura 7 – 23 Imagen con segmentación mixta	111
Figura 7 – 24 Histograma de la imagen anterior	112
Figura 7 – 25 20 Iteraciones	112
Figura 7 – 26 30 Iteraciones	113
Figura 7 – 27 40 Iteraciones	113
Figura 7 – 28 60 Iteraciones	114
Figura 7 – 29 80 Iteraciones	114
Figura 7 – 30 100 Iteraciones	115
Figura 7 – 31 Función de energía a posteriori	115
Figura 7 – 32 Comparación final	116
Figura 7 – 33 Funciones de energía para DF3_512.RAW	117
Figura 7 – 34 Píxeles de rechazo clasificados con Markov	118
Figura 7 – 35 Histograma de la imagen anterior	118
Figura 7 – 36 Imagen con segmentación mixta	119



<i>Figura 7 – 37</i>	<i>Histograma de la imagen anterior</i>	<i>119</i>
<i>Figura 7 – 38</i>	<i>20 Iteraciones</i>	<i>120</i>
<i>Figura 7 – 39</i>	<i>30 Iteraciones</i>	<i>120</i>
<i>Figura 7 – 40</i>	<i>40 Iteraciones</i>	<i>121</i>
<i>Figura 7 – 41</i>	<i>60 Iteraciones</i>	<i>121</i>
<i>Figura 7 – 42</i>	<i>80 Iteraciones</i>	<i>122</i>
<i>Figura 7 – 43</i>	<i>100 Iteraciones</i>	<i>122</i>
<i>Figura 7 – 44</i>	<i>Función de energía a posteriori</i>	<i>123</i>
<i>Figura 7 – 45</i>	<i>Comparación final</i>	<i>124</i>



ÍNDICE DE TABLAS

	<i>PÁGINA</i>
3. PRINCIPALES SATÉLITES DE PERCEPCIÓN REMOTA	30
<i>Tabla 3 – 1 Serie LANDSAT</i>	<i>35</i>
<i>Tabla 3 – 2 Sistema RBV</i>	<i>36</i>
<i>Tabla 3 – 3 Sistema MSS</i>	<i>36</i>
<i>Tabla 3 – 4 Sistema TM</i>	<i>37</i>
<i>Tabla 3 – 5 Sistema ETM+</i>	<i>38</i>
<i>Tabla 3 – 6 Características del sensor HRV - SPOT</i>	<i>42</i>
<i>Tabla 3 – 7 Tabla cronológica del satélite IKONOS</i>	<i>48</i>
APÉNDICES	131
<i>Tabla A – 1 Evaluación de Peligros Naturales</i>	<i>131</i>
<i>Tabla B – 1 Instrumentos y sistemas que componen al ENVISAT</i>	<i>132</i>
<i>Tabla B – 2 Especificaciones Técnicas del ENVISAT</i>	<i>133</i>
<i>Tabla B – 3 Características técnicas del programa SPOT</i>	<i>134</i>
<i>Tabla B – 4 Instrumentos sensores de alta resolución...</i>	<i>135</i>
<i>Tabla B – 5 Instrumentos estereoscópicos de los satélites...</i>	<i>135</i>
<i>Tabla B – 6 Instrumentos sensores de alta resolución...</i>	<i>136</i>
<i>Tabla B – 7 Instrumentos estereoscópicos del satélite SPOT 4</i>	<i>136</i>
<i>Tabla B – 8 Instrumento colector de imágenes VEGETATION...</i>	<i>137</i>
<i>Tabla B – 9 Instrumentos sensores de alta resolución...</i>	<i>137</i>
<i>Tabla B – 10 Instrumentos estereoscópicos del satélite SPOT 5</i>	<i>138</i>
<i>Tabla B – 11 Instrumento colector de imágenes VEGETATION...</i>	<i>138</i>
<i>Tabla B – 12 Características de la órbita del satélite IKONOS</i>	<i>139</i>
<i>Tabla B – 13 Características del sensor del satélite IKONOS</i>	<i>139</i>



RESUMEN

La segmentación de imágenes ha sido un problema que ha llevado a múltiples estudios a través de diferentes métodos para la optimización de esta. Por lo anterior, el propósito de esta tesis fue investigar sobre el análisis de técnicas de segmentación y definir un esquema de segmentación mixta basado en la ya muy conocida Teoría de Bayes y Campos Aleatorios de Markov (CAM), para la segmentación de imágenes de fotografía aérea de alta resolución, incluyendo en el análisis la creación de una clase de rechazo para segmentar más adecuadamente imágenes con modos de probabilidad mezclados. Las imágenes que se usaron para nuestro propósito son imágenes obtenidas a través de la fotografía aérea y corresponden a regiones semiurbanas del sur y oriente de la Ciudad de México, las imágenes se encuentran definidas en 256 niveles de gris, y en esta parte del esquema sólo se busca encontrar las 5 clases típicas que caractericen cada imagen obteniéndose mejores resultados en la tercer imagen (Aeropuerto de la Ciudad de México). De esta forma se logra optimizar este método de segmentación, pues en un principio se usa un Análisis Bayesiano para obtener las bases para la clasificación, y con un Análisis Markoviano, se clasifica solamente aquellos píxeles en los que no se tiene una seguridad de clasificar correctamente (Clase de Rechazo); mejorando notablemente los tiempos de procesamiento y obteniendo resultados muy satisfactorios.



GLOSARIO

A

AATSR: *Advanced Along Track Scanning Radiometer.*

ABSORCIÓN ATMOSFÉRICA: *Indica la eliminación que realiza la atmósfera de distintos tipos de energía, en razón de sus propios componentes, principalmente del ozono, oxígeno atómico y vapor de agua.*

ASAR: *Advanced Synthetic Aperture Radar.*

B

BANDA ESPECTRAL: *Porción del espectro electromagnético, limitada por dos longitudes de onda, dos frecuencias o dos números de onda.*

BARRIDO MULTIESPECTRAL: *Capacidad de explorar secuencialmente la superficie de la Tierra, dividiendo la radiación captada en diversas bandas espectrales.*

C

CAM: *Campo Aleatorio de Markov, se define como una colección de variables aleatorias, que corresponden a los píxeles de una rejilla, cuya distribución de probabilidad es tal que la probabilidad condicional de que una variable determinada tenga un valor particular, dado los valores del resto de las variables, es idéntica a la probabilidad condicional dados los valores del campo en un conjunto pequeño de píxeles, que son los vecinos de ese píxel determinado.*

CLASIFICACIÓN DIGITAL: *Proceso por el que se asigna un píxel de una imagen multi-espectral a una de las categorías de la leyenda, generalmente sobre la base de similitudes entre los valores numéricos que la definen.*

CLIQUE: *Subconjunto de píxeles que puede formarse de un solo píxel, dos píxeles, tres píxeles o más.*

CNES: *Centre National d'Études Spatiales.*

CONEXIDAD: *Constituye una relación de vecindad espacial entre un píxel y sus vecinos próximos.*

D

DIGITALIZACIÓN: *El concepto refiere a cualquier conversión de datos analógicos en formatos numéricos.*

DISTRIBUCIÓN GAUSSIANA O NORMAL: *Término estadístico que refiere a la disposición de las frecuencias observadas en una variable como ajustadas a la curva normal.*

DORIS: *Doppler Orbitography and Radio positioning Integrated by Satellite.*

E

ENERGÍA ELECTROMAGNÉTICA: *Energía propagada a través del espacio o de otro medio material en un modelo armónico ondulatorio con un componente magnético y otro eléctrico.*

ERTS: *Earth Resources Technology Satellite, fué el primer satélite de la serie LANDSAT.*

ESA: *European Space Agency.*

ESBT: *Experimental S-Band Terminal.*



ESPECTRO ELECTROMAGNÉTICO: *Es la organización de bandas de longitudes de onda o frecuencias desde las más cortas a las más largas.*

ETM: *Enhanced Thematic Mapper.*

F

FRECUENCIA: *Número de ciclos por segundo que pasan por un punto fijo.*

G

GOMOS: *Global Ozone Monitoring by Occultation of Stars.*

H

HISTOGRAMA: *Representación gráfica de las frecuencias observadas en una determinada imagen.*

HRS: *High Resolution Stereoscopic.*

HRV: *Haute Résolution Visible.*

HRVIR: *High Resolution Visible and Infrared.*

I

IMAGEN: *Cualquier forma de representación pictórica de los datos.*

L

LANDSAT: *Land Satellite.*

LRR: *Laser Retro-Reflector.*

M

MAP: *Maximo A Posterior.i*

MÁXIMA VEROSIMILITUD: *Criterio estadístico de clasificación digital de imágenes, por el cual se asigna a cada píxel de la imagen a la categoría para la cual posee mayor probabilidad de pertenencia.*

MERIS: *Medium resolution imaging Spectrometer.*

MIPAS: *Michelson Interferometer for Passive Atmospheric Sounding.*

MLL: *MultiLevel Logistic*

MSS: *Multispectral Scanner Subsystem.*

MWR: *Microwave Radiometer.*

N

NASA: *National Aeronautics and Space Administration.*

NG: *Niveles de Gris.*

NOAA: *National Oceanic and Atmospheric Administration.*

NRL: *Naval Research Laboratory.*

P

PASTEC: *PASSager TEChnologique.*

PASTEL: *PASSager SPOT de TELécommunication Laser.*

PDF: *Probability Density Function.*

PERCEPCIÓN REMOTA O TELEDETECCIÓN: *Puede definirse como la ciencia y arte de obtener información de un objeto analizando los datos adquiridos mediante algún dispositivo que no está en contacto físico con dicho objeto.*



PÍXEL: Derivado del inglés "picture element". Es el elemento pictórico más pequeño de las imágenes que es susceptible de ser procesado.

POAM: Polar Ozone and Aerosol Measurement

R

RA-2: Radar Altimeter versión 2.

RADIACIÓN ELECTROMAGNÉTICA: Es una combinación de campos eléctricos y magnéticos oscilantes que se propagan a través del espacio transportando energía de un lugar a otro.

RBV: Return Beam Vidicon.

REFLECTIVIDAD: Porcentaje de radiación incidente que es reflejado por una superficie bidimensional.

RESOLUCIÓN: Medida de la habilidad de un sistema sensor para discriminar información dentro de la imagen.

S

SAR: Synthetic Aperture Radar.

SCIAMACHY: Scanning Imaging Absorption Spectrometer for Atmospheric Cartography.

SENSOR: Cualquier instrumento que detecta energía (principalmente electromagnética), la convierte en una señal y la presenta en forma susceptible de ser aprovechada para el estudio del medio ambiente.

SIG: Sistema de Información Geográfica, es un conjunto de programas que permiten almacenar, modificar y relacionar cualquier tipo de información espacial.

SPECKLE (EFECTO SAL Y PIMIENTA): Se refiere al ruido característico producido en la respuesta de la señal del radar, se observa una estructura del tipo al azar de los elementos pictóricos, causados por la interferencia entre las ondas electromagnéticas dispersadas por la superficie o los objetos.

SPOT: Système Probatoire d'Observation de la Terre.

T

TM: Thematic Mapper.

U

USGS: United States Geological Survey.





1. INTRODUCCIÓN

1.1 OBJETIVO

Investigar sobre el análisis de técnicas de segmentación y definir un esquema de segmentación mixta basado en la ya muy conocida Teoría de Bayes y Campos Aleatorios de Markov (CAM), para la segmentación de imágenes de fotografía aérea de alta resolución, incluyendo en el análisis la creación de una clase de rechazo para segmentar más adecuadamente imágenes con modos de probabilidad mezclados.

1.1.1 ANTECEDENTES DEL TEMA

A pesar de que la percepción remota es una tecnología muy reciente (145 años aproximadamente), son numerosos los centros que se dedican a la producción, enseñanza e investigación de esta técnica. En los últimos años se ha desarrollado una cierta polémica sobre el método de análisis más idóneo para abordar un estudio de clasificación de imágenes, y para la mayoría de los usuarios de la teledetección la clasificación supone la fase culminante del tratamiento digital de imágenes.

Para que una fotografía aérea pueda ser interpretada en detalle es preciso que exista una experiencia previa, que nos permita identificar cada una de las categorías de interés por una serie de rasgos, como son textura, situación o tamaño. Es posible distinguir entre matorral y arbolado, gracias a que éste tiene una textura más rugosa; mientras la separación entre agua y cultivos herbáceos se realiza sobre la diferencia de tonalidad. Es decir, en una clasificación se trata de obtener el nivel de gris, o mejor aún el rango de niveles de gris, que identifican a cada categoría o clase en la imagen. Este objetivo se logra seleccionando una muestra de píxeles de la imagen, que representen, adecuadamente, a las clases de interés. A partir de esos píxeles pueden calcularse las medias y la variabilidad numérica de cada clase, al igual que en cualquier otro muestreo, el objetivo de esta fase es obtener los resultados más precisos con el mínimo coste, llamándosele a esta etapa, fase de entrenamiento.

Tradicionalmente se han dividido los métodos de clasificación en dos grupos: supervisado y no supervisado, de acuerdo a la forma en que son obtenidas las estadísticas de entrenamiento. El método supervisado parte de un conocimiento previo del terreno, a partir del cual se seleccionan las muestras para cada una de las categorías. Por su parte, el método no supervisado procede a una búsqueda automática de grupos de valores homogéneos dentro de la imagen.

Tanto el método supervisado como el no supervisado cuentan con ventajas y desventajas. El primero resulta muchas veces subjetivo, pues el usuario establece a priori unas clases sin valorar las características espectrales de la imagen. El segundo, no garantiza que las clases deducidas tengan significado para el usuario del producto, además de ser de difícil verificación.

Con el objeto de minimizar los inconvenientes de ambos métodos, se han propuesto diversas alternativas que los combinan de alguna forma, y se les llama métodos mixtos o semisupervisados, y se pueden agrupar en dos bloques:



- i. *Por un lado, se sitúan aquellos trabajos que emplean el análisis supervisado para “guiar” el no supervisado. En este caso, el conocimiento del intérprete se utiliza para orientar la búsqueda de esos grupos espectrales homogéneos. Otra forma de orientar el análisis no supervisado, consiste en introducir las medias de las categorías de interés (obtenidas a partir de los campos de entrenamiento) como centros iniciales de grupo. Gracias a ello, el proceso iterativo de búsqueda se reduce notablemente, a la vez que se predispone la formación de grupos con un significado temático.*
- ii. *Por otro lado, el análisis supervisado y el no supervisado pueden combinarse gracias a aplicarlos separadamente sobre la misma imagen, para luego sintetizar las medidas extraídas por ambos. Se asume que las clases obtenidas por ambos pueden complementarse mutuamente, ganando en significado espectral e informacional las clases resultantes.*

Es por ello que podemos encontrar una diversidad de algoritmos y de parámetros de control; sin embargo, la elección del mejor método dependerá de los datos y medios disponibles y de las propias preferencias personales. [2]

1.1.2 DEFINICIÓN DEL PROBLEMA

Existen regiones del planeta de difícil acceso para la adquisición de datos. Las condiciones meteorológicas son factores determinantes en regiones muy frecuentemente cubiertas por nubes. Otro factor adicional son las condiciones de iluminación del sol en las imágenes adquiridas en el rango espectral visible e infrarrojo. Es en este contexto que las tecnologías contemporáneas de Procesamiento Digital de Imágenes y de Percepción Remota se sitúan como fuentes de datos útiles a los sistemas de información ambiental.

*Las imágenes provenientes de instrumentos de Radar de Apertura Sintética (SAR, por sus siglas en inglés) se han revelado con una fuente de datos de enorme potencial de aplicación, debido a su naturaleza de adquisición de datos por captadores activos. En desventaja, diversos problemas urgen por la adquisición empleando fuentes de iluminación coherentes. El *speckle* (efecto sal y pimienta) y las interacciones de la atmósfera con la superficie de los océanos crean efectos de difícil análisis al emplear técnicas de procesamiento tradicionales. Una alternativa de análisis es emplear fotografía aérea de alta resolución, del orden de 20 x 20 cm. el tamaño del píxel. Es en este contexto que en el presente tema de Seminario/Tesis, se pretende el estudio de técnicas bayesianas para la segmentación de imágenes de percepción remota. El uso combinado de la ya muy conocida Teoría de Bayes y de los Campos Aleatorios de Markov permitirán definir un esquema de segmentación que incluya el análisis de una clase de rechazo, y tal estrategia servirá para segmentar más adecuadamente imágenes con modos de probabilidad mezclados.*

Se pretende la segmentación de 3 imágenes de fotografía aérea de alta resolución, pertenecientes a escenas urbanas del Distrito Federal, en 5 clases usando un esquema de segmentación mixto.



1.1.3 METODOLOGÍA EMPLEADA

El objetivo final de un sistema de Reconocimiento de Patrones es el etiquetar de forma automática patrones de los cuales desconocemos su clase. Suponemos que el sistema dispone de un módulo de adquisición de datos y que se han seleccionado previamente las variables más significativas.

Una vez establecido el conjunto de clases se procede a la construcción del clasificador. Como puede intuirse, la construcción del clasificador no es una tarea trivial ni directa e involucra una serie de etapas:

- 1. La elección del modelo*
- 2. Aprendizaje (entrenamiento del clasificador)*
- 3. Verificación de los resultados*

Es muy importante señalar que estas etapas no deben verse de forma secuencial. Puede ocurrir que en un momento dado hay que volver atrás para replantearse alguno de los pasos dados, incluso el conjunto de clases.

Para la elaboración de esta tesis sólo se llevará a cabo el proceso de segmentación, que es parte fundamental en la elaboración del clasificador. Para este propósito se empleará la segmentación usando el Análisis Bayesiano como fundamento. El modelo de segmentación bajo este enfoque resulta muy útil y práctico en la tarea de la clasificación; sin embargo, puede tener problemas de clasificación errónea debido a que en muchos de los casos la probabilidad de pertenencia de un píxel a una clase determinada es muy baja y esto es lo que nos lleva a crear un esquema mixto de segmentación en el que se defina una sexta clase de rechazo. Se pretende aplicar a una imagen en 256 niveles de gris, involucrando en el proceso funciones equiprobables, la obtención de medias de 5 clases representativas y de probabilidades a priori. Una vez obtenidos estos parámetros se definirá una sexta clase de rechazo, tal que si $P(\omega_i | X) \leq \text{umbral de rechazo}$, el píxel analizado será asignado a la clase de rechazo, finalmente esta clase de rechazo será segmentada usando Campos Aleatorios de Markov (Capítulo 5) para asegurar que estos píxeles se clasificarán correctamente, es por ello que a esta segmentación se le llamó semisupervisada, y lo que interesa es llevarla a cabo en imágenes de percepción remota del Distrito Federal.



2. FUNDAMENTOS DE PERCEPCIÓN REMOTA

2.1 DESCRIPCIÓN GENERAL

La Percepción Remota (*Remote Sensing*) o Teledetección puede definirse como aquella técnica que nos permite obtener información a distancia de los objetos situados sobre la superficie terrestre. Para que esta observación remota sea posible, es preciso que entre los objetos y el sensor exista algún tipo de interacción.

Podría decirse que la historia de la Percepción Remota comenzó hace unos 600 millones de años, cuando alguna forma inferior de vida animal diferenció algunas de sus células, volviéndolas fotosensibles. También durante millones de años dicho rudimento fotosensible evolucionó convirtiéndose en un poderoso y sofisticado sensor, el ojo humano. Las primeras experiencias de teledetección se remontan a 1859, cuando Gaspar Felix de Tournachon obtiene las primeras fotografías aéreas desde un globo cautivo. Al año siguiente, James Wallace repite la misma experiencia sobre la ciudad de Boston, poniéndose en evidencia el interés de la nueva perspectiva aérea para un conocimiento más detallado de la organización urbana. [2]

La cámara fotográfica, hizo su aparición hace algo más de un siglo y que fue muy mejorada durante la década de 1930 para ser aplicada a la fotografía aérea. La Segunda Guerra Mundial dio un gran impulso a la fotografía aérea así como a otras formas de percepción remota. Sin embargo, el "salto cuántico" en esta disciplina se produjo en la década de 1960 cuando las plataformas satelitales reemplazaron a las aéreas y los sensores electrónicos multiespectrales, acoplados a computadoras, reemplazaron las cámaras fotográficas. El esquema operativo de un satélite de observación se representa en forma muy simplificada, en la Figura 2 - 1.



Figura 2 - 1 (Esquema operativo de un satélite de observación) [8]

Los objetos terrestres, iluminados por la radiación solar, reflejan ésta luego de introducir en ella modificaciones inducidas por la misma estructura y composición de dichos objetos. La radiación reflejada es capturada por los sensores del satélite, siendo parcialmente procesada a bordo de éste y retransmitida a estaciones receptoras terrestres para su posterior procesamiento y análisis. [8]



2.2 PRINCIPIOS Y FUNDAMENTOS

La utilización efectiva de los datos provenientes de percepción remota depende de la habilidad del usuario para interpretar, correcta y consistentemente, las fotografías, imágenes, gráficos o estadísticas que se derivan de las fuentes de percepción remota.

Los instrumentos que registran la radiación electromagnética emitida o reflejada por la tierra pueden ser instalados en aeronaves o satélites. Los primeros son llamados sensores remotos aéreos o aero-transportados y, los segundos, sensores remotos de satélite o del espacio. Estos instrumentos registran los datos usando dispositivos ópticos, electro-ópticos, óptico-mecánicos o electrónicos. [9]

La atmósfera no es un cuerpo transparente en ella se encuentra pequeñas partículas en suspensión que interactúan con la radiación incidente. La energía al chocar con estas partículas puede ser dispersada, absorbida o emitida dependiendo de la longitud de onda y esto puede observarse gráficamente en la Figura 2 - 2. Por lo general a mayor longitud de onda la dispersión disminuye, en tanto que la absorción presenta comportamientos variables. Las porciones del espectro electromagnético donde la radiación no es absorbida y llega a la superficie de la Tierra se denominan ventanas atmosféricas y son de gran importancia para diseñar los sensores de los satélites para captar dentro de estas longitudes de onda.




Figura 2 - 2 (Esquema de comportamiento de la energía) [10]

También la atmósfera emite parte de la energía absorbida en forma de calor y este tipo de energía es registrada principalmente por los sensores diseñados para generar información de las energías electromagnéticas del infrarrojo térmico.

La energía que llega a los cuerpos, incide en la superficie y puede sufrir tres procesos: ser reflejada (R), absorbida (A) o transmitida (T), por lo tanto la energía incidente (I) será la sumatoria de todos los anteriores procesos y se puede resumir en la siguiente ecuación:

$$I = R + A + T$$

Ecuación 2 - 1

La energía reflejada y el calor que los cuerpos emiten, es la energía que los sensores de los satélites reciben, después de interactuar nuevamente con la atmósfera como se observa en la Figura 2 - 3.

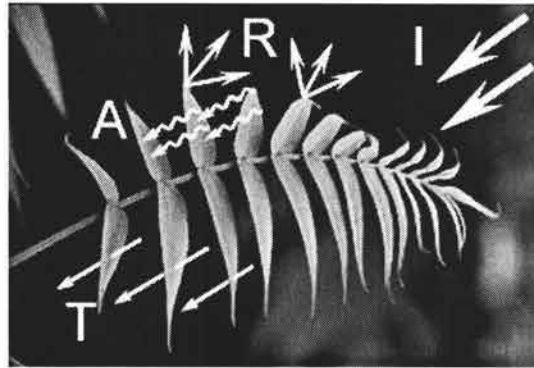


Figura 2 - 3 (Comportamiento de la energía) [10]

2.2.1 CONCEPTOS FUNDAMENTALES

2.2.1.1. Sensores activos

Los sensores activos, se basan en que proveen su propia fuente de energía que emiten hacia los cuerpos y reciben la señal de retorno. Entre los sensores activos más comunes están los radares, que pueden trabajar bajo cualquier condición atmosférica, tanto de día como de noche. Estos sensores trabajan principalmente en la región de las microondas. [10]

2.2.1.2. Sensores pasivos

Los sensores pasivos de teledetección reciben la señal de una fuente de luz o energía externa reflejada por la superficie de los cuerpos. Estos sensores están incluidos sobre la mayoría de los satélites que manejan las bandas del espectro visible. [10]

2.2.1.3. Escala

La escala a la que se puede ampliar una fotografía o una imagen, con o sin mejoramiento óptico o computarizado, determina en qué fase del estudio de planificación para el desarrollo debe de ser utilizada esta información. Las presentaciones a escala de 1:500.000 se usan cuando no se necesita mayor detalle, las imágenes a escalas de 1:250.000 o mayores se requieren donde si es importante el detalle y donde deben ser definidos ciertos aspectos menos obvios. Frecuentemente es posible detectar fenómenos de peligros naturales en una fotografía o imagen a pequeña escala, pero es imposible anotar la información sin su ampliación a escalas mayores. En consecuencia, es necesario utilizar imágenes a escalas compatibles con el nivel de detalle requerido para cada etapa particular del estudio, así como con la extensión del área del estudio mismo. [9]

2.2.1.4. Resolución

La escala misma no tiene sentido si no se dispone de una adecuada resolución espacial; es decir, de la capacidad de distinguir objetos que están muy cerca unos a otros en una imagen o fotografía. La resolución de la imagen es determinada por el



tamaño y número de elementos básicos de la figura o de la imagen, o sea, los píxeles que conforman la imagen. Cuanto más pequeño es el tamaño del píxel, mayor será la resolución. En la fotografía, la resolución está limitada principalmente por el tamaño del grano de la película, pero los lentes y otras consideraciones técnicas también tienen un rol importante.

En ambos casos, imágenes y fotografías, la posibilidad de poder distinguir entre rasgos adyacentes, juega un papel muy importante en el proceso de identificación. La ampliación de fotografías o imágenes no puede mejorar la resolución sino sólo el espacio de trabajo para la interpretación.

La resolución espectral también necesita ser tomada en consideración al seleccionar el tipo de datos, ya que los diferentes sensores están diseñados para cubrir diferentes regiones espectrales. La resolución espectral se refiere al ancho de banda o a un rango de bandas que ofrece el sensor. La Figura 2 - 4 presenta las regiones espectrales más comúnmente usadas en percepción remota, usualmente ubicadas en las regiones: visible e infrarrojo cercano, infrarrojo medio e infrarrojo termal o extremo y microondas. [9]

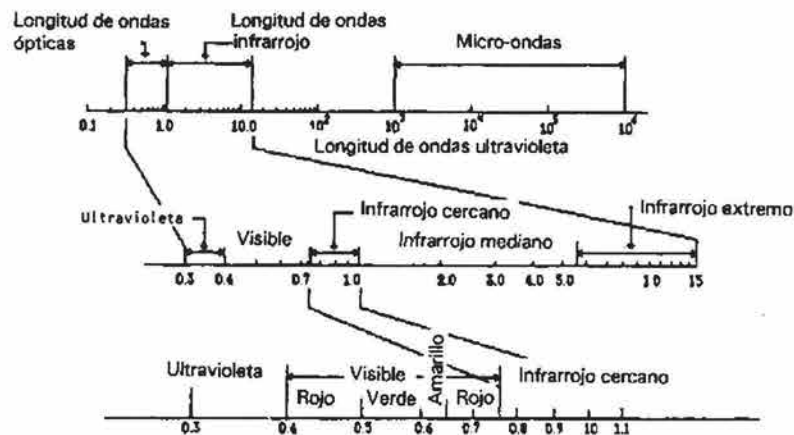


Figura 2 - 4 (Regiones espectrales más comúnmente usadas en percepción remota) [9]

2.2.1.5. Contraste de imágenes

El contraste entre rasgos, en una imagen o fotografía, es una función de la habilidad del sensor para captar el contenido tonal o espectral de la escena. Las diferentes bandas espectrales de los sistemas de percepción remota pueden exhibir contrastes fuertes o débiles según la región del espectro electromagnético cubierta y la superficie observada. Por ejemplo, una determinada banda puede mostrar poco contraste entre tipos de vegetación en un ambiente forestal y fuertes contrastes entre tipos de roca en una zona árida. Las áreas peligrosas tales como zonas de fallas sísmicas o las susceptibles a deslizamientos de tierra, pueden ser demasiado reducidas para algunos sensores, por ejemplo, el Advanced Very High Resolution Radiometer (AVHRR), pero pueden ser fácilmente visibles en imágenes producidas por otros sistemas de sensores, por ejemplo el LANDSAT Thematic Mapper (TM). Además, los terrenos con abundante vegetación y mucha nubosidad en los trópicos de América Latina y el Caribe son los más difíciles de interpretar geológicamente. Sin embargo, un



intérprete experto puede detectar muchos peligros naturales en base al análisis fisiográfico de datos obtenidos por radares que pueden penetrar las nubes.

Cuando una imagen no proporciona el detalle, la resolución o contraste requerido, se dispone de varias opciones. Dado que no siempre es posible identificar todas las características deseadas en base a la interpretación de un sólo sensor, es posible que se requiera un segundo sensor de tipo completamente diferente al primero, o de una combinación de sensores. Los datos digitales pueden ser mejorados y/o manipulados usando técnicas tales como ampliación del contraste, compuestos a falso color, análisis del componente principal, filtraje y clasificaciones supervisadas y no supervisadas. [9]

2.2.1.6. Marco del tiempo

Las ocurrencias temporales de eventos naturales también afectarán la utilidad de los datos de percepción remota. Ciertos sensores, como por ejemplo el LANDSAT, pueden detectar un fenómeno muy fácilmente, aunque la cobertura repetitiva sea hecha cada 16 días. Durante ese lapso podrían ocurrir una inundación y la normalización posterior de la situación. Por otro lado, la desertificación de un área puede ser un proceso largo y la utilidad de datos de percepción remota puede ser muy grande para monitorear los cambios. Los eventos que son estacionales, predecibles o altamente correlacionados con otros eventos, probablemente se beneficiarán más de las imágenes que aquellos otros que ocurren aleatoriamente, tales como los terremotos o tsunamis. [9]

2.2.1.7. Imágenes y mapas de percepción remota

Para obtener el mayor provecho del uso de datos disponibles de percepción remota, los planificadores deben hacer uso de toda la información relevante existente del área de estudio. Los mapas son especialmente útiles para interpretar los datos de percepción remota. Entre los mapas, los topográficos son la principal ayuda para esclarecer muchas de las ambigüedades que se presentan en las imágenes de percepción remota para el reconocimiento del terreno. Los mapas geológicos se enfocan en las formaciones que conducen a ciertos tipos de peligros. Este conocimiento puede ayudar a la localización y búsqueda sistemática de estos peligros. Los mapas de suelos pueden servir para un propósito similar aunque en menor grado. Finalmente, los mapas de vegetación y de uso de tierras pueden proporcionar información sobre el contenido de humedad, formaciones geológicas subyacentes y tipo de suelos presentes. [9]

2.2.1.8. Formatos de productos

Los formatos de los productos consisten en diferentes maneras de presentar los datos de sensores remotos. Los datos fotográficos generalmente son usados en formato de película positiva o como impresión fotográfica. Los datos en película e impresiones fotográficas pueden ser analizados y convertidos a datos digitales para su registro en cinta compatible con la computadora (CCT). La principal ventaja de los datos digitales es que pueden ser cuantificados y manipulados usando técnicas de procesamiento de imágenes. Las imágenes de satélite u otras grabadas en CCT pueden ser presentadas en



un formato de película positiva o fotografiada directamente de la pantalla del monitor.
[9]

2.2.2 AGENCIA ESPACIAL EUROPEA

La ESA (Agencia Espacial Europea, European Space Agency) se encarga de desarrollar proyectos de colaboración en los campos de la ciencia y tecnología espaciales, se compone de 15 estados miembros y nació en 1975.

Algunos de los logros mayores de la ESA son:

- *Los cohetes Ariane.*
- *Los estándares globales de la actual generación de satélites para telecomunicaciones basados en técnicas probadas por la ESA.*
- *La ESA es primera en el mundo en cuanto al seguimiento del agujero del ozono, de las capas de hielo, de los vientos y corrientes oceánicas y demás elementos reveladores de la salud del planeta. También el Meteosat, que facilita los mapas meteorológicos televisivos que todo el mundo conoce en Europa y África.*
- *Las sondas científicas construidas por la ESA han alcanzado un papel de primera plana en el estudio del sol y sus efectos sobre la Tierra, los cometas, el levantamiento de mapas de las estrellas desde el espacio y en el descubrimiento de los secretos del universo por medio de rayos X e infrarrojos.*

He aquí los vehículos espaciales de la Agencia Europea del Espacio (algunos ya son operativos, mientras que otros se espera lanzarlos antes de fines del 2004). Son de más de 20 proyectos, indicados aproximadamente de acuerdo con el orden de lanzamiento.

- **Telescopio Espacial Hubble** (NASA & ESA) – 1990
Telescopio espacial de la luz visible.
- **Ulysses** (ESA & NASA, construido en Europa) – 1990
Primer vehículo espacial en sobrevolar los polos del Sol ha determinado un cambio profundo en los conocimientos científicos acerca del viento solar y su magnetismo.
- **ERS-2** – 1995
Está equipado con un nuevo instrumento para la observación del agujero del ozono.
- **SOHO** (ESA & NASA, construido en Europa) – 1995
Dedicado a descubrimientos acerca del interior del Sol y su atmósfera explosiva, además de seguir las tormentas solares las 24 horas del día.
- **Huygens** (aporte de la ESA a la misión Cassini de la NASA) – 1997



En noviembre de 2004, Huygens penetrará en la brumosa atmósfera de Titán, la luna más grande de Saturno.

- **XMM-Newton – 1999**
El observatorio espacial más sensible jamás construido para la astronomía de rayos X, gracias a sus tres telescopios, cada uno dotado de 58 espejos diseñados con extrema precisión y anidados uno dentro del otro.
- **Cluster (ESA & NASA, construido en Europa) – 2000**
Cuatro satélites que operan juntos a fin de dar una visión en tres dimensiones, de la lucha entre el viento solar y el campo magnético terrestre, así como de las tempestades espaciales que la acompañan.
- **Artemis (ESA y Japón) – 2001**
Indicará los enlaces directos a los usuarios de móviles en tierra, recogerá datos de otros satélites por medio de rayos láser y transmitirá informaciones para la navegación a EGNOS.
- **ENVISAT – 2001**
Estará destinado a la observación de la Tierra por medio de versiones avanzadas de los instrumentos usados en el ERS-2 y también varios importantes instrumentos nuevos.
- **Brazo Robótico Europeo – 2001**
Destinado a ser montado en el módulo ruso pero también útil para los proyectos europeos a realizarse en la estación.
- **Integral – 2002**
Empleará sus propios telescopios ingeniosos y detectores sensibles para observar los rayos gamma procedentes de eventos muy violentos en el espacio cósmico.
- **MSG-1 (ESA & Eumetsat) – 2002 y MSG-2 aproximadamente 18 meses después.**
Facilitarán información meteorológica mucho más precisa que los Meteosats, en actividad sobre el ecuador desde 1977.
- **SMART-1 – 2002**
Este pequeño vehículo espacial experimental probará el uso de la propulsión eléctrica a energía solar y llevará consigo una serie de instrumentos científicos destinados al estudio de la Luna.
- **Rosetta (ESA, con el lander franco-alemán) – 2003**
Su objetivo es el cometa Wirtanen observándolo desde una órbita próxima y depositando una pequeña sonda en su superficie.
- **EGNOS en servicio a partir de 2003**



El Servicio Geoestacionario Europeo de Asistencia a la Navegación se servirá de los instrumentos a bordo de tres satélites geoestacionarios y una red de estaciones terrestres, para mejorar la precisión y fiabilidad de los sistemas de navegación estadounidenses y rusos.

- **Mars Express** (ESA, más el lander del Reino Unido) – 2003
Buscará agua o hielo no visibles y depositará en la superficie de Marte un aparato sensible a las eventuales señales de vida.
- **Cryosat** – 2003
Usará dos radares gemelos para registrar con mayor precisión que nunca los cambios en las capas de hielo terrestres y marinas.
- **METOP-1** (ESA & Eumetsat) – 2003
Monitoreará la atmósfera desde los polos.
- **Vehículo automático ATV** – 2003
Transportará cargas a la Estación Espacial Internacional, atracará automáticamente, corregirá la órbita de la estación, para acabar como incinerador.
- **Galileo** – 2004-2008
Sistema de navegación europeo, Galileo, serán probados en el espacio en el 2004, mientras que la constelación entera, de 30 satélites, será operativa para 2008.
- **Columbus** – 2004
Es un laboratorio cilíndrico de 6,7 metros de largo, en el que los astronautas podrán realizar cientos de experimentos al año.

Los diez miembros fundadores de la ESA fueron los mayores países de Europa occidental - Francia, Alemania, Italia, España y el Reino Unido, juntamente con Bélgica, Dinamarca, los Países Bajos, Suecia y Suiza. A éstos se añadieron sucesivamente otros cinco: Irlanda, Austria, Noruega, Finlandia y Portugal. Canadá participa como Estado Colaborador. La ESA mantiene oficinas permanentes de enlace en Bruselas, Tolosa, Washington DC y Moscú. [11]

2.2.3 NASA

Desde su inicio en 1958, la NASA (National Aeronautics and Space Administration) ha logrado muchas grandes hazañas científicas y tecnológicas en el campo aéreo y espacial. La tecnología de la NASA también ha sido adaptada para muchas aplicaciones no-aeroespaciales por el sector privado. La NASA sigue siendo una fuerza principal en la investigación científica y en la estimulación del interés público en la exploración aeroespacial, así como ciencia y tecnología en general. [12]

En lo relacionado a teledetección, la NASA mantiene programas para obtener información del color del océano mediante sensores de diversas bandas espectrales. De 1978 a 1986 se tuvo acceso a datos de ese tipo de los océanos mundiales a través del



sensor CZCS (Coastal Zone Color Scanner). El sucesor del CZCS que cuenta con una mejor cobertura espectral, fue lanzado recientemente (SeaWiFS) y el plan para el uso de sensores más sofisticados con bandas multiespectrales por parte de la NASA se consolida. La NASA lanzó a su órbita en diciembre de 1999, al MODIS a bordo del satélite Terra. La ESA por su parte, contribuye a la extensión de este tipo de programas mediante el MERIS que funcionará a bordo del ENVISAT. [13]

El **Programa Nuevo Milenio** (New Millennium Program - NMP) es un programa tecnológico interempresarial financiado y administrado conjuntamente por las Oficinas de Ciencias Espaciales y de Ciencias Terrestres de la NASA (Administración Nacional de Aeronáutica y Espacio de los Estados Unidos). Este ambicioso e interesante proyecto fue establecido en 1995 para acelerar la exploración espacial mediante el desarrollo de tecnologías altamente avanzadas. Por consiguiente, el propósito del programa es realizar pruebas de tecnologías avanzadas en un ambiente espacial, a fin de eliminar el riesgo del primer uso antes de incorporarlas a una nueva generación de misiones futuras de ciencias espaciales y terrestres. En este aspecto, el programa es único.

Si bien existen muchas tecnologías espaciales relacionadas que se pueden ensayar en laboratorios terrestres, las tecnologías y los conceptos seleccionados por el programa NMP -tales como la propulsión eléctrica solar (iónica), la Percepción Remota Avanzada desde sistemas terrestres o el vuelo de vehículos espaciales en formaciones- presentan un alto riesgo para las misiones que los usan por primera vez. [16]

Se tienen las siguientes misiones:

- **Deep Space 1.** La nave fue lanzada el 24 de octubre de 1998, cuenta con una cámara miniatura, un espectrómetro de imágenes y un espectrómetro iónico y electrónico miniatura que enviaba datos científicos del sol (Figura 2 - 5). La misión finalizó el 18 de septiembre de 1999 y el satélite fue retirado después de haber concluido todas sus misiones exitosamente y haber capturado las mejores imágenes el día 18 de Diciembre de 2001. [17]




Figura 2 - 5 (Deep Space-1) [16]

- **Deep Space 2.** Lanzado en enero de 1999, envió a Marte dos sondas miniatura altamente avanzadas (Ver Figura 2 - 6). Poco antes de que las



sondas llegaran al punto de aterrizaje, los ingenieros de la misión perdieron contacto con el vehículo espacial que las transportaba.




Figura 2 - 6 (Sonda miniatura de la misión Deep Space 2) [16]

- ─ **Earth-Observing 1.** La nueva tecnología de monitoreo a bordo del satélite Earth-Observing 1 de la NASA (EO-1) ha probado por sí solo que la claridad en sus imágenes es invaluable y que posee una habilidad para identificar exactamente los objetos en la superficie de la Tierra, es por ello que será parte de una misión de monitoreo de la Tierra de largo plazo en el próximo satélite LANDSAT. Las Figuras 2 - 7 y 2 - 8 muestran las imágenes correspondientes a un poblado de Maryland (La Plata) antes y después de ocurrido un tornado, estas imágenes fueron obtenidas mediante el satélite de esta misión.



Figura 2 - 7 (Antes del tornado, 24/04/02) [16]



Figura 2 - 8 (Después del tornado, 1/05/02) [16]

- ─ **Earth-Observing 3.** La misión Earth Observing 3 (EO3) del programa Nuevo Milenio (NMP) (Véase Figura 2 - 9), llamada GIFTS, tiene como objetivo mejorar los sistemas operacionales de observación meteorológica. Además de ser el nombre de la misión, "GIFTS" es también la sigla en inglés del instrumento de esta misión, es decir, espectrómetro geosincrónico generador de imágenes por transformada



de Fourier. Además, de una mejor predicción de los cambios meteorológicos ofrece beneficios en otros campos, tales como el pronóstico de las cosechas, el transporte aéreo y el consumo de energía.




Figura 2 - 9 (Concepto artístico del Satélite de la misión EO3) [16]

- **Space Technology 5.** Como parte del proyecto Space Technology 5 (ST5) del Programa Nuevo Milenio (NMP) (Véase Figura 2 - 10), se están construyendo tres satélites miniaturizados de tamaño no mayor al de un televisor común, pero de menor peso. Estos diminutos satélites, llamados nanosatélites o "small-sats", trabajan en conjunto y una vez puestos en servicio volarán en varios puntos dentro de la magnetosfera, que es la región que rodea a nuestro planeta como si fuera un blindaje. Los magnetómetros de a bordo de estos satélites miniaturizados medirán las partículas energéticas de la magnetosfera y sus datos serán enviados a científicos en tierra para su análisis. Los datos obtenidos contribuirán a determinar los niveles de radiación ambiental y la respuesta del subsistema del vehículo espacial a este riesgo.





Figura 2 - 10 (Conceptos artísticos de la misión ST5) [16]

- **Space Technology 6.** En 2004 y 2006, la misión Space Technology 6 (ST6) del Programa del Nuevo Milenio probará dos tecnologías experimentales: el experimento de una nave espacial científica



autónoma (denominado "Sciencecraft", Figura 2 - 11) y la brújula inercial estelar (denominada "Compass", Figura 2 - 12). Este dúo de tecnologías avanzadas mejorará las capacidades autónomas de toma de decisiones por parte de una nave espacial sin tripulación. [16]




Figura 2 - 11 (Concepto artístico de la tecnología Sciencecraft) [16]




Figura 2 - 12 (Concepto artístico de la tecnología Compass) [16]

2.3 APLICACIONES

2.3.1 EVALUACIÓN DE PELIGROS NATURALES

Para la evaluación de peligros naturales, en el contexto de estudios de planificación para el desarrollo integrado, no es necesario disponer de imágenes de percepción remota en tiempo real o casi real. Lo que se requiere es habilidad para definir áreas potenciales de exposición a peligros naturales, identificando su ocurrencia en el pasado y las condiciones bajo las cuales podrían volver a ocurrir y, también, habilidad para identificar los mecanismos de prevención o mitigación los efectos de estos peligros. Esta sección considera la posibilidad práctica de detectar el potencial de inundaciones, huracanes, terremotos, erupciones volcánicas y peligros asociados; así como deslizamientos de tierra, con la tecnología de percepción.

La posibilidad de poder identificar estos peligros naturales o su potencial de ocurrencia depende de la resolución de la imagen, la escala de adquisición de los datos del sensor, la escala de trabajo, tomas sin nubosidad o neblina densa y del adecuado contraste de textura, tono o color. La disponibilidad de estéreo-modelos de la escena en estudio puede mejorar la interpretación enormemente. El Apéndice A muestra los atributos de percepción remota con satélites (Tabla A - 1), a ser considerados en la evaluación de peligros naturales.



Luego de identificar un peligro, la formulación de medidas apropiadas de mitigación y planes de respuesta para el desarrollo, podrán requerir diferentes conjuntos de datos de sensores remotos. Estos datos adicionales de percepción remota, probablemente incluirán mayores detalles de la infraestructura, por ejemplo, caminos e instalaciones. Es posible que esto tenga que ser derivado de fotografías aéreas. [9]

2.3.1.1. Inundaciones

Las inundaciones son el más común de los peligros naturales que puede afectar a personas, infraestructura y medio ambiente natural. Ocurren de muchas maneras y en diferentes ambientes. Las inundaciones de ríos, que son las más frecuentes, se originan por prolongadas e intensas precipitaciones, rápido derretimiento de nieve en las cabeceras de vertientes, o por el ciclo regular de deshielo durante la primavera. Otras inundaciones son causadas por precipitaciones cortas pero extremadamente fuertes sobre terrenos relativamente planos.

Es imposible definir todo el potencial de inundación en un área determinada. Sin embargo, con los mejores datos pertinentes de percepción remota y un intérprete competente, se pueden encontrar o inferir evidencias de inundaciones potenciales. La evidencia más obvia del potencial de una importante inundación, además de los antecedentes históricos, es la identificación de una llanura inundable o de áreas inundables, generalmente reconocibles en imágenes de sensamiento remoto. La más valiosa aplicación de la percepción remota en las evaluaciones de peligros de inundación es, por lo tanto, la cartografía de áreas susceptibles a inundaciones.

La cobertura sinóptica con sensores de satélites, de un área de estudios de planificación es la alternativa práctica a la fotografía aérea por consideraciones de costo y tiempo. La aplicación de imágenes LANDSAT MSS para demarcar llanuras inundables y llanuras de inundación ya ha sido demostrada comparando imágenes anteriores a la inundación, con otras obtenidas en el punto más alto de la misma utilizando la banda 7 del LANDSAT MSS (IR cercano) con un visor color aditivo. Esta comparación temporal puede ser ahora realizada píxel por píxel por una computadora. El LANDSAT TM, con mayor resolución espacial que los MSS (30m versus 80m) y cobertura espectral adicional (7 bandas versus 4 bandas), puede ser utilizado para cartografía más detallada de llanuras de inundación y de áreas inundables, a escalas de 1:50.000 o mayores. Los datos TM han sido usados para discriminar las clasificaciones de cobertura del terreno, para proporcionar información útil en el pronóstico de inundaciones y modelos de daños ocasionados por inundación de zonas urbanas y agrícolas.

Sin embargo, este enfoque para delinear llanuras de inundación tiene limitaciones. El área de inundación potencial así demarcada puede representar un grado no aceptable de inundación considerando el monto de las pérdidas. Por otro lado, pudieron no haber ocurrido inundaciones durante el período operativo del sensor. En este caso, se utilizan indicadores indirectos de susceptibilidad a inundaciones. La Figura 2 - 13 presenta un listado de datos LANDSAT y otros, presumiblemente similares, como indicadores de llanuras de inundación.



INDICADORES LANDSAT DE LLANURAS DE INUNDACION

- Fisiografía en tierras altas
- Características de la cuenca fluvial, tales como forma, drenaje y densidad
- Grado de abandono de diques naturales
- Ocurrencia de dunas de arenas estabilizadas, sobre terrazas de río
- Configuración del canal y características geomórficas fluviales
- Áreas detrás de pantanos
- Humedad en el suelo (también es indicador a corto plazo de la susceptibilidad a inundaciones)
- Variación de características del suelo
- Variación de características de vegetación
- Fronteras para uso de tierras
- Medidas de atenuación de inundaciones para el desarrollo agrícola en llanuras de inundación

Fuente: Adaptado de Rango, A. y Anderson, A.T. "Flood Hazard Studies in the Mississippi River Basin Using Remote Sensing" en *Water Resources Bulletin*, vol 10, 1974.

Figura 2 - 13 (Indicadores LANDSAT de llanuras de inundación) [9]

Existen grandes zonas de ecosistemas tropicales húmedos para las cuales no se dispone de imágenes LANDSAT u otras similares, debido a la excesiva nubosidad o fuerte neblina. En algunos casos la densa vegetación tropical esconde muchos rasgos geomórficos que son muy evidentes en climas más secos. En este caso, son deseables las imágenes de radar del espacio o las que anteriormente hubieran sido obtenidas mediante observaciones aéreas. Las imágenes de radar, que tienen una resolución comparable a las del LANDSAT TM y SPOT pueden penetrar satisfactoriamente las nubes e identificar muchos rasgos de llanuras inundables, tanto desde el espacio como desde altitudes suborbitales. La humedad del suelo afecta notablemente el eco del radar y, conjuntamente con las variaciones de textura resaltadas por el sensor, hacen del radar una herramienta potencialmente atractiva para la cartografía de inundaciones y llanuras de inundación. [9]

2.3.1.2. Huracanes

A fin de mitigar el impacto de los huracanes, el planificador debe conocer la frecuencia e intensidad de las tormentas en el área de estudio, el grado en que pueden afectar a la población y las estructuras, y cuáles sub-áreas serían las más afectadas, tales como las áreas costeras bajas, de estuarios y ribereñas amenazadas por inundaciones terrestres y marinas.

La trayectoria de anteriores huracanes en la región, puede ser obtenida de los datos de percepción remota con los sensores abordo de los satélites de la U.S. National Oceanographic and Atmospheric Administration (NOAA), diseñados y operados con fines meteorológicos. Estos datos ya han sido graficados por organizaciones meteorológicas en los Estados Unidos y en otros países donde los huracanes también son un peligro. Para graficar nuevos datos, el mejor sensor es el AVHRR por la cobertura de una franja de terreno de 2.700 Km. de ancho, dos veces al día y resolución apropiada. La banda roja es utilizable para definir nubes y vegetación en horas del día, mientras que la banda IR térmica (10,5mm a 11,5mm) es útil tanto de día como de noche para la observación de nubes.



El AVHRR no es útil para planificar contingencias de huracanes en otros aspectos, porque tiene una resolución espacial limitada. Las necesidades de la planificación requieren mayor resolución que la que se puede obtener con otros sensores de satélites. Deben ser utilizadas, no importando su resolución, todas las imágenes de las áreas inundadas por ríos, tormentas de huracanes u otras, obtenidas inmediatamente después del evento. Cualquier información que se obtenga oportunamente debe ser utilizada para demarcar las áreas problemáticas, dado que su definición es más exacta que la que se puede interpretar de datos de mayor resolución obtenidos durante periodos normales.

Se pueden predecir las áreas con potencial de inundación a lo largo de la costa y en el interior utilizando mapas topográficos a escalas tan grandes como 1:12.500. Cuando estos mapas no están a disposición, puede usarse técnicas de percepción remota. En regiones con estaciones húmedas y secas marcadas, es deseable obtener imágenes LANDSAT o comparables, durante la estación húmeda, bien en las bandas del IR cercano, bien usando un compuesto a color IR de imágenes LANDSAT MSS o TM, o las del SPOT HRV. Estas imágenes pueden ser usadas para identificar las áreas saturadas de humedad susceptibles a inundaciones, así como los terrenos más elevados y secos que son áreas potenciales de evacuación. Así mismo, la consideración de planes de desarrollo a la luz de este peligro natural potencial, puede proceder de igual manera que para las áreas expuestas a peligros de inundación. Para las evaluaciones de peligros de inundación, se podrían usar imágenes de radar del espacio o de aeronaves (si estuvieran disponibles) en vez de las imágenes LANDSAT MSS. Dado que en general las áreas costeras bajas y las zonas de estuarios no tienen mucho relieve, la estereoscopia normalmente no tendría un rol importante en esta situación. Sin embargo, la visión estereoscópica, aún sin un realce significativo de relieve, puede reforzar detalles de la escena, aunque a un costo considerablemente mayor.

El planificador del desarrollo también debe considerar una característica adicional de los huracanes: los fuertes vientos. Al identificar medidas para mitigar los efectos del viento, el planificador puede considerar tipo de cultivos, si existen planes para desarrollo agrícola, y/o el diseño y los materiales de construcción a ser empleados en los edificios. [9]

2.3.1.3. Terremotos

La planificación del desarrollo en áreas propensas a movimientos sísmicos esta llena de problemas. Existen muchísimos asentamientos humanos en áreas de alta sismicidad. Como en el caso de otros peligros geológicos, la frecuencia de ocurrencia puede tener ciclos de décadas o siglos. Los terremotos son especialmente difíciles de predecir. Por lo tanto, el énfasis de la mitigación se pone en la planificación sobre uso de tierras (uso no intensivo en áreas peligrosas), en la resistencia e integridad de edificaciones, en los planes de respuesta a la emergencia, y en la incorporación de medidas de mitigación dentro de los esfuerzos de reconstrucción. El principal problema es la identificación de zonas propensas a daños por terremotos. Si bien en la mayoría de las zonas de alta sismicidad se dispone de alguna información sísmica, puede no ser suficiente para fines de planificación. Las técnicas de percepción remota y la interpretación de datos resultantes podrían proporcionar información adicional.



La actividad tectónica es la principal causa de los terremotos destructivos, seguida por los terremotos asociados a la actividad volcánica. En áreas que presenten un historial de terremotos debidos a la actividad sísmica, las fallas asociadas con dicha actividad pueden ser frecuentemente identificadas sobre imágenes de satélite. Por lo general, la fuente no es tan obvia en lugares donde ocurren terremotos vinculados con la actividad volcánica: puede deberse al movimiento de una falla cerca de la superficie o a profundidad dentro de la tierra, al colapso de una caldera o al movimiento de magma dentro del conducto volcánico.

Para identificar los peligros de terremotos es necesario tener el conocimiento que permite reconocerlos y luego escoger los sistemas de percepción remota que ayuden a demarcarlos de la mejor manera. Las imágenes del LANDSAT han sido usadas extensa y efectivamente para este propósito, dado que sus datos son menos costosos y más fácilmente accesibles que otros de percepción remota. Los mosaicos del radar aéreo han sido usados con éxito para la demarcación de zonas de falla. En general, se pueden producir dos mosaicos por cada área: uno, con la porción de rango lejano del SLAR y el otro con la porción de rango cercano. El primero es de mayor utilidad para áreas de bajo relieve en las que se necesita resaltar rasgos en tanto que, el segundo, para áreas de alto relieve donde no se requiere el efecto de las sombras o donde este efecto puede ser más bien negativo para la imagen.

El radar es aplicable para demarcar la ubicación de depósitos no consolidados en zonas de fallas donde ocurre la mayor destrucción, y así identificar áreas donde un terremoto puede iniciar deslizamientos de tierra. Esto se logra mejor en modelos estereoscópicos, usando líneas de vuelo de radar contiguas y superpuestas. La fotografía aérea convencional, en blanco y negro o a color, también serviría para este propósito.

Una alternativa, adecuada pero de menor bondad que el uso del radar o de la fotografía aérea, es el uso de imágenes multiespectrales obtenidas con los sensores LANDSAT TM y/o SPOT HRV. Los compuestos a color IR o las imágenes sólo en IR cercano de estos sensores, a escalas de hasta 1:100.000, pueden ser utilizados para definir superficies de zonas de fallas activas, pero sus imágenes no son tan eficientes como las del radar. Se puede determinar la diferencia entre roca firme y material no consolidado y las áreas potenciales de deslizamientos de tierra pero, nuevamente, sólo si se dispone de cobertura estereoscópica. Los sensores SPOT pueden proporcionar esa capacidad.

Si bien las imágenes de radar son una fuente ideal de datos, la cobertura es extremadamente limitada y la contratación de radares aéreos es, por lo general, excesivamente cara. Los LANDSAT TM y MSS son la fuente de datos más práctica, simplemente debido a su disponibilidad, y ambos tienen resolución suficiente para los estudios de planificación regional. [9]

2.3.1.4. Erupciones volcánicas y peligros asociados

Muchos peligros están asociados con las condiciones derivadas de la actividad volcánica. Los volcanes activos presentan peligros como la liberación inmediata de cenizas expulsadas, lava, flujos piroclásticos o gases calientes venenosos; terremotos



volcánicos; y, el peligro de flujos de lodo e inundaciones que provienen del rápido deshielo producido alrededor de la chimenea del volcán durante la erupción. Algunos peligros secundarios pueden amenazar tanto durante la actividad volcánica como en época de inactividad. Estos incluyen deslizamientos de tierra debido a acumulaciones inestables de material volcánico, que pueden precipitarse por causa de lluvias prolongadas o por movimientos sísmicos.

Cada volcán tiene su propio comportamiento peculiar en el marco de sus características magmáticas y tectónicas. La predicción del comportamiento de un volcán es sumamente difícil, y la mejor evidencia respecto a la frecuencia y severidad de su actividad es el archivo histórico de sus erupciones. Actualmente, las erupciones inminentes son mejor detectadas mediante el monitoreo sísmico in situ. Algunas clasificaciones distinguen entre volcanes activos, inactivos, dormidos o extintos. Pero, considerando que algunas de las erupciones más catastróficas se deben a volcanes "extintos", muchos volcanólogos han abandonado tal clasificación, y aceptan la diferencia simple que existe entre actividad periódica a corto y a largo plazo.

Los primeros en detectar el calor volcánico mediante la percepción remota de satélite, utilizaron imágenes de IR térmico de un radiómetro IR de alta resolución (HRIR). La interpretación de los datos de percepción remota puede conducir al reconocimiento de eventos catastróficos pasados asociados con volcanes activos recientemente, en términos geológicos, como es el caso de los Andes y las Antillas Menores. Esa información, aunada a datos históricos disponibles, puede ser utilizada como base para evaluar los riesgos de un área con peligro potencial relacionado a los volcanes.

La variada naturaleza y tamaño de los peligros volcánicos requiere del uso de diferentes tipos de sensores, tanto de satélites como de aeronaves. Debe alentarse el uso de la fotografía para el análisis del área relativamente pequeña, circundante a los volcanes. La cobertura aérea estereoscópica, en blanco y negro pancromático, a escalas entre 1:25.000 y 1:60.000, es generalmente adecuada para reconocer y cartografiar evidencias geomórficas de actividad reciente y sus peligros asociados. La fotografía a color, y también a color IR, puede ser útil para determinar los posibles efectos de la actividad volcánica en la vegetación circundante, pero la menor velocidad de la película, menor resolución y su alto costo reducen en gran parte cualquier ventaja.

El barredor térmico aéreo IR es, probablemente, la herramienta más valiosa para examinar el estado geotérmico de un volcán. Es posible detectar tanto el calor interior y subyacente como su desplazamiento. Debido a que la resolución disminuye rápidamente conforme aumenta la altitud (unos 2m por cada 1.000m), las observaciones deben hacerse a altitudes bajas, por debajo de los 2.000 metros.

Un patrón en IR del calor geotérmico en la vecindad de un volcán, es una indicación de la actividad térmica que caracteriza a muchos volcanes inactivos. Una gran cantidad de volcanes considerados extintos tendrían que ser reclasificados si las observaciones aéreas con IR descubrieran emisiones anormalmente altas, en IR, sea de los cráteres en la cima o de los costados. Los cambios en los patrones térmicos para un volcán, sólo pueden ser obtenidos en base a observaciones aéreas de IR, realizadas en



forma periódica y bajo condiciones similares durante la toma de datos. Los cambios de temperatura y emisión de gases, sin embargo, pueden ser monitoreados desde lugares adecuados en tierra, elegidos en base a las imágenes térmicas, lo cual hace innecesarios los sobrevuelos periódicos. El monitoreo electrónico continuo de estas estaciones es posible por medio de la retransmisión de datos usando un satélite geoestacionario, otra fase de la percepción remota.

Las bandas térmicas IR actualmente disponibles en los sensores de satélite, no tienen resolución espacial y térmica adecuada como para que se les asigne valor significativo en la detección de los cambios dinámicos de la actividad geotérmica volcánica. Sin embargo, además de la percepción remota del calor geotérmico, otras técnicas son útiles en la preparación de mapas de zonificación de peligros volcánicos y en la mitigación de los mismos. Las técnicas de mitigación que requieren foto-interpretación y mapas topográficos, incluyen la predicción del recorrido de flujos potenciales de lodo o lava y la restricción del desarrollo en esas áreas. [9]

2.3.1.5. Deslizamientos de tierra

Los deslizamientos de tierra, o movimientos masivos de rocas y material no consolidado, tal como suelos, lodo y derrubio volcánico, son mucho más comunes de lo que generalmente se percibe por la población. Muchas personas son concientes de los deslizamientos catastróficos, pero pocas saben que los pequeños deslizamientos son un problema constante para aquellos involucrados en actividades de diseño y construcción. Estos profesionales, frecuentemente, pueden agravar el problema de los deslizamientos de tierra por deficiente planificación, diseño o prácticas de construcción. A menudo, el ingeniero y el constructor también se ven forzados a situaciones difíciles de construcción o desarrollo como resultado de haber ignorado el peligro potencial de los deslizamientos de tierra. Esto se puede evitar si se reconoce el peligro desde un comienzo y se da la consulta efectiva entre planificadores y el equipo de construcción antes de la planificación detallada del desarrollo.

El movimiento masivo de roca firme y materiales no consolidados tiene como resultado diferentes tipos, magnitudes y velocidades de desplazamientos. El área con peligro potencial de deslizamientos normalmente presenta evidencias de ocurrencias previas, o existen datos históricos. Desafortunadamente, algunos tipos de deslizamiento, especialmente los más pequeños, no pueden ser definidos con imágenes de sensores remotos o con fotografías aéreas. Suele ocurrir que las huellas dejadas por los grandes deslizamientos son evidentes, y aunque los rasgos de los deslizamientos más pequeños puedan no ser individualmente distinguibles, la apariencia áspera general de una pendiente específica puede sugerir que ocurrieron movimientos masivos. Si se dispone de un buen mapa geológico a una escala razonable (1:50.000 o mayor), se podrían examinar los tipos de rocas y/o formaciones susceptibles a deslizamientos para encontrar evidencia de movimientos. Un ejemplo de esto sería encontrar pizarras en una zona de pendientes más pronunciadas que lo normal, lo cual implicaría una fuerte posibilidad de antecedentes de deslizamientos de tierra. El examen de vestigios de ríos frecuentemente muestra desplazamiento en sus cursos debido a deslizamientos. Si uno pudiera separar aquellos segmentos del río tectónicamente controlados, en muchos casos se tornarían evidentes los desplazamientos debidos a deslizamientos o derrumbes.



Los típicos rasgos que conllevan la ocurrencia de deslizamientos incluyen bloques caóticos de roca firme cuya única fuente parece estar pendiente arriba; los farallones o huellas cuyos extremos apuntan hacia abajo en pendientes que parecen normales; protuberancias anormales con vegetación perturbada en la base de la pendiente; grandes depósitos de rocas sedimentarias competentes, u otro tipo de roca estratificada, desplazadas hacia abajo sin evidencia alguna de asociación tectónica; y lenguas de flujos de lodo que se extienden a partir de la base de una huella obviamente erosionada, compuesta de material relativamente no consolidado. Un buen conocimiento de la geología estructural del área de estudio permite poner en perspectiva estas anomalías superficiales. Los deslizamientos pueden ocurrir en pendientes suaves así como fuertes, según las características del terreno.

La mayoría de los debates sobre deslizamientos no consideran el problema de dolinas u hoyadas (sinkholes), que son una forma de deslizamiento de colapso circular. Las áreas características en las que esto ocurre son fáciles de identificar, aún en algunas imágenes de satélite (MSS, TM, SPOT, etc.), debido a su apariencia picada y a la evidencia de drenaje principalmente interno. A pesar de la obvia existencia de muchas dolinas, varias de éstas, de tamaño pequeño, son individualmente muy sutiles y no fácilmente reconocibles. Frecuentemente, estos son lugares de colapso y de posteriores daños a cualquier estructura que sobreyace cuando las aguas subterráneas son utilizadas para satisfacer necesidades de desarrollo, lo cual conduce a la profundización de la capa freática y propicia la inestabilidad del terreno.

La resolución espacial requerida para el reconocimiento de los principales rasgos de deslizamientos de tierra es de unos 10 metros. Sin embargo, tal reconocimiento depende en gran medida de la habilidad y experiencia del intérprete y es facilitada si se dispone de cobertura estereoscópica, cuya adquisición puede resultar costosa. El requerimiento de cobertura estereoscópica y de determinada resolución excluye el uso de la mayoría de las imágenes de sensores en satélites si bien los grandes deslizamientos en bloque pueden ser detectados en imágenes de LANDSAT MSS y TM.

Dado el requerimiento de resolución espacial, las imágenes del SPOT HRV-P (modo pancromático), pueden ser útiles dada su resolución de 10 mts. Sin embargo, su amplia cobertura en banda ancha no conduce al contraste adecuado en escenas que incluyan a los trópicos con densa vegetación, que son lugares donde ocurren la mayor parte de los peligros potenciales. Este hecho está compensado ligeramente si se dispone de cobertura estereoscópica. Es importante comprender que esta capacidad se logra con una programación específica del satélite SPOT y que la cobertura estereoscópica no es normalmente obtenida durante la operación del sensor.

La detección de rasgos de deslizamientos se logra más fácilmente utilizando sensores en aeronaves. La fotografía aérea con su cobertura estereoscópica normal es el mejor sistema de sensores para definir grandes y pequeños deslizamientos. Pueden utilizarse escalas aerofotográficas tan pequeñas como 1:60.000. Las películas pancromáticas en blanco y negro o IR son adecuadas en la mayoría de los casos, pero las de color IR podrían ser mejor en ciertas situaciones. Las emulsiones IR - sensibles, como ya se ha mencionado, eliminan gran parte de la neblina que se encuentra en los



tropicos húmedos. En los modelos estereoscópicos IR aéreos, las aguas al descubierto u otra humedad detrás de derrumbes recientes, son resaltadas como una anomalía, en blanco y negro o a color. La fotografía a color IR podría, en raras ocasiones, demostrar la presión sobre la vegetación a causa de recientes movimientos. Si las escalas son lo suficientemente grandes, también se podría detectar la deformación de los árboles por la progresiva inclinación de la pendiente del suelo.

Un detector más sensible de la humedad, asociada con deslizamientos es el barredor electrónico de IR térmico. Este sensor es especialmente útil para localizar áreas de infiltración que lubrican los deslizamientos. Esto es particularmente efectivo durante la noche, cuando existe la máxima diferencia de temperatura entre el terreno y el agua subterránea que emerge a la superficie. A pesar de su utilidad, muchos factores descartan el uso generalizado del barredor térmico IR. Estos factores incluyen la baja altitud requerida para obtener una resolución espacial razonable, el gran número de líneas de vuelo requerido para la extensa área involucrada, y las distorsiones geométricas inherentes al sistema. Si el terreno por interpretar presenta cierto relieve y carece de características especiales, estas distorsiones se convierten en un problema aún más serio para la interpretación de los datos, al hacer muy difícil la localización de los rasgos.

El SLAR, especialmente el radar de banda-X de apertura sintética, con su resolución nominal de 10m, puede ser marginalmente útil en modo estereoscópico debido a su habilidad para definir algunas texturas mayores relacionadas con los deslizamientos. En algunos ambientes propensos a nubosidad, los radares pueden ser el único sensor que proporcione información interpretable. [9]

2.3.1.6. Desertificación

La desertificación ocurre cuando un ecosistema experimenta disminución o pérdida de productividad. El grado de riesgo de desertificación está directamente relacionado a ciertas condiciones naturales tales como clima, topografía, vegetación natural, suelos, e hidrología, así como a la intensidad y tipo de actividad antrópica¹ en el área. Esta tendencia exige tomar en creciente consideración los procesos de desertificación en los estudios de planificación para el desarrollo integrado. La percepción remota, espacial y aérea, proporciona herramientas valiosas para evaluar áreas propensas a la desertificación. Las transparencias en película, fotografías, y datos digitales pueden ser usadas para el propósito de ubicar, evaluar y monitorear el deterioro de las condiciones naturales en un área determinada. La información sobre estas condiciones puede ser obtenida a partir de mediciones directas o inferidas de indicadores (claves para el reconocimiento de un proceso de desertificación).

Para describir, evaluar y decidir sobre el tipo de acción a tomarse, los siguientes puntos deben ser considerados:

- *Ubicación:* incluye la identificación de áreas que están actualmente bajo proceso de desertificación y áreas que se supone están expuestas a las fuerzas que conducen al deterioro.

¹ La erosión antrópica o acelerada es la provocada por el hombre, muchas veces por supresión o cambio de la vegetación natural.



- *Evaluación: Involucra la identificación y cuantificación de tipos de cobertura de vegetación, suelos, formas de terreno y patrones de cambio en el uso de tierras. La vulnerabilidad al cambio, velocidad de cambio, y dirección del cambio en patrones de desertificación, pueden ser estudiados en base a ésta evaluación.*
- *Monitoreo: Se logra con la detección y medición de cambios en las características del entorno durante un período de tiempo. Se hacen comparaciones entre condiciones presentes y condiciones previamente observadas, con el propósito de conocer la reducción en la productividad biológica.*

Un método más detallado, debe tomar en consideración cuatro conjuntos de datos para el estudio de desertificación de una área dada: datos que se obtienen al final de la estación húmeda, datos que se obtienen al final de la estación seca, y los datos para ambas estaciones que se hubieran obtenido cinco o diez años antes. La selección de datos para un área dada estará directamente relacionada con el nivel de detalle deseado, el tamaño del área, el grado de precisión y exactitud requerido y tiempo disponible.

La fotografía aérea a gran escala, provee una buena cantidad de detalles para este tipo de estudio. Los vuelos de reconocimiento sistemáticos pueden ser usados para el monitoreo ambiental y la evaluación de recursos. Los sensores de radar y barredores infrarrojos pueden ser usados para monitorear la humedad del suelo y otros indicadores de la desertificación. Sin embargo, adquirir este tipo de datos es costoso y consume mucho tiempo.

El uso de imágenes de satélite es recomendado para las primeras etapas de un estudio detallado de desertificación, ya que ofrece una visión general de toda la región. El refuerzo con computadora, compuestos a falso color y las clasificaciones, pueden proporcionar información útil. Se pueden lograr refuerzos ópticos, pero éstos carecen de un control cuantitativo que sí se logra con modelos automatizados. Los datos estadísticos obtenidos de un análisis cuantitativo mediante el uso del sistema de información geográfica (SIG), pueden ser expresados como un histograma, un gráfico, una tabulación, o una nueva imagen.

Las imágenes AVHRR están comercialmente disponibles y han sido usadas para estudios de cambios de vegetación. Una resolución en superficie de 1 a 4 Km. representa limitación para hacer estudios de áreas continentales grandes. Otros estudios han hecho uso de los datos del Nimbus para demarcar patrones de humedad y linderos de la vegetación. Los datos del satélite GOES (Satélite Ambiental Operacional Geoestacionario) han sido usados eficientemente para localizar y medir plumas de polvo; también las imágenes del Seasat SAR han sido aplicadas en la demarcación de la morfología de grandes dunas.

Los datos de LANDSAT MSS y TM, y de SPOT han demostrado ser útiles y costo-efectivos para evaluaciones regionales. Las transparencias de LANDSAT, bandas 5 y 7, han sido utilizadas para monitorear cambios superficiales en áreas que están en proceso de desertificación, y para graficar los actuales cuerpos de agua y antiguos



sistemas de drenaje. Las variaciones temporales tonales del LANDSAT MSS han sido correlacionadas con variaciones en el campo. Los cambios de albedo en terrenos áridos han sido calculados usando datos digitales LANDSAT: los fenómenos que tienden a disminuir la productividad (mayor erosión, pérdida de la densidad de vegetación, deposición de sedimentación eólica) también tienden a parecer más brillantes sobre la imagen. Por el contrario, los fenómenos que propician el aumento de productividad (mayor vegetación, humedad de suelo), tienden a oscurecer el color de la tierra. De esta manera las variaciones en brillo pueden ser detectadas en un área durante un período de tiempo. Estos datos también pueden ser calibrados con datos de superficie obtenidos de las áreas donde ha ocurrido el cambio.

La percepción remota aérea y espacial proporcionan elementos valiosos para estudios de desertificación aunque, como para cualquier otro estudio relacionado con peligros naturales, deben ser combinados con datos recogidos en superficie. El uso de métodos de percepción remota debe minimizar la necesidad de datos en superficie, ahorrando tiempo y resultando, así, relativamente poco costoso por unidad de dato. La combinación de datos de percepción remota obtenidos en superficie puede, por lo tanto, ser la base para la evaluación. [9]

2.3.2 FOTOGRAFÍA AÉREA

La percepción remota aérea, es el proceso de obtener información tal como fotografías e imágenes, con sensores a bordo de aeronaves. Los sistemas aéreos disponibles incluyen cámaras aéreas, barredores electrónicos multiespectrales, barredores electrónicos térmicos infrarrojos (TIR), radiómetros pasivos para producir imágenes con microondas y radares aéreos de vista lateral (SLAR). Los sistemas que ofrecen los datos más prácticos y útiles en el contexto de la planificación para el desarrollo integrado y evaluación de peligros naturales son las cámaras aéreas, los barredores electrónicos multiespectrales, los barredores electrónicos térmicos (TIR) y el SLAR.

La disponibilidad de imágenes de percepción remota aérea varía según el tipo de datos requeridos. La fotografía aérea está disponible para muchas áreas de estudio en la mayor parte del mundo, aunque en algunas ocasiones deberá ser autorizada para uso no militar por el gobierno del país objeto del estudio. Las imágenes de radar suelen tener también carácter reservado.

La adquisición de datos infrarrojos (IR) y de radar es más complicada que la adquisición de fotografías aéreas, aunque para una área extensa, el radar puede resultar menos costoso. Debido a los sistemas especializados y al personal calificado que se necesita para producir imágenes IR y SLAR, tales datos suelen estar a disposición de un número limitado de organizaciones que son dueñas de los sistemas o los alquilan. El costo de movilizar aeronaves, equipos y tripulación es elevado, pero el costo de la cobertura de datos por kilómetro en línea o por unidad de área, puede resultar razonable si el área de sobrevuelo es grande.

De todos los sensores, la fotografía aérea ofrece la interpretación más exacta de lo que ve el ojo humano, en términos de respuesta a la longitud de onda, resolución, perspectiva, visión estereoscópica y valores tonales y de color. El intérprete



familiarizado con las fotografías puede interpretar fácilmente estas escenas, mientras que otros sensores, como los barredores térmicos IR y sistemas SLAR, producen imágenes cuya apariencia y base física es completamente extraña al ojo inexperto. Las fotografías aéreas son probablemente los datos de percepción remota con los cuales el planificador está más familiarizado.

A) Escalas y longitudes de onda

Las escalas más útiles para fotografías aéreas van desde 1:5.000 hasta 1:120.000. La necesidad de información de tipo reconocimiento, sobre extensas áreas, limita el uso de las fotografías a escalas de 1:40.000 o menos.

La fotografía está limitada a longitudes de ondas ópticas compuestas de las porciones ultravioleta (UV), visible e infrarrojo cercano del espectro electromagnético (Figura 4-1). La primera y última de estas porciones son recuperables bajo condiciones especiales de películas y filtros. Las longitudes de onda cercanas a IR corresponden al segmento reflectivo de la mayor parte del infrarrojo, que también incluye longitudes de ondas emitidas o térmicas.

B) Tipos de película

Las fotografías aéreas pueden ser obtenidas con películas blanco y negro, las menos costosas, o a color convencional o color IR. El tipo de película que deberá usarse depende de su aplicabilidad al terreno particular que se está estudiando, y del costo de la película. La velocidad de la película también es factor importante, pues películas a color de baja velocidad no pueden ser utilizadas en terrenos demasiados oscuros tales como áreas con densa vegetación ubicua o rocas predominantemente oscuras.

Los dos tipos generales de películas en blanco y negro utilizados con mayor frecuencia, son las películas pancromáticas y las IR sensibles. Las películas pancromáticas, que son materiales negativos que presentan aproximadamente el mismo rango de sensibilidad a la luz que el ojo humano, son consideradas como la norma para la fotografía aérea. Es el medio más económico para la cartografía aérea y la foto-interpretación, pero puede no ser la alternativa lógica para una determinada área de estudio.

La película en blanco y negro IR sensible, a pesar de no ser de uso común, es una mejor opción para penetrar la neblina y/o una exuberante vegetación, en áreas tropicales húmedas. Proporciona mucho mejor contraste para aguas superficiales, humedad y vegetación, que la película normal y, como resultado, puede ser una herramienta efectiva en la planificación regional y en las evaluaciones de peligros naturales en áreas tropicales húmedas. Existe, sin embargo, una disminución de detalle en áreas en sombra debido al filtrado de la luz dispersa más fría (extremo azul).

En áreas de alto relieve, es mejor fotografiar cerca del mediodía con película IR. En áreas de bajo relieve, se deben tomar las fotografías cuando el sol se encuentra cerca del horizonte (10°-30°), produciendo sombras sobre superficies de textura fina. La fotografía con ángulo solar bajo (LSAP) resaltan las características de textura de determinados tipos de roca, las discontinuidades y rasgos topográficos lineales asociados con fallas y fracturas. También se pueden definir tipos de vegetación natural



y cultivada, en gran parte por la textura, lo cual proporciona información adicional respecto al terreno. Casi cualquier cámara aérea moderna puede obtener LSAP usando película pancromática o infrarrojo con filtro rojo.

La película a color se usa de varias formas para la evaluación de los peligros naturales: película negativa de la cual se producen fotos a color y transparencias positivas, incluyendo diapositivas a color. Hasta cierto punto, las películas negativas pueden ser copiadas en papel para resaltar ciertos colores y facilitar su manejo. Sin embargo, éstas no poseen la nitidez y el rango dinámico de color de las transparencias positivas, las cuales son significativamente mejores para propósitos de interpretación. Existen dos tipos espectrales principales de película a color: la película a color natural o convencional, que cubre el espectro visible, y la película a color IR (desde el verde hasta el IR cercano). La primera se encuentra disponible como película en negativo (copias en papel) y transparencias positivas, y la segunda está disponible sólo como una transparencia positiva.

La respuesta de las películas a color IR es superior a la de las películas a color natural por varias razones. Primero, el filtro amarillo requerido para su uso apropiado elimina la luz azul que se dispersa preferentemente por la atmósfera. Al eliminar gran parte de tal dispersión, mejora enormemente el contraste. Segundo, las diferencias de reflectancia entre los tipos de vegetación, suelos y rocas son comúnmente mayores en el componente fotográfico IR de esta película. Tercero, la absorción del infrarrojo por el agua y gran parte de las longitudes de onda roja, permiten una definición más clara de depósitos de agua y de áreas con contenido de humedad. Y cuarto, la disminución de luz dispersa en áreas en sombra realza detalles de relieve, mejorando así la interpretación de la geomorfología. En vista de estos atributos, se prefiere la película a color IR si es que se desea fotografía aérea a color en climas tropicales húmedos. [9]

2.3.3 IMÁGENES MULTIESPECTRALES

Una imagen adquirida desde el espacio presenta menos errores que una fotografía aérea, como consecuencia de la mayor estabilidad y altura de vuelo de la plataforma. Esto no quiere decir que estas imágenes estén libres de errores geométricos, y que puedan suponerse directamente sobre la cartografía básica.

El carácter multiespectral de las imágenes espaciales resulta básico de cara a su interpretación. Se producen por la combinación de imágenes, en que se graban diferentes intervalos de longitudes de onda o diferentes bandas espectrales usando una misma escena. Tres bandas de longitud de onda se pueden combinar para formar imágenes en color. La posibilidad de observar un fenómeno en diversas bandas del espectro amplía notablemente nuestra capacidad de reconocerlo. Cada cubierta ofrece un comportamiento espectral tipo, en función de las características de sus componentes, que denominamos *signatura espectral*. Un intérprete puede acostumbrarse a observar las masas vegetales con tonos oscuros en las bandas visibles y claros en el infrarrojo cercano, sin considerar los factores que inciden en ese fenómeno. No cabe duda que si éstos se tienen presentes en la interpretación de la imagen, resulta más fácil adaptarlos a zonas o categorías peor conocidas, convirtiendo la teledetección en una técnica aplicable a contextos más amplios.



No quiere esto decir que los tonos de gris sean una traducción estricta de las curvas de reflectividad, son más bien, una traducción de los valores numéricos almacenados por el sensor, consecuencia, a su vez, de esa reflectividad, pero no identificables con ella, ya que cuentan también los valores de calibración del sensor y los efectos atmosféricos. [2]

Finalmente se muestra un ejemplo de una imagen multispectral adquirida por el LANDSAT con sensores de percepción remota de la India:




Figura 2 - 14 (Ejemplo de Imagen multispectral) [52]

2.3.4 IMÁGENES SAR

El radar difiere de la aerofotografía como sensor remoto aéreo. La fotografía es un sistema de percepción remota que utiliza la reflexión natural del sol, en tanto que el radar es un sensor activo que produce su propia iluminación. El radar ilumina el terreno y luego recibe y ordena las señales reflejadas sobre una imagen que puede ser evaluada. Estas imágenes se parecen a las fotografías en blanco y negro. El mejor uso de las imágenes obtenidas con radares aéreos, en el proceso de planificación para el desarrollo y evaluaciones de peligros naturales es la identificación de características geológicas y geomorfológicas. Las imágenes de radar, así como la fotografía, presentan variaciones de tono, textura, forma y patrones que corresponden a diferencias en rasgos y estructuras en la superficie. De estos elementos, las variaciones de tono que se observan en las fotografías aéreas convencionales son las mismas que se ven con los ojos. Las variaciones de tono que presentan las imágenes de radar y que



aparecen como propiedades no familiares, son el resultado de la interacción de la señal del radar con el terreno y la vegetación. Así como para poder hacer uso de fotografías aéreas no es esencial comprender del todo la teoría óptica y sus procesos propios, también es posible utilizar las imágenes de radar sin entender cabalmente lo concerniente a la radiación electromagnética.

Sin embargo, el intérprete experimentado debe saber algo sobre cómo se forma la imagen, para poder interpretarla correctamente y apreciar plenamente el potencial y las limitaciones del radar. Un intérprete capacitado sólo necesita familiarizarse con los parámetros que controlan el eco del radar, entender sus efectos sobre la señal de retorno, y reconocer los efectos de la configuración lateral del sensor sobre la geometría de la señal de retorno.

Muchas imágenes útiles de radar han sido obtenidas en longitudes de onda de las bandas X, K y Ka (ver Figura 4-2). Sin embargo, los contratistas comerciales ofrecen generalmente los sistemas de radar aéreo en la banda X. En este ancho de banda existen dos tipos básicos de sistemas: el radar de apertura real (RAR) y el radar de apertura sintética (SAR). Los radares de apertura real, o "fuerza bruta", utilizan una antena de la mayor longitud práctica posible para producir un haz de iluminación de ángulo muy delgado en la dirección azimutal (línea de vuelo). A mayor longitud de antena, más delgado será el haz azimutal. Una longitud típica es 4,5 mts., la cual se aproxima al tamaño máximo práctico para las aeronaves. Por esta razón, se desarrolló el SAR. El SAR es capaz de lograr una mayor resolución sin la necesidad de una antena físicamente grande, mediante un complicado procesamiento electrónico de la señal de radar.

La resolución resultante, unida a las pequeñas escalas a las que se pueden obtener imágenes, hace que el radar sea más útil que la observación fotográfica cuando se trata de cubrir grandes extensiones. Si bien el RAR es de diseño simple y no requiere grabación ni procesamiento sofisticado de datos, la resolución en la dirección de su alcance es relativamente limitada si la comparamos con la del SAR de igual longitud de onda. El SAR mantiene su alta resolución a grandes distancias en la dirección de su alcance y también mantiene su resolución azimutal. La resolución con el SAR es cercana a los 10 m. en azimut y alcance. [9]



3. PRINCIPALES SATÉLITES DE PERCEPCIÓN REMOTA

3.1 ENVISAT




Figura 3 - 1(Satélite ENVISAT en órbita) [20]

ENVISAT (Figura 3 - 1) es un satélite europeo avanzado para la observación de la Tierra, cuyas características son que emite una multitud de frecuencias algunas de las cuales podemos recibir. Comenzó su viaje de 5 años al espacio el 1 de Marzo de 2002. Su misión es la de "vigilar" la Tierra, para de esta forma poder controlar el calentamiento global, el grado de la contaminación atmosférica y los riesgos de desastres naturales para poder mitigar sus efectos.

El ENVISAT, desarrollado por los científicos y técnicos más prestigiosos y de mayor talento de Europa, es el satélite para la observación de la Tierra más ambicioso del mundo. A bordo, el vehículo lleva 10 instrumentos extremadamente sofisticados (Figura 3 - 3), que funcionan noche y día, en todas las posibles condiciones atmosféricas, recogiendo datos fundamentales acerca del medio ambiente.

El ENVISAT es la fuente más importante de información medioambiental de la Tierra, y ayuda a Europa a desempeñar un papel importante en el campo de las cuestiones medioambientales mundiales. [19]



Su peso es de 8.2 toneladas. Para esta misión, que bate todos los récords de lanzamiento de peso, el Ariane-5 fue equipado por primera vez con una cápsula en su extremo de 17 metros que envuelve y protege al mayor satélite construido jamás en Europa, según el consorcio europeo Arianespace. El ENVISAT fue fabricado por un consorcio de cincuenta empresas bajo la dirección de ASTRIUM¹, ENVISAT quedó situado en una órbita geoestacionaria casi polar.

Tras desplegar sus antenas solares, ENVISAT alcanzó una dimensión de 25 metros de largo por 10 de ancho y da una vuelta a la Tierra cada cien minutos aproximadamente. [20]

Una vez en órbita, que está inclinada 98 grados con respecto al Ecuador, sobrevuela los polos a 800 Km. de altitud y puede analizar siempre las zonas a la misma hora solar. Desde esa posición privilegiada, nada escapa a los diez sofisticados instrumentos con los que va equipado; puede detectar: gases de efecto invernadero, cambios del nivel de los océanos, fundición de glaciares, destrucción de bosques tropicales, restos de hidrocarburos en el mar, inundaciones, erupciones volcánicas o el fenómeno de "El Niño", etc.

Los instrumentos GOMOS, MIPAS y SCIAMACHY tienen la misión de sondear y cartografiar la atmósfera, con el fin de determinar las concentraciones de gases de efecto invernadero o los contaminantes industriales, y seguir la evolución del agujero en la capa de ozono. SCIAMACHY analiza también los efectos de los incendios forestales, de las tormentas de polvo y las erupciones volcánicas.

El espectrómetro MERIS capta los colores de los mares y océanos, de forma que ve, por ejemplo, el paso del azul normal al rojo característico de la proliferación de algas, identifica los diferentes estados en el crecimiento de las plantas y medirá los niveles de clorofila.




Figura 3 - 2 (Antena del Sistema DORIS del ENVISAT) [18]

¹ ASTRIUM: consorcio aerospacial europeo, del que forman parte cincuenta compañías. A la industria espacial española, por ejemplo, le ha correspondido el 4.42 % del proyecto ENVISAT. La carcasa que sustenta los equipos y los paneles del radar principal fueron tarea de CASA. Y empresas como GMV, CRISA, Sener y Alcatel España, se hicieron cargo de programas informáticos y sistemas electrónicos.



La Figura 3 – 2 muestra la antena del sistema DORIS, un sistema que consta de:

- Un receptor con dos cadenas de recepción
- Un oscilador de cristal muy estable
- Una antena omnidireccional bibanda
- Una unidad de control

Cada 10 segundos el receptor mide el cambio de doppler de las señales transmitidas continuamente desde balizas en tierra en las frecuencias de 2036.25 MHz y 401.250 MHz. El oscilador del sistema DORIS obtiene la referencia de las mediciones de forma fiable. Los receptores del satélite pueden seguir dos balizas simultáneamente.

El sistema RA-2 emite un poco mas arriba, en 13.575 Ghz (banda Ku) y 3.2 GHz (Banda S). [18]

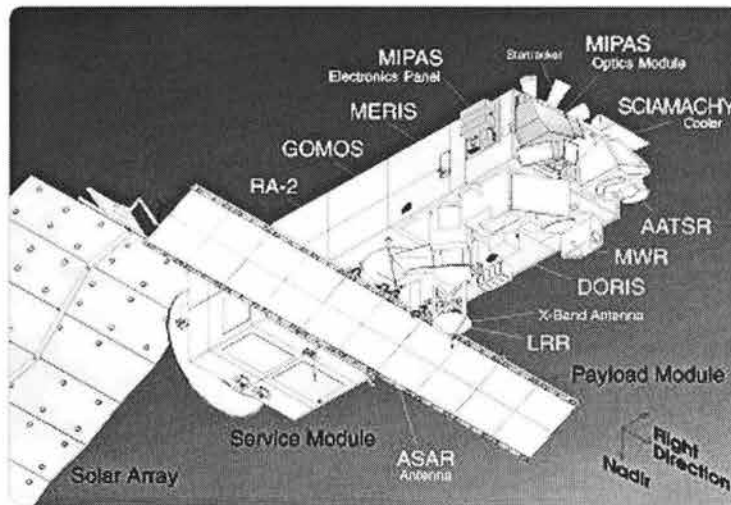


Figura 3 - 3 (Instrumentos del ENVISAT) [20]

En el Apéndice B se muestra una tabla (Tabla B - 1) con todos los instrumentos y sistemas que componen al ENVISAT, y otra (Tabla B - 2) que resume las especificaciones técnicas del mismo.



A continuación se muestran 3 imágenes obtenidas con el satélite ENVISAT:

➤ *Primera Imagen del ENVISAT (Figura 3 - 4).*

Fecha de recibida: 22/Marzo/2002

Instrumento usado: MERIS

La primera observación del MERIS capturó una gran capa de fitoplancton producida por el mecanismo de "upwelling"² a lo largo de la costa de Mauritania. La resolución sin precedente permite que estructuras de escala fina sean detectadas [20]



Figura 3 - 4 (Primera Imagen del ENVISAT) [20]

² *Upwelling: transporte de las aguas profundas hacia niveles poco profundos.*



➤ **Mosaico del mundo (Figura 3 - 5).**

Fecha de recibida: Marzo/2003

Instrumento usado: MERIS

Este es un mosaico hecho de imágenes con colores verdaderos, adquiridas en Marzo de 2003 usando 3 de las 15 bandas espectrales tomadas del ENVISAT en su órbita polar a una altitud de 800 Km., con datos combinados de alrededor de 500 segmentos separados con la intención de minimizar la nubosidad tanto como fuera posible. La imagen original tiene una resolución de 1.2 Km., y está hecha de 40,000 por 50,000 píxeles, lo que es igual a 2.5 Gb. de datos. [20]



Figura 3 - 5 (Mosaico del Mundo) [20]

➤ **Huracán Isabel (Figura 3 - 6).**

Fecha de recibida: 8/Septiembre/2003

Instrumento usado: MERIS

Estas imágenes muestran al huracán Isabel (calificado como huracán de categoría 3 en el tiempo que la imagen fue adquirida) localizado 2000 kilómetros al este de las Islas Leeward y moviéndose al noroeste en el Océano Atlántico a aproximadamente 22.5 kilómetros por hora. La imagen de la izquierda, resultante de una composición de colores (Rojo-865 nm, Verde-560 nm, Azul-412.5 nm), muestra la perfecta organización del huracán y de su ojo; así como, las estructuras nubosas delgadas asociadas con la convección dentro de la pared del ojo. La imagen de la derecha muestra la presión sobre las nubes que como puede ser observada en la imagen varía enormemente de los 360 hPa (aproximadamente 8 Km.) en los brazos de la espiral a los 800 hPa (aproximadamente 2 Km.) en el centro del huracán. [20]




Figura 3 - 6 (Huracán Isabel) [20]



3.2 LANDSAT

El programa LANDSAT, desarrollado por la NASA, fue originalmente denominado *Earth Resources Technology Satellite - ERTS*. Fue el primer programa de satélites de percepción remota para observación de los recursos terrestres, puesto en órbita terrestre. El primer satélite, de carácter experimental, fue construido para demostrar la viabilidad de mapear y monitorear rasgos de la superficie de la Tierra a partir de imágenes orbitales. Este programa fue desarrollado con el objetivo de posibilitar la adquisición de imágenes de la superficie de la Tierra de manera global y repetitiva.

El primer satélite de esta serie fue lanzado el 23 de julio de 1972 con la denominación de *ERTS-1*. El 14 de enero de 1975 el nombre fue cambiado para *LANDSAT - LANDSATellite*, y el 22 de enero fue lanzado el segundo satélite, entonces denominado *LANDSAT-2*. [21]

De la serie LANDSAT ya fueron lanzados los siguientes satélites (Tabla 3 - 1):

Satélite	Lanzamiento	Fin de operación	Sistemas Sensores	Vehículo de Lanzamiento	Sitio de Lanzamiento
<i>ERTS-1</i>	23 / julio / 1972	02 / enero / 1978	MSS e RBV	Delta 900	Base de la Fuerza Aérea de Vandenberg, California
<i>LANDSAT-2</i>	22 / enero / 1975	25 / febrero / 1982	MSS e RBV	Delta 2910	Base de la Fuerza Aérea de Vandenberg, California
<i>LANDSAT-3</i>	05 / marzo / 1978	31 / marzo / 1983	MSS e RBV	Delta 2910	Base de la Fuerza Aérea de Vandenberg, California
<i>LANDSAT-4</i>	16 / julio / 1982	En órbita	MSS e TM	Delta	Base de la Fuerza Aérea de Vandenberg, California
<i>LANDSAT-5</i>	01 / marzo / 1984	En órbita	MSS e TM	Delta	Base de la Fuerza Aérea de Vandenberg, California
<i>LANDSAT-6</i>	05 / octubre / 1993	05 / octubre / 1993	ETM	Titan-2(23)G Star-37XFP-ISS	Base de la Fuerza Aérea de Vandenberg, California
<i>LANDSAT-7</i>	15 / abril / 1999	En órbita	ETM+	Delta-7920-10C	Base de la Fuerza Aérea de Vandenberg, California

Tabla 3 - 1 (Serie LANDSAT) [21 - 31]

3.2.1 ERTS-1, LANDSAT-2, LANDSAT-3

Los tres primeros satélites de la serie LANDSAT fueron construidos a partir de una modificación del satélite meteorológico NIMBUS. Tenían una órbita circular, casi polar, sincrónica con el sol, a una altura aproximada de 917 Km. Durante su período de operación, los satélites realizaban una órbita completa al rededor de la Tierra cada 103 minutos y 27 segundos, recubriendo 14 bandas de la superficie terrestre por día. La configuración de estos tres satélites fue concebida de modo que cada 18 días ellos pasaban sobre la misma región de la superficie de la Tierra. El horario medio de pasaje de los satélites por el Ecuador era a las 09:30, horario local y su tasa de transmisión de datos era de 15 Mbps.



Estos tres satélites llevaban a bordo dos sistemas sensores:

- **Sistema Return Beam Vidicon – RBV (Tabla 3 - 2)** - fue el primer sistema sensor a ser proyectado para obtener imágenes a bordo del LANDSAT. Era un sistema que observaba toda la escena registrada en forma instantánea, constituido por cámaras de televisión (tres en los satélites ERTS 1 y LANDSAT 2, y dos en el LANDSAT 3), operaba en una banda comprendida entre el visible y el infrarrojo próximo del espectro electromagnético. La escena terrestre registrada por la cámara representaba un área de 185 Km. La resolución espacial de este sistema en los satélites ERTS 1 y LANDSAT 2 era de 80 x 80 m, con tres bandas espectrales (verde, rojo e infrarrojo próximo) y en el LANDSAT 3 era de 30 x 80 m, con una banda espectral (pancromático).

Satélite	Cámaras	Banda Espectral (µm)	Aplicaciones
ERTS-1 y LANDSAT-2	1	0.475-0.575(verde)	diferenciación entre suelo y vegetación
	2	0.580-0.680(rojo)	mapeamiento de vegetación
	3	0.690-0.830(rojo)	delineamiento de cuerpos de agua
LANDSAT-3	1	0.505-0.750(pancromático)	mapeamiento de áreas urbanas, vegetación y agricultura

Tabla 3 - 2 (Sistema RBV) [21]

- **Sistema Generador de Imágenes Multiespectral (Multispectral Scanner Subsystem) - MSS (Tabla 3 - 3)** - colocado a bordo del LANDSAT por insistencia de los investigadores del Departamento de Agricultura de los Estados Unidos, que querían probar un sistema multiespectral para estudios agrícolas. Este sensor es un equipo de barradura óptico-electrónica, que opera en cuatro bandas del espectro electromagnético, dos en el visible (canales 4 y 5) y dos en el infrarrojo próximo (canales 6 y 7). La escena terrestre observada por este sensor representaba un área de 185 Km. y la resolución espacial era de 80 x 80 m. En el LANDSAT 3 fue agregado un canal en la banda del infrarrojo termal (canal 8), cuya resolución era de 240 m, que captaba la radiación emitida por los objetos terrestres. [21]

Satélite	Canales	Bandas Espectrales (µm)	Aplicación
ERTS-1, LANDSAT-2, LANDSAT-3	4	0.5-0.6(verde)	uso del suelo, vegetación, áreas urbanas, calidad del agua
	5	0.6-0.7(rojo)	diferenciación de especies vegetales, agricultura, calidad de agua, áreas urbanas
	6	0.7-0.8(infrarrojo próximo)	delineamiento de cuerpos de agua, mapeamiento geológico, mapeamiento geomorfológico, áreas húmedas
	7	0.8-1.1(infrarrojo próximo)	delineamiento de cuerpos de agua, mapeamiento geológico, mapeamiento geomorfológico, áreas húmedas, fuegos
LANDSAT-3	8	10.4-12.6 (infrarrojo termal)	corrientes marinas, diferencias de temperatura de los objetos de la superficie terrestre

Tabla 3 - 3 (Sistema MSS) [21]



3.2.2 LANDSAT-4, LANDSAT-5

Estos dos últimos satélites de la serie LANDSAT sufrieron algunas modificaciones tanto en la forma de la plataforma como en sus características orbitales. La altitud fue modificada de 917 Km. para 705 Km., el ciclo de recubrimiento pasó de 18 días para 16 días, y el período orbital pasó de 103 minutos para 98,9 minutos. El horario medio de pasaje por el Ecuador continuó siendo 09:30, horario local, teniendo una tasa de transmisión de datos de 85 Mbps. [21]

Otra diferencia importante de este satélite fue el sistema sensor con el que fue equipado que cambió de ser el RBV, para ser el sistema que se conoce como TM, que se describe a continuación, el sistema MSS siguió operando en estas dos versiones del LANDSAT. Cabe resaltar que la transmisión de datos del sistema TM del satélite LANDSAT 4 falló en Agosto de 1993. [23]

- **Sistema Thematic Mapper – TM (Tabla 3 - 4) - tal como su antecesor, el TM, es un sensor de barrido multiespectral, avanzado, concebido para proporcionar una resolución espacial más fina, mejor discriminación espectral entre los objetos de la superficie terrestre, mayor fidelidad geométrica y mayor precisión radiométrica. Opera simultáneamente en siete bandas espectrales, siendo tres en el visible, una en el infrarrojo próximo, dos en el infrarrojo medio y una en el infrarrojo termal. Tiene una resolución espacial de 30 metros en las bandas del visible e infrarrojo reflejado y 80 metros en la banda del infrarrojo termal. La escena terrestre registrada por este sensor es también de 185 Km. [21]**

No de Banda	Banda Espectral (μm)	Aplicaciones
1	0.45-0.52(azul)	mapeamiento de aguas costeras, diferenciación entre suelo y vegetación, diferenciación entre vegetación conifera y decidua
2	0.52-0.60(verde)	mapeamiento de vegetación, calidad de agua
3	0.63-0.69(rojo)	absorción de la clorofila, diferenciación de especies vegetales, áreas urbanas, uso del suelo, agricultura, calidad de agua
4	0.76-0.90(infrarrojo próximo)	delineamiento de cuerpos de agua, mapeamiento geomorfológico, mapeamiento geológico, áreas de incendios, áreas húmedas, agricultura, vegetación
5	1.55-1.75(infrarrojo termal)	uso del suelo, medidas de humedad de la vegetación, diferenciación entre nubes y nieve, agricultura, vegetación
6	10.40-12.50(infrarrojo termal)	mapeamiento de estrés térmico en plantas, corrientes marinas, propiedades termales del suelo y otros mapeamientos térmicos
7	2.08-2.35(infrarrojo medio)	identificación de minerales, mapeamiento hidrotermal

Tabla 3 - 4 (Sistema TM) [21]

3.2.3 LANDSAT-6, LANDSAT-7

El LANDSAT 6 se lanzó en 1993 pero por fallos de comunicación con la plataforma no se ubicó en la órbita precisa y se perdió. Este fracaso y el dudoso éxito de la gestión privada hicieron temer por el futuro de estos satélites. No obstante, se inicia el proyecto LANDSAT 7 bajo un programa en el que participan 3 agencias: la



NASA como responsable del desarrollo y lanzamiento del satélite, así como del sector de tierra, la NOAA que se encargó de su operación y mantenimiento durante todo el tiempo de vida del satélite, y la USGS que recoge, procesa y distribuye los datos, encargándose de mantener el archivo de datos. [53]

La altura de vuelo del LANDSAT 7 se reduce de 917 a 705 Km., aunque se mejora el ciclo de recubrimiento, de 18 a 16 días, gracias a su menor periodo orbital (98.9 grados). Sin embargo, el momento de adquisición se mantiene en torno a las 9:45 horas local en nuestras latitudes.

- **Sistema Enhanced Thematic Mapper – ETM+(Tabla 3 - 5)** - el LANDSAT 7 está equipado con una versión mejorada del TM por lo que todo lo explicado en este apartado para el TM es de aplicación para el ETM+. Este sistema incorpora una banda pancromática (0.5 a 0.9 μm) con una resolución espacial de 15 m, lo que permite obtener ampliaciones a una escala de hasta 1:25.000. [21]

No de Banda	Banda Espectral (μm)	Aplicaciones
1	0.45-0.52(azul)	mapeamiento de aguas costeras, diferenciación entre suelo y vegetación, diferenciación entre vegetación conífera y decidua
2	0.53-0.61(verde)	mapeamiento de vegetación, calidad de agua
3	0.63-0.69(rojo)	absorción de la clorofila, diferenciación de especies vegetales, áreas urbanas, uso del suelo, agricultura, calidad de agua
4	0.78-0.90(infrarrojo próximo)	delineamiento de cuerpos de agua, mapeamiento geomorfológico, mapeamiento geológico, áreas de incendios, áreas húmedas, agricultura, vegetación
5	1.55-1.75(infrarrojo termal)	uso del suelo, medidas de humedad de la vegetación, diferenciación entre nubes y nieve, agricultura, vegetación
6	10.40-12.50(infrarrojo termal)	mapeamiento de estrés térmico en plantas, corrientes marinas, propiedades termales del suelo y otros mapeamientos térmicos
7	2.09-2.35(infrarrojo medio)	identificación de minerales, mapeamiento hidrotermal
PAN	0.5-0.9(pancromático)	mapeamiento de áreas urbanas, vegetación y agricultura

Tabla 3 - 5 (Sistema ETM+) [21]

Este proyecto ha culminado con el lanzamiento en 1999 del LANDSAT 7, que se espera tenga una vida de cinco años. El LANDSAT 7 parece abrir nuevas expectativas en la distribución y comercialización de los datos con el abaratamiento de los productos y el consiguiente acceso a un mayor número de usuarios. [53]



A continuación se muestran 3 imágenes obtenidas con el satélite LANDSAT 7:

➤ *Bagdad, Irak (Figura 3 - 7).*

Fecha de recibida: 2/Abril/2003

Instrumento usado: ETM+

Esta imagen de Bagdad, Irak fue adquirida el 2 de Abril de 2003, con el LANDSAT 7 en "Color Verdadero" con las bandas 1-2-3. [32]



Figura 3 - 7 (Bagdad, Irak) [32]

➤ *Ciudad de México (Figura 3 - 8).*

Fecha de recibida: 6/Enero/2001

Instrumento usado: ETM+

La Ciudad capital de México fue captada con su población de alrededor de 18 millones de personas. [33]




Figura 3 - 8 (Ciudad de México) [33]



— *Cancún Quintana Roo, México (Figura 3 - 9).*

Fecha de recibida: 17/Abril/2001

Instrumento usado: ETM+

Cancún está localizado hacia el noreste de la península de Yucatán en México, en el estado de Quintana Roo. Cancún posee fina arena blanca rodeada de aguas color turquesa. [33]



Figura 3 - 9 (Cancún Quintana Roo, México) [33]



3.3 SPOT




Figura 3 - 10 (Ubicación orbital de los satélites del programa SPOT) [39]

El programa SPOT (Système Probatoire d'Observation de la Terre) fue planeado y proyectado como un sistema operacional y comercial. El programa de observación de la tierra mediante los satélites SPOT (Figura 3 - 10) ha sido desarrollado por Francia con la participación de Suecia y Bélgica. El primer satélite SPOT se lanzó en 1986 y la continuidad del programa se mantiene sin inconvenientes. Este programa está administrado por la CNES (Centre National d'Études Spatiales), una agencia espacial francesa responsable del desarrollo del programa y de la operación de los satélites.




Figura 3 - 11 (Cronología de los satélites del programa SPOT) [38]



Ya fueron lanzados los satélites SPOT 1, 2, 3, 4 y 5 (Figura 3 - 11). El SPOT 3 desafortunadamente sufrió algunos problemas técnicos y tuvo que dejar de funcionar el 14 de Noviembre de 1996, pero los satélites SPOT 1, 2, 4 y 5 actualmente siguen en funcionamiento.

Una característica importante de los satélites SPOT es su capacidad de visión oblicua, que hace posible la obtención de pares estereoscópicos por combinación de dos imágenes de la misma área obtenidas en diferentes fechas y en diferentes ángulos. [34]. Su capacidad para variar el ángulo de observación es gracias a un dispositivo móvil instalado en el equipo óptico. Esto le permite observar la misma zona en órbitas sucesivas, reduciendo la frecuencia temporal de las imágenes (de 26 días a 2-3 días según las latitudes). Esta misma aptitud, permite al SPOT adquirir imágenes estereoscópicas, lo que añade a su potencial temático una clara capacidad topográfica. Otra importante novedad de este satélite, se cuenta la incorporación de dos equipos de exploración por empuje denominados HRV (Haute Résolution Visible). Estos dos sensores permiten obtener imágenes en dos modalidades: pancromático y multibanda (verde, rojo e infrarrojo cercano), con una resolución espacial de 10 y 20 m, respectivamente (Tabla 3 - 6). El área cubierta en cada escena es de 60 Km. de lado, por lo que estos sensores necesitan incorporar 3,000 detectores en modo multi-espectral y 6,000 en modo pancromático. La resolución radiométrica por píxel se cifra en 8 bits en multibanda y 6 en pancromático. [39]

Banda	Amplitud	Resolución
XS1	0.50 - 0.59 μm	20 metros
XS2	0.61 - 0.68 μm	20 metros
XS3	0.79 - 0.89 μm	20 metros
P	0.51 - 0.73 μm	10 metros

Tabla 3 - 6 (Características del sensor HRV - SPOT) [38]


Esta capacidad del sistema SPOT le permite cubrir un área de 950 Km., paralela a la dirección de movimiento del satélite y centrada en su órbita, permitiendo también aumentar la frecuencia de cobertura de una determinada área.

La mejora en resolución espacial frente al sensor TM hace a las imágenes SPOT idóneas para tareas de análisis visual, especialmente en el medio urbano. Así mismo, se han desarrollado técnicas para combinar el canal pancromático de SPOT con imágenes TM, de tal forma que se aproveche la resolución espectral de este último, recogiendo de alguna forma la resolución espacial del primero.

En lo que se refiere a clasificaciones temáticas a partir de estas imágenes, aún no ha quedado patente su superioridad frente a las imágenes TM. En otras palabras, todavía no se ha evaluado con rigor qué supone la mejora en resolución espacial frente a la pérdida en espectral para identificar tipos de cubierta. No obstante, la práctica de la comunidad científica parece mantener su confianza en el sensor TM, por cuanto la dimensión espectral es básica en determinados estudios medio ambientales. [38]



3.3.1 SPOT-1, SPOT-2, SPOT-3



Spot 1, 2, 3

Figura 3 - 12 (Modelo de los satélites SPOT 1,2 y 3) [38]

El 22 de Febrero de 1986, un vehículo de lanzamiento de la serie Ariane ponía en órbita el primer satélite de la familia SPOT, el SPOT 1 (Figura 3 - 12). Dos días más tarde, transmitía su primera imagen, que presentaba características únicas: resolución espacial de 10 a 20 metros y la posibilidad de restaurar la calidad de la imagen con margen de algunos metros gracias a su capacidad de visión lateral. El 6 de mayo de 1986, SPOT 1 es declarado operacional. Doce años más tarde, en 1998, su capacidad de almacenamiento deja de existir; sin embargo, SPOT 1 sigue enviando siempre imágenes de gran calidad. La duración de la vida de este satélite, como la de sus sucesores, estaba calculada para 2 años.

El satélite SPOT 2 fue lanzado el 22 de enero de 1990, pero perdió sus capacidades de almacenamiento en 1993, todavía funciona, pero en modo de transmisión directa. De la misma forma que su precursor, SPOT 2, fue el primer satélite de esta serie en portar el instrumento de posicionamiento de precisión, DORIS. Desafortunadamente el SPOT 1 y el SPOT 2 perdieron un canal de emisión en la banda X debido a una falla en un tubo de transmisión.

El tercer modelo de esta serie, SPOT 3, perdió su órbita el 26 de septiembre de 1993, debido a una falla en el sistema de control de altitud, se hizo inutilizable después del 14 de noviembre de 1996. Una comisión de investigación dio en febrero de 1997 un análisis de las causas del accidente. Este sistema también llevaba a bordo el sistema DORIS, además de un sistema de carga americano llamado POAM II, usado para medir el ozono en la atmósfera de los polos.

Los satélites SPOT 1 y SPOT 2 aún están en funcionamiento, pero en modo de transmisión directa, pues su capacidad de almacenamiento se ha agotado. SPOT 3 debido a su falla en 1996, alcanzó el final de su vida nominal como misión. [38]

En el Apéndice B, se muestra una tabla (Tabla B - 3) que resume las principales características técnicas del programa SPOT en todas sus versiones, y de la misma forma se enuncia en 3 tablas más los datos y características referentes a los



instrumentos sensores de alta resolución (Tabla B - 4) y los instrumentos estereoscópicos (Tabla B - 5) de este satélite.

Los sistemas SPOT 1, 2 y 3 no portaban el instrumento VEGETATION, es por ello que no se muestran características del mismo.

3.3.2 SPOT-4

El satélite SPOT 4 (Figura 3 - 13), cuya realización fue decidida en julio de 1989 dentro del mismo marco de cooperación con Suecia y Bélgica, fue lanzado el 24 de marzo de 1998. Tiene capacidades de hacer observaciones avanzadas, lo que le permite enfrentar ambientes cada vez más competentes.

Las instrumentos principales HRVIR y VEGETATION para el estudio de la biosfera y de las culturas son complementados con instrumentos tecnológicos o científicos como: DORIS, ESBT, PASTEL, PASTEC, POAM III y VEGA.




Figura 3 - 13 (Modelo del satélite SPOT 4) [41]

1. HRVIR's, están diseñados para adquirir, instantáneamente, una línea completa de píxeles en un momento, cubriendo el campo completo de vista. Esto es llevado a cabo usando un dispositivo de carga doble (Charged-Couple Device CCD) con un arreglo lineal.
4. POAM III, se trata de un experimento administrado por el Laboratorio de Investigación Naval de los Estados Unidos (NRL) para medir la distribución vertical de componentes atmosféricos por medio de la ocultación solar.
6. DORIS, idéntico al instrumento a bordo de los satélites previos de la serie SPOT. Este sistema, usado desde el SPOT 2, usa procesamiento en base a la Tierra para determinar la posición del satélite con un rango de 10 cm.
7. VEGETATION, es un sistema completo y autónomo hecho de los siguientes subsistemas: un conjunto de 4 cámaras independientes, un módulo de procesamiento de imágenes para la sincronización de tasas de transmisión y formatos, un sistema de administración a bordo para la activación y el




monitoreo del equipo, un sistema de almacenamiento de hasta 97 minutos de grabación de imágenes, un sistema de telemetría para la transmisión (Banda-X) de datos almacenados, un sistema de telemetría para la transmisión (Banda-L) directa de imágenes, una unidad de control y una lámpara de calibración así como, calentadores para el control de la temperatura.

8. PASTEC, diseñado para estudiar el ambiente orbital. Este es un conjunto de experimentos tecnológicos que confirman el conocimiento en áreas como vibraciones de lanzamiento, envejecimiento de materiales, etc.
9. PASTEL, este instrumento es parte del SILEX (Semiconductor Intersatellite Link EXperiment) que es un experimento de la Agencia Espacial Europea. PASTEL permite la transmisión de imágenes a altas velocidades a las estaciones terrestres. Esto es posible a vía un canal óptico, a través del satélite geoestacionario Artemis.
10. ESBT es la contraparte del instrumento PASTEL, pero le concierne al SPOT 4 manejar y controlar las funciones. Los intercambios se hacen a través de satélite Artemis, con una tasa de transmisión más lenta que con el instrumento PASTEL.
11. VEGA, un transpondedor radar, usado en todos los satélites de la familia SPOT para calibrar los radares en tierra.

[41]

En el Apéndice B se enunciará en 3 tablas los datos y características referentes a los instrumentos sensores de alta resolución (Tabla B - 6), los instrumentos estereoscópicos (Tabla B - 7) y al instrumento colector de imágenes VEGETATION (Tabla B - 8) de este satélite.

3.3.3 SPOT-5



Spot 5

Figura 3 - 14 (Modelo del satélite SPOT 5) [38]



La creencia de un sistema de observación de la Tierra como el SPOT depende de la continuidad del servicio y de un continuo mejoramiento en la calidad de las imágenes. SPOT 5 fue diseñado con este objetivo en mente.

Manteniendo las características principales que le habían dado al programa SPOT su reputación mundial, debido a su capacidad de adquisición, se creó (con la misma órbita, bandas espectrales y resolución) el nuevo satélite SPOT 5; que ofrecía mejoras en la resolución, ahora con 10 metros en el modo multiespectral y 2.5 a 5 metros en el modo pancromático e infrarrojo. Para resoluciones mayores a 2.5 metros, las imágenes se capturan usando un concepto de muestreo innovador llamado Supermodo.

SPOT 5 también lleva a bordo un nuevo instrumento adquirente de imágenes HRS operando en el modo pancromático y capaz de apuntar por delante y por detrás del satélite. En un solo paso, la cámara de apuntamiento doble, adquiere imágenes de la Tierra con un intervalo de tiempo, entre la imagen delantera y la trasera, de 90 segundos. HRS es así capaz de adquirir parejas de imágenes estereoscópicas casi simultáneamente para mapear relieves, produce modelos de elevación digitales (Digital Elevation Models - DEM's) de áreas extensas y genera productos ortorectificados de una calidad inigualable. El instrumento HRS puede adquirir hasta 126,000 kilómetros cuadrados de datos todos los días.

Además, SPOT 5 también lleva consigo el instrumento VEGETATION 2 que resulta ser idéntico a aquel a bordo del SPOT 4. [39]

De la misma forma se ilustra en el Apéndice B, en base a 3 tablas, los datos y características referentes a los instrumentos sensores de alta resolución (Tabla B - 9), los instrumentos estereoscópicos (Tabla B - 10) y al instrumento colector de imágenes VEGETATION (Tabla B - 11) de este satélite.

Finalmente se muestran 3 imágenes obtenidas con el satélite SPOT 5:

— Paris (Figura 3 - 15).
Instrumento usado: HRG



Figura 3 - 15 (Paris, Francia) [42]



└ India (Figura 3 - 16).

Instrumento usado: VEGETATION

Esta es la primera imagen obtenida con el instrumento VEGETATION




Figura 3 - 16 (India) [42]

└ Toulouse (Figura 3 - 17).

Instrumento usado: HRG



Figura 3 - 17 (Toulouse, Francia) [42]



3.4 IKONOS

El satélite IKONOS fue lanzado el 24 de Septiembre de 1999 desde la Base de la Fuerza Aérea de Vandenberg en California, en el vehículo espacial Athena II. Este es el primer satélite comercial del mundo, posee la capacidad de mostrar imágenes satelitales de alta resolución. La nave fue hecha por Lockheed Martin, los inversionistas del sistema IKONOS son la Corporación Lockheed Martin, la Compañía Raytheon, la Corporación Japonesa Mitsubishi, el Consorcio de Singapur Van Der Horst, la Empresa Coreana Hyundai Space & Aircraft, Afiliados europeos de la Compañía Space Imaging³, la Corporación Sueca del Espacio, y la Compañía tailandesa Loxley Public.

Este satélite utiliza el instrumento LM-900, una plataforma estabilizada de tres ejes. La principal carga se encuentra en el sensor digital de imágenes o 'cámara' que se comunica con estaciones terrestres. La altitud y velocidad le proporciona un amplio campo de vista la habilidad de capturar gran cantidad de datos en poco tiempo. Cuando se combina con imágenes de otras fuentes satelitales y la fotografía aérea, el LM-900 permite a la Space Imaging ofrecer imágenes con una muy alta resolución, calidad de imagen, contenido de información, y una rápida entrega a sus clientes.

El lanzamiento del primer satélite falló, cuando la carga oculta del vehículo espacial Athena II falló al momento de la separación. Hubo un segundo lanzamiento del mismo satélite en el mismo vehículo, resultando este último exitoso (Tabla 3 - 7).

Satélite	Fecha	Lugar de Lanzamiento	Vehículo de Lanzamiento
IKONOS (Primera Edición: Fallida)	27/04/1999	Vandenberg SLC-6 ⁴	Athena II
IKONOS (Segunda Edición: Exitosa)	24/09/1999	Vandenberg SLC-6	Athena II

Tabla 3 - 7 (Tabla cronológica del satélite IKONOS) [43]

La palabra IKONOS se deriva de una palabra griega que significa "imagen". Debido al incremento de demanda en aplicaciones como el mapeo, monitoreo de la agricultura, y planeación urbana, el satélite IKONOS es el primero en su tipo con la capacidad de adquirir simultáneamente imágenes pancromáticas (blanco y negro) con resolución de 1 metro e imágenes multiespectrales (color) con resolución de 4 metros. Diseñada para tomar imágenes digitales de la Tierra desde una altura de 680 Km. y viajando a una velocidad de aproximadamente siete Km. por segundo, la cámara satelital puede distinguir objetos en la superficie de la Tierra tan pequeños como un metro cuadrado. Este satélite gira alrededor de la Tierra en una órbita en sincronía con el sol con período de 98 minutos en 14 revoluciones, pasa una longitud dada a aproximadamente la misma hora local de 10:30 a.m. diariamente, y puede producir un metro de imágenes de la misma geografía cada 3 días. La vida operacional del satélite está calculada para más de 7 años y su peso es de 725 Kg. [43]. Finalmente en el

³ Desde su fundación en 1994 en Denver Colorado, Space Imaging ha establecido la colección mundial más grande de imágenes comerciales terrestres de satélites y plataformas de mapeo aéreo diseñadas para proveer de la información necesaria para poder elaborar la clasificación apropiada temporal y espacialmente de nuestro planeta.

⁴ Space Launch Complex-6: Complejo de Lanzamiento Espacial 6



Apéndice B podemos encontrar dos tablas que nos muestran las características tanto de la órbita (Tabla B - 12) como del sensor (Tabla B - 13) de este satélite.

Por último se muestran 3 imágenes obtenidas con este satélite, y en ellas podemos observar claramente la gran calidad que posee su sensor.

- *Primera Imagen del IKONOS – Monumento Jefferson (Figura 3 - 18)*
El satélite IKONOS captó esta imagen de un metro de resolución en blanco y negro de Washington, D.C., el 30 de Septiembre de 1999. La imagen completa muestra además otros edificios importantes como la Casa Blanca, el Aeropuerto de Washington Ronald Reagan y el Monumento a Washington. [45]




Figura 3 - 18 (Monumento Jefferson, Estados Unidos, Créditos: Space Imaging) [45]



➤ *Roma, Italia (Figura 3 - 19)*

Esta imagen con resolución de un metro en blanco y negro del antiguo estadio Coliseo Romano, es una de las primeras imágenes captadas por el IKONOS desde una órbita de más de 400 millas el 9 de Octubre de 1999. [46]



Figura 3 - 19 (Roma, Italia, Créditos: Space Imaging) [46]

➤ *Beijing, China (Figura 3 - 20)*

Esta imagen con resolución de cuatro metros en color, fue captada el 22 de Octubre de 1999 por el satélite IKONOS. Esta fue la primera imagen del IKONOS a color, en ella se pueden observar la cuadra de Tiananmen, a la izquierda, y el Templo del Cielo. [47]



Figura 3 - 20 (Beijing, China, Créditos: Space Imaging) [47]



4. ANÁLISIS BAYESIANO

4.1 FUNDAMENTOS

4.1.1 PROBABILIDAD CONDICIONAL

Sea el evento B , con $P(B) > 0$, la probabilidad condicional del evento A , dado el evento B es:

$$P(A|B) = \frac{P(A \cap B)}{P(B)}$$

Ecuación 4 - 1

Generalmente hablando, la probabilidad condicional de un evento A dado otro evento B , denotada $P(A|B)$ es la probabilidad de que el evento A ocurra cuando sabemos que el evento B ocurrió. Esta es la razón por la cual se llama condicional a esta probabilidad. La probabilidad de que el evento A ocurra está condicionada por la ocurrencia de B . [4]

Cuando A y B son mutuamente excluyentes¹:

$$A \cap B = \phi$$

$$P(A \cap B) = P(\phi) = 0$$

4.1.2 REGLA DE MULTIPLICACIÓN

Sean A y B dos eventos definidos en el espacio muestral S , entonces:

$$P(A \cap B) = P(A) P(B|A)$$

O bien:

$$P(A \cap B) = P(B) P(A|B)$$

NOTA: Si A y B son eventos independientes²,

$$P(A|B) = P(A)$$

$$P(B|A) = P(B)$$

Entonces:

$$P(A \cap B) = P(A) P(B)$$

$$P(A \cap B) = P(B) P(A)$$

[4]

¹ Si dos o más eventos no pueden ocurrir simultáneamente, se llaman **eventos mutuamente excluyentes**, es decir, que la intersección de ambos eventos es vacía.

² Los **eventos independientes** son eventos en los que la ocurrencia de uno no tiene nada que ver con la ocurrencia del otro.



4.1.3 PROBABILIDAD TOTAL

Sean N eventos mutuamente excluyentes, $B_n, n=1, 2, \dots, N$ que están definidos en el espacio muestral S (Figura 4 - 1),

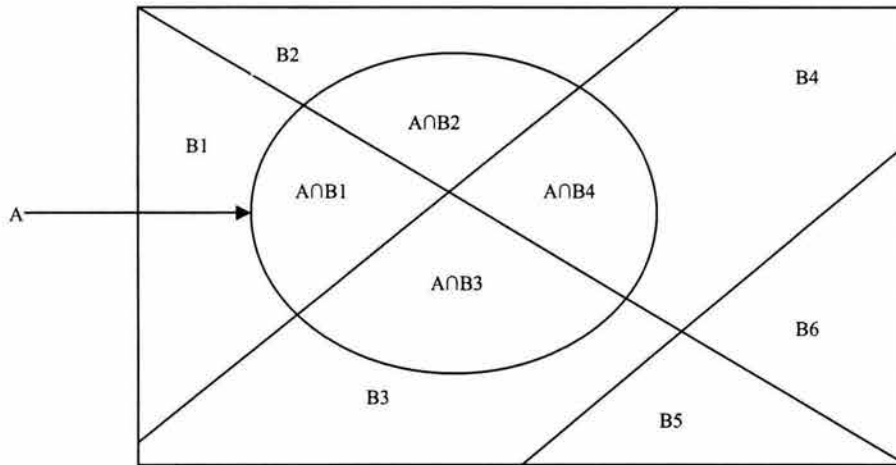


Figura 4 - 1 (Esquema ilustrativo de la probabilidad total) [4]

$$\begin{aligned}
 A \cap S &= A \\
 S &= B_1 \cup B_2 \cup \dots \cup B_6 \\
 A \cap \left(\bigcup_{n=1}^N B_n \right) &= A \\
 \bigcup_{n=1}^N (A \cap B_n) &= A
 \end{aligned}$$

Entonces la **Probabilidad total del evento A** es:

$$P(A) = \sum_{n=1}^N P(A \cap B_n) = \sum_{n=1}^N [P(B_n)P(A | B_n)]$$

Ecuación 4 - 2

[4]

4.1.4 REGLA DE BAYES

Para clasificar una imagen en las categorías de interés, el algoritmo de clasificación necesita ser entrenado para distinguir esas categorías. Las muestras representativas de la categoría, conocidas como prototipos, ejemplares, o simplemente muestras de entrenamiento, son usadas para este propósito. Una vez que el clasificador es entrenado para “reconocer” las diferentes categorías representadas por las muestras de entrenamiento, las “reglas” que fueron desarrolladas durante el entrenamiento son usadas para etiquetar todos los píxeles en la imagen como pertenecientes a una o más de las categorías de entrenamiento.



Si se dispone de un número suficientemente grande de píxeles de entrenamiento representativos para cada clase, se pueden calcular los histogramas de clase y usarlos como aproximaciones para las funciones de densidad de probabilidad continuas de una muestra de datos infinita. Las funciones de densidad de probabilidad de las clases condicionales, $p(\mathbf{x} | \omega_i)$, tienen área unitaria y describen la probabilidad de que un píxel tenga un vector característico \mathbf{x} dado que el píxel pertenezca a la clase ω_i .

Cada función de densidad de probabilidad (histograma) puede ser ponderada por la probabilidad **a priori**, $p(\omega_i)$, tal que la clase i ocurra en el área de interés de la imagen. Estas funciones de probabilidad escaladas, $p(\mathbf{x} | \omega_i) p(\omega_i)$, no tienen área unitaria. En percepción remota, las probabilidades **a priori** pueden estimarse de fuentes externas de información como estudios terrestres, mapas existentes o datos históricos. Por ejemplo, supongamos que nuestro propósito es determinar la proporción de tipos de cosechas plantadas en una estación del año en particular a partir de la clasificación de una imagen LANDSAT. Podríamos establecer razonablemente las probabilidades **a priori** por estimaciones históricas del porcentaje de cada tipo de cosecha en el área. En muchos de los casos, sin embargo, las probabilidades **a priori** confiables son difíciles de obtener y son asumidas como iguales en todos los casos. [2, 5]

Para hacer una decisión en la clasificación de un píxel, se necesitan conocer las probabilidades **a posteriori** que el píxel pertenezca a alguna de las clases de entrenamiento ω_i , dado que el píxel tiene el vector característico \mathbf{x} . Esta probabilidad, $p(\omega_i | \mathbf{x})$, puede calcularse por medio de la Regla de Bayes como,

$$p(\omega_i | \mathbf{x}) = \frac{p(\mathbf{x} | \omega_i) p(\omega_i)}{p(\mathbf{x})}$$

Ecuación 4 - 3

Donde,

$p(\omega_i)$ es la probabilidad a priori de la clase i

$p(\mathbf{x} | \omega_i)$ es la función de verosimilitud de la clase i , o la función de densidad de probabilidad de la clase i

$p(\omega_i | \mathbf{x})$ es la probabilidad a posteriori de la clase i

Finalmente,

$$p(\mathbf{x}) = \sum_i p(\mathbf{x} | \omega_i) p(\omega_i)$$

Ecuación 4 - 4

Ahora puede formarse una regla de decisión con las probabilidades **a posteriori** de la Ecuación 4 - 3. Es intuitivamente satisfactorio asignar el píxel a una clase particular si su probabilidad **a posteriori** es mayor que aquella para todas las otras clases; esta es la regla para el clasificador de máxima verosimilitud. Como $p(\mathbf{x})$ es la misma en todas las clases por la Ecuación 4 - 4, puede ser ignorada en una comparación de probabilidades **a posteriori**, y se puede escribir la regla de decisión de Bayes como,



Si $p(\omega_i | \mathbf{x}) > p(\omega_j | \mathbf{x})$, para toda $\omega_j \neq \omega_i$, asignar píxel a clase ω_i

Donde $p(\omega_i | \mathbf{x})$ se calcula de la Ecuación 4 – 3, las distribuciones de los datos de entrenamiento $p(\mathbf{x} | \omega_i)$, y las probabilidades *a priori* $p(\omega_i)$. [3]

4.1.5 FUNCIONES DE PÉRDIDA

Se puede definir una función de pérdida, L_{ij} , como la pérdida, costo o penalidad debido a la decisión de que $\mathbf{x} \in \omega_j$ cuando en realidad, $\mathbf{x} \in \omega_i$. Es por ello que se busca minimizar la pérdida promedio y se define la siguiente función de pérdida promedio o riesgo promedio,

$$r_k(\mathbf{x}) = \sum_{i=1}^M L_{ik} p(\omega_i | \mathbf{x})$$

Ecuación 4 - 5

Y este es el promedio o pérdida esperada de clasificar erróneamente \mathbf{x} como perteneciente a la clase ω_k , cuando de hecho debería estar en alguna otra de las clases ω_i , $i = 1, 2, \dots, M$ con $i \neq k$.

El trabajo del clasificador entonces es encontrar la decisión óptima que minimice el promedio del riesgo. Entonces ahora la regla de decisión consistiría en:

1. Calcular las pérdidas esperadas, $r_i(\mathbf{x})$ en caso de que $\mathbf{x} \in \omega_i \forall i, i = 1, 2, \dots, M$.
2. Decidir que $\mathbf{x} \in \omega_k$ si $r_k(\mathbf{x}) \leq r_i(\mathbf{x}) \forall i, i \neq k$.

La función de segmentación correspondiente es entonces,

$$d_k(\mathbf{x}) = -r_k(\mathbf{x})$$

Ecuación 4 - 6

El signo negativo de $r_k(\mathbf{x})$ se escribió debido a que $d_k(\mathbf{x})$ representa la clase más probable. Entre más pequeño sea $r_k(\mathbf{x})$, es más probable que $\mathbf{x} \in \omega_k$.

Puede entonces establecerse una matriz de pérdida como,

$$L = \begin{bmatrix} 0 & & & & & & & & \\ & 0 & & & & & & & & 1 \\ & & \cdot & & & & & & & \\ & & & \cdot & & & & & & \\ & & & & \cdot & & & & & \\ & & & & & \cdot & & & & \\ & & & & & & \cdot & & & \\ & & & & & & & \cdot & & \\ & & & & & & & & \cdot & \\ & & & & & & & & & \\ & & & & & & & & & \\ & & & & & & & & & \\ & & & & & & & & & \\ & 1 & & & & & & & & 0 \end{bmatrix}$$

Ecuación 4 - 7



Donde $L_{ii} = 0$, $i = 1, \dots, M$, por tanto no se tienen errores de clasificación en estos casos; mientras que $L_{ik} = 1$, si tiene una pérdida al clasificar erróneamente $x \in \omega_k$, cuando $x \in \omega_i$, $i = 1, \dots, M$, $i \neq k$.

Subsecuentemente una función de pérdida simétrica,

$$L_{ik} = 1 - \delta(k - i)$$

Ecuación 4 - 8

Donde $\delta(k - i)$ es la función delta Kronecker,

$$\delta(k - i) = \begin{cases} 1 & \text{si } k = i \\ 0 & \text{Otros casos} \end{cases}$$

Ecuación 4 - 9

Si el valor de L_{ik} es tal que,

$$L_{ik} = \begin{cases} -h_i & i = k \\ 0 & i \neq k \end{cases}$$

Ecuación 4 - 10

La matriz de pérdida se convierte en una función matricial de pérdidas negativas:

$$\mathbf{L}_{neg} = \begin{bmatrix} -h_1 & & & & \\ & -h_2 & & & \\ & & \cdot & & \\ & & & \cdot & \\ & & & & \cdot \\ 0 & & & & & -h_M \end{bmatrix}$$

Ecuación 4 - 11

El significado de esta pérdida negativa (ganancia positiva) es una decisión correcta; esto es, la pérdida asignada a una decisión es mayor para la decisión errónea que para la correcta.

Nótese que los términos h_i en la matriz no tienen que ser iguales, pueden ser diferentes para indicar la importancia relativa de estimar correctamente una clase en lugar de la otra. Similarmente, L_{ik} y L_{ki} en la matriz de pérdidas no tienen que ser iguales.

Ahora bien si sustituimos la Ecuación 4 - 3 en la Ecuación 4 - 5 se tiene,



$$r_k(\mathbf{x}) = \frac{1}{p(\mathbf{x})} \sum_{i=1}^M L_{ik} p(\mathbf{x} | \omega_i) p(\omega_i)$$

Ecuación 4 - 12

Ya que $p(\mathbf{x})$ en la Ecuación 4 - 12 es común para toda $r_j(\mathbf{x})$, $j = 1, \dots, M$, se puede eliminar de la ecuación del riesgo promedio y calcular únicamente lo siguiente,

$$\min_k r_k(\mathbf{x}) = \min_k \sum_{i=1}^M L_{ik} p(\mathbf{x} | \omega_i) p(\omega_i)$$

Ecuación 4 - 13

Para obtener el mejor entre todos los posibles, alternativamente se puede decir que,

$$d_k(\mathbf{x}) = -r_k(\mathbf{x})$$

Ecuación 4 - 14

La cual es la función de segmentación de Bayes. El clasificador basado en esta minimización es llamado clasificador de Bayes, el cual da un óptimo desempeño desde el punto de vista estadístico.

En caso de que se presentara una situación en la que las dos probabilidades *a posteriori* fueran iguales, no se puede hacer una decisión de las probabilidades de clase, entonces se debe de emplear un proceso de separación de clases. Se puede demostrar que la regla de decisión de Bayes minimiza la probabilidad promedio de error sobre el conjunto de datos completos clasificados, si todas las clases tienen funciones de densidad de probabilidad normal (Gaussiana). [1]

4.1.6 CRITERIO DE MÁXIMA VEROSIMILITUD

Como se definió anteriormente, $p(\mathbf{x} | \omega_i)$ es llamada función de verosimilitud de ω_i . La expresión para el promedio de pérdida esperada en caso de que $\mathbf{x} \in \omega_k$ es,

$$r_k(\mathbf{x}) = \sum_{i=1}^M L_{ik} p(\mathbf{x} | \omega_i) p(\omega_i)$$

Ecuación 4 - 15

Pudiendo esta ecuación ser usada para minimizar y obtener la máxima probabilidad para $\mathbf{x} \in \omega_k$. A partir de la Ecuación 4 - 15 se puede establecer una razón de verosimilitud y un valor de umbral como se muestra a continuación, respectivamente,

$$l_{ki} = \frac{p(\mathbf{x} | \omega_k)}{p(\mathbf{x} | \omega_i)}$$

Ecuación 4 - 16

Y,



$$\theta_{ki} = \frac{(L_{ik} - L_{ii})p(\omega_i)}{(L_{ki} - L_{kk})p(\omega_k)}$$

Ecuación 4 - 17

Entonces puede establecerse el criterio de decisión como,

$$\text{Asignar } \mathbf{x} \in \omega_k \text{ si } l_{ki} > \theta_{ki} \quad \forall i$$

Ecuación 4 - 18

A este criterio se le conoce como regla de máxima verosimilitud.

Considérese ahora el caso en el que L es una función de pérdida simétrica. El problema se convierte ahora en asignar $\mathbf{x} \in \omega_k$ si $l_{ki} > \theta_{ki} \quad \forall i, i = 1, \dots, M$. La regla de máxima verosimilitud para esta función de pérdida simétrica se convierte en,

$$\frac{p(\mathbf{x} | \omega_k)}{p(\mathbf{x} | \omega_i)} > \frac{p(\omega_i)}{p(\omega_k)}$$

Ecuación 4 - 19

Debido a que $L_{ik} = 1$ y $L_{ii} = 0 \quad \forall i, k$ donde $i \neq k; i, k = 1, \dots, M$. Si $p(\omega_i) = p(\omega_k) \quad \forall i, k$, teniendo entonces la regla de máxima verosimilitud como,

$$\text{Asignar } \mathbf{x} \in \omega_k \text{ si } l_{ki} > 1$$

Ecuación 4 - 20

Se debe tener en cuenta que una función de pérdida diferente produce una regla de máxima verosimilitud diferente.

Si ahora volvemos al caso más general en el que $p(\omega_i) \neq p(\omega_k)$, se formulara una función de segmentación para el caso de una función de pérdida simétrica. Si se tiene,

$$l_{ki} = \frac{p(\mathbf{x} | \omega_k)}{p(\mathbf{x} | \omega_i)} > \frac{p(\omega_i)}{p(\omega_k)}$$

Ecuación 4 - 21

Entonces,

$$p(\mathbf{x} | \omega_k)p(\omega_k) > p(\mathbf{x} | \omega_i)p(\omega_i)$$

Ecuación 4 - 22

En otras palabras, podemos asignar $\mathbf{x} \in \omega_k$ si,



$$p(\mathbf{x} | \omega_k)p(\omega_k) > p(\mathbf{x} | \omega_i)p(\omega_i) \quad \forall i$$

Ecuación 4 - 23

De esta forma la función de segmentación es,

$$d_k(\mathbf{x}) = p(\mathbf{x} | \omega_k)p(\omega_k)$$

Ecuación 4 - 24

Una forma alternativa de esta función de segmentación es:

$$d_k'(\mathbf{x}) = \log p(\mathbf{x} | \omega_k) + \log p(\omega_k)$$

Ecuación 4 - 25

Si se extiende esto a un caso más general, el promedio de pérdida en la decisión que $\mathbf{x} \in \omega_k$ es,

$$r_k(\mathbf{x}) = \sum_{i=1}^M L_{ik} p(\mathbf{x} | \omega_i)p(\omega_i)$$

Ecuación 4 - 26

O en forma matricial,

$$\mathbf{r} = \mathbf{L}^T \mathbf{p}$$

Ecuación 4 - 27

La regla de máxima verosimilitud es entonces,

$$\mathbf{x} \in \omega_i \quad \text{Si } r_i(\mathbf{x}) < r_j(\mathbf{x})$$

Ecuación 4 - 28

O,

$$\sum_{k=1}^M L_{ki} p(\mathbf{x} | \omega_k)p(\omega_k) < \sum_{q=1}^M L_{qj} p(\mathbf{x} | \omega_q)p(\omega_q)$$

$$\forall j, j \neq i; j = 1, \dots, M$$

Ecuación 4 - 29

La sumatoria de los términos en el lado izquierdo de la Ecuación 4 - 29 representa el promedio de pérdidas en la decisión de que $\mathbf{x} \in \omega_i$, mientras que la parte



en el lado derecho de la ecuación representa las pérdidas en la decisión de que $x \in \omega_j$, $j = 1, \dots, M$ y $j \neq i$. [1]

4.1.7 PROBABILIDAD DE ERROR

Para esta explicación, se tomará como ejemplo el caso de dos clases. El clasificador dividirá el espacio en dos regiones, R_1 y R_2 . La decisión de que $x \in \omega_1$ se hará cuando el x caiga en la región R_1 ; y $x \in \omega_2$, cuando x caiga en R_2 . Bajo esas circunstancias, habrá dos tipos posibles de errores:

- a) x caiga en la región R_1 , pero ciertamente $x \in \omega_2$. Esto da la probabilidad de error E_1 , que se puede denotar como $\text{Prob}(x \in R_1, \omega_2)$.
- b) x caiga en la región R_2 , pero ciertamente $x \in \omega_1$. Esto da la probabilidad de error E_2 , que se puede denotar como $\text{Prob}(x \in R_2, \omega_1)$. Siendo entonces la probabilidad total de error,

$$P_{\text{error}} = \text{Prob}(x \in R_1 | \omega_2)p(\omega_2) + \text{Prob}(x \in R_2 | \omega_1)p(\omega_1)$$

$$P_{\text{error}} = \int_{R_1} p(x | \omega_2)p(\omega_2)dx + \int_{R_2} p(x | \omega_1)p(\omega_1)dx$$

Ecuación 4 - 30

Este es el criterio de funcionamiento que se trata de minimizar para obtener una buena clasificación. Las dos integrales en la Ecuación 4 – 30 se ilustran en la siguiente figura (Ver Figura 4 – 2):

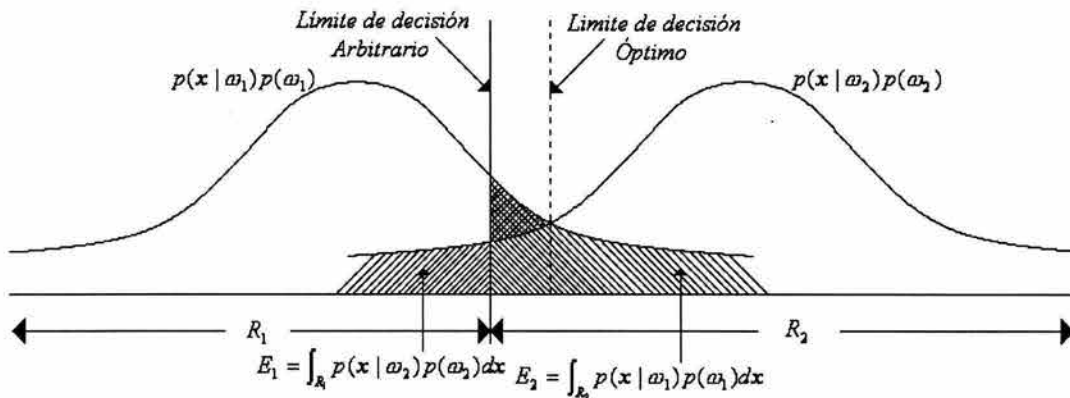


Figura 4 - 2 (Probabilidad de error en el caso de dos clases) [1]

Las áreas bajo la curva mostradas con las líneas en forma de trama representan E_1 y E_2 , donde $E_1 = \int_{R_1} p(x | \omega_2)p(\omega_2)dx$ y $E_2 = \int_{R_2} p(x | \omega_1)p(\omega_1)dx$. Si el límite de decisión se mueve a la derecha, hacia la posición óptima, que es la línea que pasa a través de la intersección de las dos curvas de probabilidad, entonces el área doblemente tramada se elimina del área total y se tiene el mínimo error. Este límite de decisión óptimo ocurre cuando x satisface la siguiente ecuación:



$$d_1(\mathbf{x}) = d_2(\mathbf{x})$$

Ecuación 4 - 31

O,

$$p(\mathbf{x} | \omega_1)p(\omega_1) = p(\mathbf{x} | \omega_2)p(\omega_2)$$

Ecuación 4 - 32

Por consiguiente, la regla de máxima verosimilitud (o regla de decisión de Bayes con función de pérdida simétrica) es el clasificador óptimo desde el punto de vista de mínima probabilidad de error.

Para dar una expresión analítica de la probabilidad de error, se asumirán funciones de densidad normales multivariantes para los vectores con $C_1 = C_2 = C$; entonces,

$$p(\mathbf{x} | \omega_1) = \frac{1}{(2\pi)^{n/2} |C|^{1/2}} \exp\left[-\frac{1}{2}(\mathbf{x} - \mathbf{m}_1)^T C^{-1}(\mathbf{x} - \mathbf{m}_1)\right]$$

Ecuación 4 - 33

Y,

$$p(\mathbf{x} | \omega_2) = \frac{1}{(2\pi)^{n/2} |C|^{1/2}} \exp\left[-\frac{1}{2}(\mathbf{x} - \mathbf{m}_2)^T C^{-1}(\mathbf{x} - \mathbf{m}_2)\right]$$

Ecuación 4 - 34

Entonces,

$$\mathbf{x} \in \omega_1 \quad \text{Si } l_{12} > \theta_{12}$$

Ecuación 4 - 35

O,

$$\frac{p(\mathbf{x} | \omega_1)}{p(\mathbf{x} | \omega_2)} > \frac{(L_{21} - L_{22})p(\omega_2)}{(L_{12} - L_{11})p(\omega_1)}$$

Ecuación 4 - 36

Para el caso donde las funciones de pérdida son simétricas, se tiene,

$$\frac{p(\mathbf{x} | \omega_1)}{p(\mathbf{x} | \omega_2)} > \frac{p(\omega_2)}{p(\omega_1)} = \theta'_{12}$$

Ecuación 4 - 37



De forma similar, $\mathbf{x} \in \omega_2$ Si $l_{21} > \theta_{21}$, esto es,

$$\mathbf{x} \in \omega_2 \quad \text{Si} \quad \frac{p(\mathbf{x} | \omega_2)}{p(\mathbf{x} | \omega_1)} > \frac{p(\omega_1)}{p(\omega_2)} = \theta'_{21}$$

Ecuación 4 - 38

Substituyendo las funciones de densidad normal por $p(\mathbf{x} | \omega_1)$ y $p(\mathbf{x} | \omega_2)$, respectivamente, se tiene,

$$\frac{p(\mathbf{x} | \omega_1)}{p(\mathbf{x} | \omega_2)} = \frac{\exp\left[-\frac{1}{2}(\mathbf{x} - \mathbf{m}_1)^T \mathbf{C}^{-1}(\mathbf{x} - \mathbf{m}_1)\right]}{\exp\left[-\frac{1}{2}(\mathbf{x} - \mathbf{m}_2)^T \mathbf{C}^{-1}(\mathbf{x} - \mathbf{m}_2)\right]}$$

Ecuación 4 - 39

Tomando el logaritmo del cociente $\frac{p(\mathbf{x} | \omega_1)}{p(\mathbf{x} | \omega_2)}$ y denotándolo por p_{12} , entonces,

$$p_{12} = -\frac{1}{2}(\mathbf{x} - \mathbf{m}_1)^T \mathbf{C}^{-1}(\mathbf{x} - \mathbf{m}_1) + \frac{1}{2}(\mathbf{x} - \mathbf{m}_2)^T \mathbf{C}^{-1}(\mathbf{x} - \mathbf{m}_2)$$

$$p_{12} = \mathbf{x}^T \mathbf{C}^{-1}(\mathbf{m}_1 - \mathbf{m}_2) - \frac{1}{2}(\mathbf{m}_1 + \mathbf{m}_2)^T \mathbf{C}^{-1}(\mathbf{m}_1 - \mathbf{m}_2)$$

Ecuación 4 - 40

Entonces,

$$\text{Prob}(\mathbf{x} \in R_1, \omega_2) = p[p_{12} > \log \theta'_{12} | \omega_2]$$

Ecuación 4 - 41

Y,

$$\text{Prob}(\mathbf{x} \in R_2, \omega_1) = p[p_{12} < \log \theta'_{12} | \omega_1]$$

Ecuación 4 - 42

El valor esperado de p_{12} para la clase 1 se calcula como,

$$E_1[p_{12}] = \mathbf{m}_1^T \mathbf{C}^{-1}(\mathbf{m}_1 - \mathbf{m}_2) - \frac{1}{2}(\mathbf{m}_1 + \mathbf{m}_2)^T \mathbf{C}^{-1}(\mathbf{m}_1 - \mathbf{m}_2)$$

$$E_1[p_{12}] = \frac{1}{2}[(\mathbf{m}_1 - \mathbf{m}_2)^T \mathbf{C}^{-1}(\mathbf{m}_1 - \mathbf{m}_2)]$$

Ecuación 4 - 43



La varianza de p_{12} para la clase 1 se define como,

$$\text{var}_1[p_{12}] = E_1[(p_{12} - \bar{p}_{12})^2]$$

Ecuación 4 - 44

Una vez que se sustituyó en la ecuación anterior se tiene,

$$\text{var}_1[p_{12}] = (\mathbf{m}_1 - \mathbf{m}_2)^T \mathbf{C}^{-1} \mathbf{C} \mathbf{C}^{-1} (\mathbf{m}_1 - \mathbf{m}_2)$$

Ecuación 4 - 45

Como $E_1[(\mathbf{x} - \mathbf{m}_1)(\mathbf{x} - \mathbf{m}_1)^T] = \mathbf{C}$ por definición. Por lo tanto,

$$\text{var}_1[p_{12}] = (\mathbf{m}_1 - \mathbf{m}_2)^T \mathbf{C}^{-1} (\mathbf{m}_1 - \mathbf{m}_2)$$

$$\text{var}_1[p_{12}] = r_{12}$$

Ecuación 4 - 46

Substituyendo nuevamente en la Ecuación 4 - 43, se obtiene,

$$E_1[p_{12}] = \frac{1}{2} r_{12}$$

Ecuación 4 - 47

Donde r_{12} es igual a la distancia de Mahalanobis entre $p(\mathbf{x} | \omega_1)$ y $p(\mathbf{x} | \omega_2)$. Así, para $\mathbf{x} \in \omega_1$, el cociente $\frac{p(\mathbf{x} | \omega_1)}{p(\mathbf{x} | \omega_2)}$ se distribuye con una media igual a $\frac{1}{2} r_{12}$ y una varianza igual a r_{12} ; mientras que para $\mathbf{x} \in \omega_2$, el cociente anterior se distribuirá con una media igual a $-\frac{1}{2} r_{12}$ y una varianza igual a r_{12} . Por lo tanto, la probabilidad de clasificar erróneamente un patrón cuando $\mathbf{x} \in \omega_2$ es,

$$p(p_{12} > \log \theta'_{12} | \omega_2) = \int_{\log \theta'_{12}}^{\infty} \frac{1}{\sqrt{2\pi r_{12}}} \exp\left[-\frac{(p_{12} + \frac{1}{2} r_{12})^2}{2r_{12}}\right] dp_{12}$$

Ecuación 4 - 48

Y la probabilidad de clasificar erróneamente un patrón cuando $\mathbf{x} \in \omega_1$ es,

$$p(p_{12} < \log \theta'_{12} | \omega_1) = \int_{-\infty}^{\log \theta'_{12}} \frac{1}{\sqrt{2\pi r_{12}}} \exp\left[-\frac{(p_{12} - \frac{1}{2} r_{12})^2}{2r_{12}}\right] dp_{12}$$

Ecuación 4 - 49



La probabilidad total de error, P_{error} , es entonces,

$$P_{error} = E_1 + E_2$$

$$P_{error} = p(p_{12} > \log \theta'_{12} | \omega_2) p(\omega_2) + p(p_{12} < \log \theta'_{12} | \omega_1) p(\omega_1)$$

Ecuación 4 - 50

Este análisis puede ser fácilmente ampliado al caso multiclase. En los casos multiclases, hay más posibilidades de equivocarse, que de estar en lo correcto, es por ello que se puede denotar la probabilidad de estar en lo correcto como,

$$P_{correcto} = \sum_{i=1}^M \text{Prob}(x \in R_i, \omega_i) = \sum_{i=1}^M \int_{R_i} p(x | \omega_i) p(\omega_i) dx$$

Ecuación 4 - 51

[1]

4.2 DISTRIBUCIONES GAUSSIANAS

El histograma de una imagen describe la distribución estadística de los píxeles de una imagen en términos del número de píxeles para cada nivel de gris, calculándose simplemente al contar el número de píxeles que corresponden a cada nivel de gris, y dividiendo entre el número total de píxeles en la imagen, N ;

$$\text{hist}_{\text{imagen}} = \frac{\text{cuenta}(NG)}{N}$$

Ecuación 4 - 52

Donde, NG son los niveles de gris, y N el número total de píxeles en la imagen.

El histograma es comúnmente asociado con la Función de Densidad de Probabilidad (PDF, por sus siglas en inglés: Probability Density Function) en estadística.

Pero esta asociación es matemáticamente problemática porque:

1. La PDF se define para variables continuas y,
2. Sólo se usa adecuadamente para distribuciones estadísticas de un proceso aleatorio.

Además del problema de tener variables discretas en lugar de continuas, las imágenes son raramente tratadas como casos de procesos aleatorios, sino más bien, como arreglos de datos individuales. El histograma es, por lo tanto, una descripción más apropiada para imágenes.

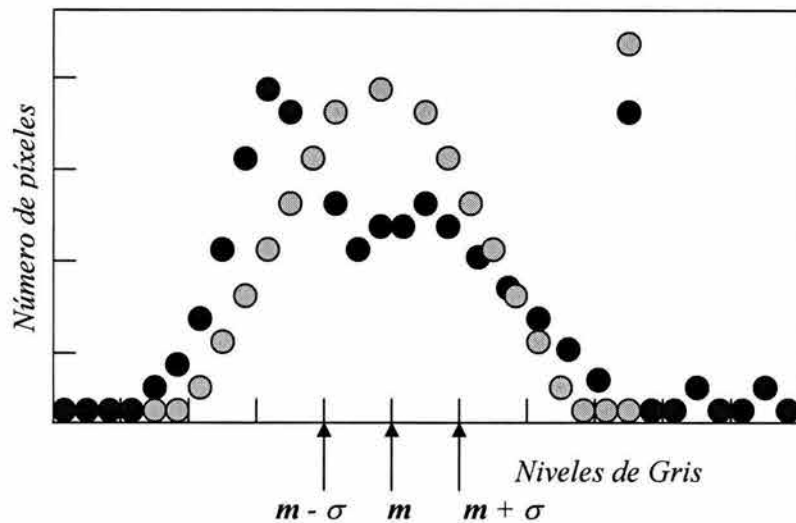


Figura 4 - 3 (Ejemplo del histograma de una imagen comparado con la distribución Gaussiana con la misma varianza y media) [5]

Los histogramas de las imágenes son típicamente unimodales (es decir, poseen un solo “pico”). Es importante recordar que el histograma de una imagen solo especifica el número de píxeles para cada nivel de gris, y no contiene información acerca de la distribución espacial de estos píxeles. A veces, sin embargo, la información espacial puede ser inferida del histograma. Por ejemplo, un histograma estrictamente bimodal generalmente nos indica dos materiales dominantes en la escena, como tierra y agua. Lo que no puede ser inferido es la extensión a la cual, los píxeles en cada categoría, están espacialmente conectados.

En percepción remota, como en muchos campos de la ciencia y la ingeniería, usualmente es conveniente por facilidad de cálculos matemáticos asumir distribuciones gaussianas (o normales) en muestras independientes e idénticamente distribuidas de un proceso aleatorio.

En una dimensión, esta distribución continua, tiene la forma,

$$N(x; m, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\left[\frac{(x-m)^2}{2\sigma^2}\right]}$$

Ecuación 4 - 53

Esta función tiene la forma familiar mostrada en la Figura 4 – 3. El centroide de esta distribución está dado por m y su ancho es proporcional a σ . Mientras la distribución gaussiana no es apropiada para usarse como un modelo global para muchas imágenes, es ampliamente usada para modelar las distribuciones de píxeles que tienen características similares en una imagen. [5]



Y aún cuando las distribuciones gaussianas o normales son asumidas generalmente, es importante recordar que se puede tener cualquier otro tipo de distribución de probabilidad en el uso práctico, sin embargo las distribuciones gaussianas nos pueden llevar a resultados matemáticos más simples como se describe a continuación.

La función de densidad normal para M clases de patrones se representa como:

$$p(\mathbf{x} | \omega_k) = \frac{1}{(2\pi)^{n/2} |\mathbf{C}_k|^{1/2}} \exp\left[-\frac{1}{2}(\mathbf{x} - \mathbf{m}_k)^T \mathbf{C}_k^{-1}(\mathbf{x} - \mathbf{m}_k)\right]$$

$$p(\mathbf{x} | \omega_k) = N(\mathbf{m}_k, \mathbf{C}_k)$$

$$k = 1, 2, \dots, M; \quad n = \text{dimensión del vector patrón}$$

Ecuación 4 - 54

Donde N es la función de densidad normal o Gaussiana, \mathbf{m}_k es el vector de la media, y \mathbf{C}_k es la matriz de covarianza para la clase k , definida respectivamente por sus valores esperados sobre los patrones pertenecientes a la clase k .

Entonces,

$$\mathbf{m}_k = E_k[\mathbf{x}]$$

Ecuación 4 - 55

Y,

$$\mathbf{C}_k = E_k[(\mathbf{x} - \mathbf{m}_k)(\mathbf{x} - \mathbf{m}_k)^T]$$

Ecuación 4 - 56

[1]

4.3 FUNCIÓN DE SEGMENTACIÓN ÓPTIMA

De la Ecuación 4 - 25, recordamos que la función de segmentación para $\mathbf{x} \in \omega_k$ se puede expresar como,

$$d_k'(\mathbf{x}) = \log p(\mathbf{x} | \omega_k) + \log p(\omega_k)$$

Ecuación 4 - 57

Donde la función de segmentación se aplica a la función de densidad normal:

$$p(\mathbf{x} | \omega_k) = \frac{1}{(2\pi)^{n/2} |\mathbf{C}_k|^{1/2}} \exp\left[-\frac{1}{2}(\mathbf{x} - \mathbf{m}_k)^T \mathbf{C}_k^{-1}(\mathbf{x} - \mathbf{m}_k)\right]$$

$$k = 1, 2, \dots, M;$$

Ecuación 4 - 58



La función de segmentación $d_k'(x)$ resulta,

$$d_k''(x) = -\frac{n}{2} \log(2\pi) - \frac{1}{2} \log |C_k| - \frac{1}{2} (x - m_k)^T C_k^{-1} (x - m_k) + \log p(\omega_k)$$

Ecuación 4 - 59

Es claro que si el primer término en el lado derecho es el mismo para todas las k , puede ser eliminado, y entonces la función de segmentación se reduce a,

$$d_k'''(x) = -\frac{1}{2} (x - m_k)^T C_k^{-1} (x - m_k) + \left[\log p(\omega_k) - \frac{1}{2} \log |C_k| \right]$$

Ecuación 4 - 60

Esta es una función de segmentación cuadrática, y puede reacomodarse de una forma más compacta como:

$$d_k^{IV}(x) = -\frac{1}{2} r^2 + f(k) \quad \text{para } x \in \omega_k$$

Ecuación 4 - 61

Donde $r^2 = (x - m_k)^T C_k^{-1} (x - m_k)$ es la llamada distancia de **Mahalanobis**, y entre dos clases puede ser expresada como $r_{ij} = (m_i - m_j)^T C^{-1} (m_i - m_j)$, y $f(k) = \log p(\omega_k) - \frac{1}{2} \log |C_k|$. Ahora se analizará esta función discriminante con más detalle dividiendo el análisis en dos casos diferentes.

CASO I: CUANDO LAS MATRICES DE COVARIANZA SON IGUALES PARA DIFERENTES CLASES ($C_i = C_j = C_k = C$). El significado físico sería representado por clusters con la misma forma y tamaño, pero con localización en diferentes medias.

$$d_k(x) = -\frac{1}{2} x^T C^{-1} x - \frac{1}{2} m_k^T C^{-1} m_k + x^T C^{-1} m_k + \log p(\omega_k) - \frac{1}{2} \log |C|$$

Ecuación 4 - 62

El primero y último términos del lado derecho de la ecuación no proporcionan información discriminante al no cambiar su valor para diferentes valores de k , por tanto, si rescribimos la ecuación anterior, tenemos:

$$d_k(x) = x^T C^{-1} m_k + \left[\log p(\omega_k) - \frac{1}{2} m_k^T C^{-1} m_k \right]$$

Ecuación 4 - 63

Para el caso de dos clases, $M = 2$:



$$d(\mathbf{x}) = d_1(\mathbf{x}) - d_2(\mathbf{x})$$

$$d(\mathbf{x}) = \mathbf{x}^T \mathbf{C}^{-1}(\mathbf{m}_1 - \mathbf{m}_2) + \left[\log \frac{p(\omega_1)}{p(\omega_2)} - \frac{1}{2}(\mathbf{m}_1^T \mathbf{C}^{-1} \mathbf{m}_1 - \mathbf{m}_2^T \mathbf{C}^{-1} \mathbf{m}_2) \right]$$

Ecuación 4 - 64

O,

$$d(\mathbf{x}) = \mathbf{x}^T \mathbf{C}^{-1}(\mathbf{m}_1 - \mathbf{m}_2) + \log \frac{p(\omega_1)}{p(\omega_2)} - \frac{1}{2}[(\mathbf{m}_1 - \mathbf{m}_2)^T \mathbf{C}^{-1}(\mathbf{m}_1 + \mathbf{m}_2)]$$

Ecuación 4 - 65

A continuación, se mencionará un pequeño ejemplo, relacionado con este caso:

Sean $\omega_1 = \left\{ \begin{pmatrix} 1 \\ 2 \end{pmatrix}, \begin{pmatrix} 2 \\ 2 \end{pmatrix}, \begin{pmatrix} 3 \\ 1 \end{pmatrix}, \begin{pmatrix} 3 \\ 2 \end{pmatrix}, \begin{pmatrix} 2 \\ 3 \end{pmatrix} \right\}$ y $\omega_2 = \left\{ \begin{pmatrix} 7 \\ 9 \end{pmatrix}, \begin{pmatrix} 8 \\ 9 \end{pmatrix}, \begin{pmatrix} 9 \\ 8 \end{pmatrix}, \begin{pmatrix} 9 \\ 9 \end{pmatrix}, \begin{pmatrix} 8 \\ 10 \end{pmatrix} \right\}$, se requiere encontrar un límite de decisión de Bayes para separar las clases.

Solución:

$$\mathbf{m}_1 = \frac{1}{N_1} \sum_{j=1}^{N_1} \mathbf{x}_{1j} = \frac{1}{5} \begin{bmatrix} 11 \\ 10 \end{bmatrix} \quad Y \quad \mathbf{m}_2 = \frac{1}{N_2} \sum_{j=1}^{N_2} \mathbf{x}_{2j} = \frac{1}{5} \begin{bmatrix} 41 \\ 45 \end{bmatrix}$$

Por definición,

$$\mathbf{C} = E[(\mathbf{x} - \mathbf{m})(\mathbf{x} - \mathbf{m})^T]$$

$$\mathbf{C} = E[\mathbf{x}\mathbf{x}^T] - \mathbf{m}\mathbf{m}^T$$

Discretamente,

$$\mathbf{C}_1 = \frac{1}{N_1} \sum_{j=1}^{N_1} \mathbf{x}_{1j} \mathbf{x}_{1j}^T - \mathbf{m}_1 \mathbf{m}_1^T$$

$$\mathbf{C}_1 = \frac{1}{5} \left[\begin{pmatrix} 1 \\ 2 \end{pmatrix} \begin{pmatrix} 1 & 2 \end{pmatrix} + \begin{pmatrix} 2 \\ 2 \end{pmatrix} \begin{pmatrix} 2 & 2 \end{pmatrix} + \begin{pmatrix} 3 \\ 1 \end{pmatrix} \begin{pmatrix} 3 & 1 \end{pmatrix} + \begin{pmatrix} 3 \\ 2 \end{pmatrix} \begin{pmatrix} 3 & 2 \end{pmatrix} + \begin{pmatrix} 2 \\ 3 \end{pmatrix} \begin{pmatrix} 2 & 3 \end{pmatrix} \right] - \frac{1}{25} \begin{pmatrix} 11 \\ 10 \end{pmatrix} \begin{pmatrix} 11 & 10 \end{pmatrix}$$

$$\mathbf{C}_1 = \frac{1}{25} \begin{pmatrix} 14 & -5 \\ -5 & 10 \end{pmatrix}$$

De forma similar,



$$C_2 = \frac{1}{N_2} \sum_{j=1}^{N_2} \mathbf{x}_{2j} \mathbf{x}_{2j}^T - \mathbf{m}_2 \mathbf{m}_2^T$$

$$C_2 = \frac{1}{25} \begin{pmatrix} 14 & -5 \\ -5 & 10 \end{pmatrix}$$

Por lo tanto, $C_1 = C_2 = C = \frac{1}{25} \begin{pmatrix} 14 & -5 \\ -5 & 10 \end{pmatrix}$

El determinante y la adjunta de C pueden ser calculadas como:

$$|C| = \frac{1}{25} \begin{pmatrix} 14 & -5 \\ -5 & 10 \end{pmatrix} = \frac{23}{5} \quad \text{adj } C = \begin{pmatrix} 10 & 5 \\ 25 & 25 \\ 5 & 14 \\ 25 & 25 \end{pmatrix}$$

$$C^{-1} = \frac{1}{|C|} \text{adj } C = \frac{1}{115} \begin{pmatrix} 10 & 5 \\ 5 & 14 \end{pmatrix}$$

$$C^{-1} \mathbf{m}_1 = \frac{1}{115} \begin{pmatrix} 32 \\ 39 \end{pmatrix}$$

$$\mathbf{m}_1^T C^{-1} \mathbf{m}_1 = \frac{742}{5 \times 115}$$

Entonces la función de segmentación o discriminante para la clase 1 es:

$$d_1(\mathbf{x}) = \mathbf{x}^T C^{-1} \mathbf{m}_1 - \frac{1}{2} \mathbf{m}_1^T C^{-1} \mathbf{m}_1$$

$$d_1(\mathbf{x}) = \frac{32}{115} x_1 + \frac{39}{115} x_2 - 0.65$$

Con un procedimiento similar obtenemos:

$$d_2(\mathbf{x}) = \frac{127}{115} x_1 + \frac{167}{115} x_2 - 11$$

Finalmente, el límite de decisión se da por la ecuación:

$$d(\mathbf{x}) = d_1(\mathbf{x}) - d_2(\mathbf{x}) = 0$$

$$d(\mathbf{x}) = -0.826x_1 - 1.11x_2 + 10.35 = 0$$

Y en la Figura 4 - 4 se ilustra este ejemplo claramente:

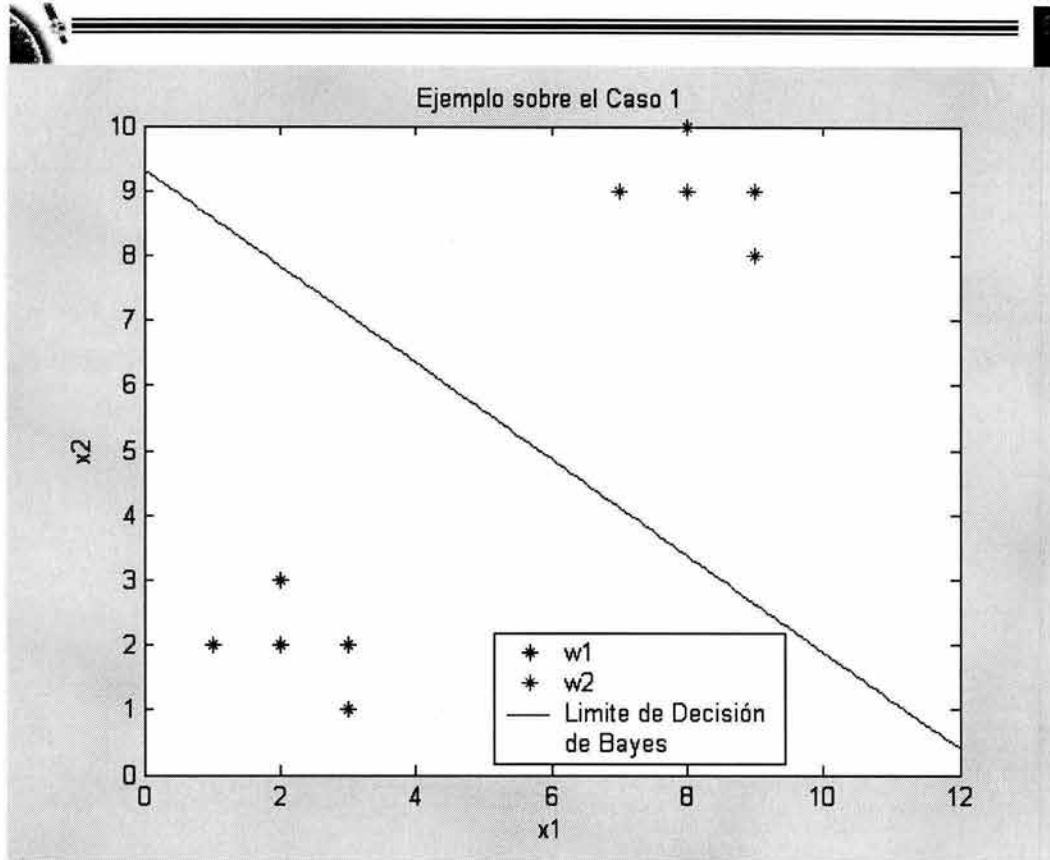


Figura 4 - 4 (Ejemplo de Caso 1) [1]

CASO 2: CUANDO LA MATRIZ DE COVARIANZA C_k ES DIAGONAL DE LA FORMA $\sigma_k^2 I$, DONDE $\sigma_k^2 = |C_k|$. El significado físico de este caso es representado por un cluster cuyos componentes son iguales a lo largo de los ejes principales y su distribución es de forma esférica.

Sustituyendo $C_k = \sigma_k^2 I$, en la Ecuación 4 - 60:

$$d_k(\mathbf{x}) = -\frac{1}{2\sigma_k^2} (\mathbf{x}^T \mathbf{x} - 2\mathbf{x}^T \mathbf{m}_k + \mathbf{m}_k^T \mathbf{m}_k) + \log p(\omega_k) - \frac{1}{2} \log \sigma_k^2$$

Ecuación 4 - 66

Si se eliminan los términos que no cambian para diferentes valores de k , y se considera que las $p(\omega_k)$ es igual para toda k , la ecuación anterior se puede describir como:

$$d_k(\mathbf{x}) = -\frac{1}{2\sigma^2} (-2\mathbf{x}^T \mathbf{m}_k + \mathbf{m}_k^T \mathbf{m}_k)$$

Ecuación 4 - 67



$$d_k(\mathbf{x}) = \mathbf{x}^T \mathbf{m}_k - \frac{1}{2} |\mathbf{m}_k|^2$$

Ecuación 4 - 68

La cual es una ecuación lineal.

De la Ecuación 4 - 66 y considerando que $C_k = C_j = C = \sigma^2 \mathbf{I}$ y $p(\omega_k) = p(\omega_j) = 1/K = \text{constante}$, resultando entonces:

$$d_k(\mathbf{x}) = -\frac{1}{2\sigma^2} (\mathbf{x} - \mathbf{m}_k)^T (\mathbf{x} - \mathbf{m}_k)$$

Ecuación 4 - 69

O simplemente:

$$d_k(\mathbf{x}) = -(\mathbf{x} - \mathbf{m}_k)^T (\mathbf{x} - \mathbf{m}_k) = -|\mathbf{x} - \mathbf{m}_k|^2$$

Ecuación 4 - 70

Y esta ecuación corresponde al clasificador de distancia mínima, como se observa, este es el caso más simple, en el que las variables son estadísticamente independientes.

Como se mencionó en el subtema anterior, las distribuciones gaussianas son sólo una de las funciones de densidad de probabilidad disponibles, y nos hemos apoyado en ellas debido a las ecuaciones tan simples que nos resultan, pero se puede usar cualquier otro tipo de distribución para modelar estas ecuaciones, haciendo las sustituciones correspondientes. [1]

4.4 CLASE DE RECHAZO

El objetivo final de un sistema de Reconocimiento de Patrones es el etiquetar de forma automática patrones de los cuales desconocemos su clase. Suponemos que el sistema dispone de un módulo de adquisición de datos y que se han seleccionado previamente las variables más significativas.

Si suponemos que todos los patrones a reconocer son elementos potenciales de I clases distintas denotadas ω_i , $i = 1, 2, \dots, I$, llamaremos $\Omega = \{\omega_1, \omega_2, \dots, \omega_I\}$ al **conjunto de las clases informacionales**. Conviene tener en cuenta que una clase informacional es la denominación que se da a una clase conocida y con significado; por ejemplo, un conjunto de clases informacionales podría ser $\Omega = \{\text{agua, vegetación, suelo}\}$, usualmente se habla simplemente de **clase** prescindiendo de la palabra "informacional" aunque esta distinción es muy importante a la hora de abordar las técnicas de clasificación y segmentación.



Resulta conveniente ampliar el conjunto Ω incorporando una nueva clase, llamada **clase de rechazo**. Así, se define la clase de rechazo, ω_{rechazo} como una clase que se asigna a todos los patrones, o píxeles en nuestro caso, para los que no se tiene una certeza **aceptable** de ser clasificados correctamente en alguna de las clases de Ω .

Por tanto se dice que $\Omega^* = \{\omega_1, \omega_2, \dots, \omega_l, \omega_{\text{rechazo}}\}$ es el **conjunto extendido de clases informacionales**.

Una vez establecido el conjunto de clases se procede a la construcción del clasificador. Como puede intuirse, la construcción del clasificador no es una tarea trivial ni directa e involucra una serie de etapas:

1. La elección del modelo
2. Aprendizaje (entrenamiento del clasificador)
3. Verificación de los resultados

Es muy importante señalar que estas etapas no deben verse de forma secuencial. Puede ocurrir que en un momento dado hay que volver atrás para replantearse alguno de los pasos dados, incluso el conjunto de clases informacionales. [54]

Para la elaboración de esta tesis sólo se llevará a cabo el proceso de segmentación, que es parte fundamental en la elaboración del clasificador. Para este propósito se empleará la segmentación usando el Análisis Bayesiano como fundamento, se pretende aplicar a una imagen en 256 niveles de gris, involucrando en el proceso funciones equiprobables, la obtención de medias de 5 clases representativas y de probabilidades a priori. Una vez obtenidos estos parámetros se definirá una sexta **clase de rechazo**, tal que si $P(\omega_i | X) \leq 0.09$, el píxel analizado será asignado a la clase de rechazo, finalmente esta clase de rechazo será segmentada usando Campos Aleatorios de Markov (Capítulo 5) para asegurar que estos píxeles se clasifican correctamente, es por ello que a esta segmentación se le llamó semisupervisada, y lo que interesa es llevarla a cabo en imágenes de percepción remota del Distrito Federal.



5. CAMPOS ALEATORIOS DE MARKOV

Los modelos de Campos Aleatorios de Markov (CAM) son atractivos por las siguientes razones:

- Se pueden desarrollar sistemáticamente algoritmos basados en los principios del sonido más que heurísticos ad-hoc para una diversidad de problemas.
- Hace más fácil el cálculo de medidas de ejecución cuantitativas para caracterizar cómo trabajan los algoritmos de análisis de imagen.
- Los modelos de CAM pueden ser usados para incorporar información contextual a priori, o bien restricciones, de manera cuantitativa.
- Los algoritmos basados en CAM tienden a ser locales y conducen a una implementación hardware paralelo de manera natural.

Los modelos de visión estocásticos completos basados en Campos Aleatorios de Markov están formulados dentro del campo de trabajo Bayesiano. La solución óptima de un problema se define como el estimador de probabilidad máxima a posteriori (MAP), el mejor que se puede obtener a partir de observaciones aleatorias. La probabilidad a posteriori se define usando la regla de Bayes, a partir de un modelo a priori y un modelo de probabilidad. El modelo de probabilidad está relacionado con cómo son observados los datos y es un problema dependiente del dominio. El modelo a priori depende de cómo se expresan ciertas restricciones a priori. Los resultados de la teoría CAM nos proporcionan herramientas para codificar restricciones contextuales en la probabilidad a priori. Esta es la principal razón para el modelo de visión usando CAM.

Del uso común que los distintos autores hacen de los CAM, la definición de un modelo de Campos Aleatorios de Markov podemos resumirla en 5 pasos:

1. Plantear el problema como uno de clasificación en el que la configuración de clases representa una solución.
2. Después plantearlo como un problema de clasificación bayesiano en el que la solución óptima se define como la configuración de clases MAP.
3. Usar la distribución de Gibbs para caracterizar la distribución a priori de las configuraciones de la clasificación.
4. Definir la Función de Energía de la distribución de Gibbs.
5. Usar un algoritmo (por ejemplo, Simulated Annealing o Recocido Simulado) para minimizar la Función de Energía de la distribución de Gibbs y obtener así la configuración de clases MAP.

El problema de segmentación de una imagen puede considerarse de una forma más simple como un problema de etiquetado. El problema de etiquetado consiste en asignar una etiqueta del conjunto de etiquetas a cada estado, y su solución consiste en la asignación de un conjunto de etiquetas a los píxeles (sites) de la imagen. Sea S un conjunto discreto con m píxeles:

$$S = \{1, 2, \dots, m\}$$

Ecuación 5 - 1



Para una imagen de $n \times n$ píxeles se puede denotar al conjunto de píxeles de la siguiente manera:

$$S = \{(i, j) \mid 1 \leq i, j \leq n\}$$

Ecuación 5 - 2

El conjunto de etiquetas L puede ser un conjunto discreto o continuo, en el caso continuo el conjunto de etiquetas puede corresponder a \mathfrak{R} (conjunto de números reales) o a un intervalo de \mathfrak{R} ,

$$L_c = [x_1, x_h] \subset \mathfrak{R}$$

Ecuación 5 - 3

En el caso discreto, las etiquetas se toman dentro de un conjunto discreto de M valores,

$$L_d = \{l_1, \dots, l_M\} = \{1, \dots, M\}$$

Ecuación 5 - 4

El conjunto de etiquetas puede ser caracterizado en términos de su continuidad. Además de la continuidad, otra característica esencial de un conjunto de etiquetas es poder establecer un orden entre las etiquetas. En un conjunto discreto como, por ejemplo, la intensidad del tono de gris $\{0, 1, \dots, 255\}$, podemos ordenar los elementos según los valores de la intensidad $0 < 1 < \dots < 255$.

En un conjunto de etiquetas ordenado, podemos definir una medida numérica (cuantitativa) de semejanza entre dos etiquetas. Para un conjunto de etiquetas sin relación de orden, la medida de semejanza es simbólica (cualitativa), normalmente tomando un valor **igual** o **no igual**. Ordenar las etiquetas no solamente es importante para clasificar problemas de etiquetado, sino que afecta también a la elección de algoritmos de etiquetado y, por lo tanto, a la complejidad computacional.

Se llamará etiquetado a:

$$f = \{f_1, \dots, f_m\}$$

Ecuación 5 - 5

Donde a cada píxel de S se le asigna una única etiqueta de L con la función mapping o de mapeo:

$$f : S \rightarrow L$$

Ecuación 5 - 6



En términos de Campos Aleatorios de Markov, se llamará **configuración** al etiquetado, de esta forma una configuración de etiquetas puede corresponder a una imagen, a un mapa de bordes de la imagen, a una interpretación de una imagen con característica en términos de características de objeto, una interpretación de los objetos que aparecen en una escena, etc.

Cuando todos los píxeles tienen el mismo conjunto de etiquetas L , el conjunto de todas las configuraciones posibles, es el producto cartesiano:

$$\mathfrak{S} = \underbrace{L \times L \times \dots \times L}_{m \text{ veces}} = L^m$$

Ecuación 5 - 7

Donde m es el tamaño de S .

En términos de homogeneidad y de continuidad, podemos clasificar un problema de etiquetado como una de las cuatro categorías siguientes:

- └ PE1: Píxeles homogéneos con conjunto de etiquetas continuo.
- └ PE2: Píxeles homogéneos con conjunto de etiquetas discreto.
- └ PE3: Píxeles no homogéneos con conjunto de etiquetas discreto.
- └ PE4: Píxeles no homogéneos con conjunto de etiquetas continuo.

Las dos primeras categorías caracterizan el procesado de bajo nivel realizado sobre las imágenes observadas y las dos últimas el procesado de alto nivel realizado sobre las características extraídas.

La restauración de imágenes en niveles de gris, o el suavizado de imágenes, son ejemplos de PE1. El conjunto de píxeles S corresponde a los píxeles de la imagen y el conjunto de etiquetas L a un intervalo real. La restauración consiste en estimar la señal de la imagen real a partir de una imagen degradada o con ruido.

La restauración de imágenes binarias, o imágenes multinivel, son ejemplos de PE2. Del mismo modo que la restauración continua, se intenta estimar la señal de la imagen real. La diferencia es que cada píxel de la imagen resultante aquí asume un valor discreto y, por tanto, L es conjunto discreto de etiquetas.

La segmentación de imágenes es un PE2. Se divide una imagen en regiones mutuamente excluyentes, cada una de las cuales tiene algunas propiedades uniformes y homogéneas cuyos valores son significativamente diferentes a los de las regiones vecinas. La propiedad puede ser, por ejemplo, un tono de gris, un color o una textura. Los píxeles dentro de cada región tienen asignadas una etiqueta única. La suposición principal en estos problemas es que la señal es suave o está formada por trozos suaves. Esto es complementario a la suposición sobre los bordes, en los que pueden ocurrir cambios bruscos.

La detección de bordes es también un PE2. A cada píxel (más concretamente, entre cada par de píxeles vecinos) se le asigna una etiqueta entre {borde y no-borde} si existen diferencias significativas entre las propiedades del par de píxeles vecinos.



El agrupamiento perceptual es un PE3. Los píxeles normalmente corresponden a características segmentadas inicialmente (puntos, líneas y regiones) que están ordenadas no homogéneamente. Las características fragmentarias se deben organizar en grupos con significado perceptual.

El reconocimiento y emparejamiento de objetos basados en características es un PE3. Cada píxel indica una característica de la imagen tal como un punto, un segmento de línea o una región. Las etiquetas son un conjunto discreto por naturaleza y cada una de ellas indica una característica del modelo. La configuración resultante es un "mapping" a partir de las características de la imagen, llegando a aquellos del objeto modelo. El emparejamiento estéreo es un PE3 similar.

La estimación de la orientación a partir de un conjunto de correspondencia de puntos puede ser formulada como un PE4. Cada etiqueta puede asumir el valor de una matriz real representando una transformación admisible (ortogonal, afin o en perspectiva).

Para un problema de etiquetado discreto con m píxeles y M etiquetas, existen M^m configuraciones posibles. Para un problema de etiquetado continuo, el número de configuraciones posibles es infinito. [5]

5.1 SISTEMAS DE VECINOS Y TIPOS DE CLIQUES ASOCIADOS

Los Campos Aleatorios de Markov son una parte de la Teoría de Probabilidad que proporciona una herramienta para analizar dependencias espaciales o contextuales de fenómenos físicos.

Los píxeles de S están relacionados mediante lo que se conoce como **sistema de vecinos**, y este se define como:

$$N = \{N_i \mid \forall i \in S\}$$

Ecuación 5 - 8

Donde N_i es el conjunto de píxeles vecinos a i para los que se cumple que:

1. $i \notin N_i$ un píxel no es vecino a sí mismo
2. $i \in N_j \Leftrightarrow j \in N_i$ la relación de vecindad es mutua entre el píxel j y el píxel i

Para una rejilla (lattice) regular S , el conjunto de vecinos del píxel i está definido como el conjunto de píxeles próximos dentro de un radio r ,

$$N_i = \{j \in S \mid [dist(pixel_j, pixel_i)]^2 \leq r, j \neq i\}$$

Ecuación 5 - 9



Donde $dist(pixel_j, pixel_i)$ es la distancia euclídea entre el píxel j y el píxel i , r es un número entero.

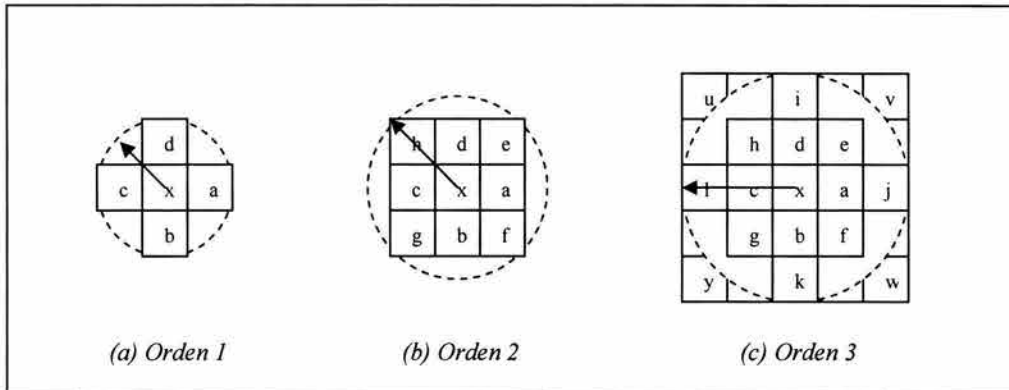


Figura 5 - 1 (Vecinos en una rejilla regular S) [5]

Al sistema de vecinos de primer orden, se le llama sistema de 4-vecinos, y en el cada píxel (interior) tiene cuatro píxeles vecinos, como se muestra en la Figura 5 - 1, (a); de la misma forma al sistema de vecinos de segundo orden, se le llama sistema de 8-vecinos, donde hay ocho vecinos para cada píxel (interior), y se muestra en la Figura 5 - 1, (b); se podrían seguir mostrando sistemas de vecinos de orden n , pero los más conocidos y usados son los tres órdenes mostrados en la Figura 5 - 1.

Tenido como base estas definiciones se introduce el concepto de **conexidad**, que constituye una relación de vecindad espacial entre un píxel y sus próximos vecinos; es decir, un píxel i y su vecino i' tienen 4-conexidad si i' pertenece al conjunto de N_i de primer orden, y dos píxeles i e i' tienen 8-conexidad si i' pertenece al conjunto de N_i de segundo orden y así sucesivamente.

Cuando se ha especificado un orden entre los elementos de S , el conjunto de vecinos se puede determinar más explícitamente. Por ejemplo, sea $S = \{1, 2, \dots, m\}$ un conjunto ordenado de píxeles cuyos elementos son los índices de los píxeles de una imagen 1D, entonces un píxel interior $i \in \{2, \dots, m-1\}$ tiene dos vecinos $N_i = \{i-1, i+1\}$ y los píxeles de la frontera (los dos extremos) tienen un vecino cada uno, $N_1 = \{2\}$ y $N_m = \{m-1\}$. El conjunto de píxeles de una rejilla regular rectangular $S = \{(i, j) | 1 \leq i, j \leq n\}$ corresponde a los píxeles de una imagen en dos dimensiones de tamaño $n \times n$. Cada píxel interior, representado por (i, j) , tiene 4 vecinos $N_{i,j} = \{(i-1, j), (i+1, j), (i, j-1), (i, j+1)\}$, los píxeles de la frontera tienen tres y los píxeles de las esquinas tienen dos.

Para un conjunto irregular de píxeles S , el conjunto de vecinos de i , N_i , se define de la misma forma que en la Ecuación 5 - 9 y corresponde a los estados próximos en un radio r ,



$$N_i = \{j \in S \mid [\text{dist}(\text{característica}_j, \text{característica}_i)]^2 \leq r, j \neq i\}$$

Ecuación 5 - 10

La función $\text{dist}(\text{característica}_j, \text{característica}_i)$ necesita ser definida apropiadamente para puntos que no tienen características. En general, el conjunto de vecinos N_i para un conjunto irregular de estados S tiene dimensión y tamaño variables.

Un **clique** c de (S, N) se define como un subconjunto de píxeles en S , y este puede formarse de un solo píxel, dos píxeles, tres píxeles o mas, y se representa por C_1 , C_2 , y C_3, \dots , respectivamente,

$$\begin{aligned} C_1 &= \{i \mid i \in S\} \\ C_2 &= \{(i, j) \mid j \in N_i, i \in S\} \\ C_3 &= \{(i, j, k) \mid i, j, k \in S \text{ son vecinos dos a dos}\} \\ &\vdots \end{aligned}$$

Ecuación 5 - 11

El conjunto de todos los cliques para $\{S, N\}$ será $C = C_1 \cup C_2 \cup \dots$

El tipo de clique para $\{S, N\}$, de una rejilla regular, viene determinado por su tamaño, dimensión y orientación. La Figura 5 - 2 muestra distintos tipos de cliques para sistemas de vecinos de primer y segundo orden. A medida que aumenta el orden del sistema de vecinos, el número de cliques crece rápidamente y también el coste computacional asociado. [5]




Figura 5 - 2 (Cliques en una rejilla regular S) [5]



5.2 CAMPOS ALEATORIOS DE MARKOV Y DISTRIBUCIÓN DE GIBBS

5.2.1 CAMPOS ALEATORIOS DE MARKOV (CAM)

Sea $F = \{F_1, \dots, F_m\}$ una familia de variables aleatorias definidas en S , donde cada variable aleatoria F_i toma un valor de f_i en L . Se llamará **Campo Aleatorio** a la familia de variables aleatorias F , se usará la notación $F_i = f_i$ para denotar que el suceso F_i toma el valor f_i .

Un suceso conjunto $\{F_1 = f_1, \dots, F_m = f_m\}$, abreviadamente $F = f$, es una **realización** de F . Se llamará **configuración** del suceso conjunto F a $f = \{f_1, \dots, f_m\}$.

Para un conjunto discreto de etiquetas L , se denota por $P(F_i = f_i) = P(f_i)$ a la probabilidad de que la variable aleatoria F_i tome el valor f_i , y se denota la probabilidad conjunta por $P(F = f) = P(F_1 = f_1, \dots, F_m = f_m) = P(f)$.

Para un conjunto continuo de etiquetas L , se denotan las funciones de densidad de probabilidad por $p(F_i = f_i)$ y $p(F = f)$ respectivamente.

Una familia de variables aleatorias F se dice que es un **Campo Aleatorio de Markov** sobre S con respecto al sistema de vecindad N si y solo si se cumple que:

$$1. P(F = f) > 0 \quad \forall f \in \mathfrak{S}$$

Ecuación 5 - 12

$$2. P(F_i = f_i | F_j = f_j, j \in d, j \neq i) = P(F_i = f_i | F_j = f_j, j \in N_i)$$

Ecuación 5 - 13(Propiedad Markoviana)

La condición (1) es para exigir que F sea un Campo Aleatorio, y es llamada **positividad**. La condición (2) se llama **característica local**. Se dice que la probabilidad de un suceso local a L condicionado a todos los sucesos restantes es equivalente a aquella condicionada a los sucesos vecinos de L . Un Campo Aleatorio de Markov puede tener otras características tales como **homogeneidad** e **isotropía** que no se discutirán aquí.

Finalmente se dirá que un Campo Aleatorio de Markov discreto sobre una trama finita se define como una colección de variables aleatorias, que corresponden a los píxeles de una rejilla, cuya distribución de probabilidad es tal que la probabilidad condicional de que una variable determinada tenga un valor particular, dado los valores del resto de las variables, es idéntica a la probabilidad condicional dados los valores del campo en un conjunto pequeño de píxeles, que son los vecinos de ese píxel determinado.

ESTA TESIS NO SALE
DE LA BIBLIOTECA



5.2.2 DISTRIBUCIÓN DE GIBBS

Diremos que un conjunto de variables aleatorias F es un Campo Aleatorio de Gibbs en S con respecto a N si y sólo si sus configuraciones siguen una distribución de Gibbs. Una distribución de Gibbs tiene la siguiente función de densidad:

$$P(f) = \frac{1}{Z} \exp\left(-\frac{1}{T} U(f)\right)$$

Ecuación 5 - 14

Donde,

$U(f)$ = función de energía

Z = constante de normalización

T = Temperatura

$$Z = \sum_f e^{-\frac{1}{T} U(f)}$$

Ecuación 5 - 15

La función de energía $U(f)$ se define como:

$$U(f) = \sum_c V_c(f)$$

Ecuación 5 - 16

Se considera entonces que $V_c(f)$ es el **potencial de clique**, y que $U(f)$ es la suma de todas las funciones cliques potenciales, $V_c(f)$, para todos los cliques posibles C , donde el valor de $V_c(f)$ depende de la configuración local del clique c , considerándose a la distribución Gaussiana como una caso especial de la familia de distribuciones de Gibbs.

Se dice que un Campo Aleatorio de Gibbs es homogéneo si $V_c(f)$ es independiente de la posición relativa del clique c en S , y se dice que es isotrópico si la región es independiente de la dirección. Es más simple especificar una distribución de Campo Aleatorio de Gibbs si es homogéneo o isotrópico que si no lo es. La homogeneidad se asume en la mayoría de los modelos de Campos Aleatorios de Markov por conveniencia matemática y computacional.

$P(f)$ mide la probabilidad de la ocurrencia de una configuración determinada, o patrón f . Las configuraciones más probables son aquellas con energías más bajas. La temperatura T controla la forma de la distribución. Cuando la temperatura es alta, todas las configuraciones tienden a estar igualmente distribuidas, cuando la temperatura es cercana a cero, la distribución se concentra alrededor del mínimo global de energía. Teniendo T y $U(f)$, se puede generar una "clase de patrones" muestreando el espacio de configuraciones \mathfrak{S} de acuerdo con $P(f)$. Para problemas de etiquetado discretos, la función clique potencial se puede especificar por un número de



parámetros, y la configuración local tiene un número finito de píxeles, y por lo tanto un número finito de valores; en el caso de etiquetado continuo la configuración local puede variar continuamente.

Se puede expresar, por conveniencia, la energía de una distribución de Gibbs como la suma de varios términos correspondientes a cliques de distintos tamaños, como se muestra:

$$U(f) = \sum_{c \in C} V_c(f) = \sum_{\{i\} \in C_1} V_1(f_i) + \sum_{\{i,j\} \in C_2} V_2(f_i, f_j) + \dots$$

Ecuación 5 - 17

La función anterior implica una distribución homogénea de Gibbs porque V_1, V_2, \dots , son independientes de las localizaciones i, j . En las distribuciones no homogéneas de Gibbs, las funciones clique se deben escribir como: $V_1(i, f_i), V_2(i, j, f_i, f_j), \dots$

Un caso importante es cuando se consideran los cliques de tamaño dos como máximo, entonces:

$$U(f) = \sum_{i \in S} V_1(f_i) + \sum_{i \in S} \sum_{j \in N_i} V_2(f_i, f_j)$$

Ecuación 5 - 18

Si se considera que $\{i, j\}$ y $\{j, i\}$ son dos cliques distintos en C_2 (ya que los estados del clique están ordenados), la probabilidad condicional puede escribirse como:

$$P(f_i | f_{N_i}) = \frac{e^{-\left(V_1(f_i) + \sum_{j \in N_i} V_2(f_i, f_j)\right)}}{\sum_{f_i \in L} e^{-\left(V_1(f_i) + \sum_{j \in N_i} V_2(f_i, f_j)\right)}}$$

Ecuación 5 - 19

Un Campo Aleatorio de Markov se caracteriza por sus propiedades locales (Markovianas) mientras que un Campo Aleatorio de Gibbs se caracteriza por sus propiedades globales (distribución de probabilidad Gibbs). El teorema de Hammersley-Clifford establece la equivalencia entre estas dos propiedades: F es un Campo Aleatorio de Markov en S con respecto a N si y solo si F es un Campo Aleatorio de Gibbs en S con respecto a N . Sin embargo, la prueba de que un Campo Aleatorio de Markov es un Campo Aleatorio de Gibbs es mucho más complicada y un resultado sobre la representación única de Campos Aleatorios de Gibbs proporciona tal prueba. [5]



5.3 MODELOS DE CAMPOS ALEATORIOS DE MARKOV

5.3.1 AUTO-MODELOS

En este modelo sólo se usan dos tipos de estados, es por ello que también se conoce como modelo de **Ising**, debido a que se basa en el fenómeno del mismo nombre.

Las restricciones de contexto entre dos etiquetas son un primer nivel a tener en cuenta en la información del contexto. Son muy utilizadas debido a su simplicidad y bajo coste computacional. Se codifican en la función de energía de Gibbs como funciones clique potenciales para cada par de píxeles, como se muestra:

$$U(f) = \sum_{i \in S} V_1(f_i) + \sum_{i \in S} \sum_{j \in N_i} V_2(f_i, f_j)$$

Ecuación 5 - 20

A esta función se le llama energía de segundo orden porque se calcula para cada clique formado por dos estados. Se puede especificar un Campo Aleatorio de Gibbs o un Campo Aleatorio de Markov mediante la selección apropiada de V_1 y V_2 .

Cuando $V_1(f_i) = f_i G_i(f_i)$ y $V_2(f_i, f_j) = \beta_{i,j} f_i f_j$, donde $G_i(\cdot)$ son funciones arbitrarias y $\beta_{i,j}$ son constantes que reflejan la interacción entre cada par de estados i y j , entonces la función de energía:

$$U(f) = \sum_{\{i\} \in C_1} f_i G_i(f_i) + \sum_{\{i,j\} \in C_2} \beta_{i,j} f_i f_j$$

Ecuación 5 - 21

El modelo anterior recibe el nombre de **auto-modelo** [Besag 1974], y este se puede considerar como un modelo **auto-logístico**, si las f_i toman valores en el conjunto de etiquetas discreto $L = \{0,1\}$ o $L = \{+1,-1\}$. La correspondiente función de energía es de la forma:

$$U(f) = \sum_{\{i\} \in C_1} \alpha_i f_i + \sum_{\{i,j\} \in C_2} \beta_{i,j} f_i f_j$$

Ecuación 5 - 22

Donde $\beta_{i,j}$ puede ser interpretado como el coeficiente de interacción. Cuando el sistema de vecinos que se considera es el de 4-vecinos en una rejilla 2D, entonces el modelo auto-logístico se reduce al modelo de Ising y la probabilidad condicional para este modelo es:



$$P(f_i | f_{N_i}) = \frac{e^{\alpha_i f_i + \sum_{j \in N_i} \beta_{i,j} f_i f_j}}{\sum_{f_i \in \{0,1\}} e^{\alpha_i f_i + \sum_{j \in N_i} \beta_{i,j} f_i f_j}} = \frac{e^{\alpha_i f_i + \sum_{j \in N_i} \beta_{i,j} f_i f_j}}{1 + e^{\alpha_i + \sum_{j \in N_i} \beta_{i,j} f_j}}$$

Ecuación 5 - 23

Cuando la distribución es homogénea, tenemos $\alpha_i = \alpha$ y $\beta_{i,j} = \beta$ sin importar i ni j . [5]

5.3.2 MODELO LOGÍSTICO MULTINIVEL (MLL)

El modelo auto-logístico se puede generalizar al **modelo logístico multinivel (MLL por sus siglas en inglés, MultiLevel Logistic)**, también llamado **proceso de Strauss** y **modelo generalizado de Ising**. En este modelo existen $M (>2)$ etiquetas discretas en el conjunto de etiquetas $L = \{1, \dots, M\}$. El clique potencial depende del tipo c (tamaño, dimensión y orientación posible) del clique y de la configuración local. Para los cliques que contienen más de un píxel se definen las funciones clique potenciales MLL como,

$$V_c(f) = \begin{cases} \zeta_c & \text{si todos los estados de } c \text{ tienen la misma etiqueta} \\ -\zeta_c & \text{en otro caso} \end{cases}$$

Ecuación 5 - 24

Donde ζ_c es el potencial para los cliques de tipo c ; para los cliques de un solo estado depende de la etiqueta asignada al píxel:

$$V_c(f) = V_c(f_i) = \alpha_I \quad \text{si } f_i = I \in L_d$$

Ecuación 5 - 25

Donde α_I es el potencial para la etiqueta I . La Figura 5 - 3 muestra los tipos de cliques y los parámetros asociados en sistemas de 8-vecinos (segundo orden).

Se asume que un modelo MLL es de segundo orden, si y solo si α (para cliques de un estado) y β (para cliques de dos estados) son parámetros distintos de cero. La función clique potencial para cliques de dos estados es:

$$V_2(f_i, f_j) = \begin{cases} \beta_c & \text{si los estados del clique } \{i, j\} = c \in C_2 \text{ tienen la misma etiqueta} \\ -\beta_c & \text{en otro caso} \end{cases}$$

Ecuación 5 - 26

Donde β_c es el parámetro β para las cliques de tipo c , y C_2 es el conjunto de cliques de dos estados. Para una vecindad de primer orden hay cuatro tipos de cliques de dos estados (Figura 5 - 3) y cuatro diferentes β_c . Cuando el modelo es isotrópico los



cuatro toman el mismo valor. Debido a su simplicidad, el modelo descrito se usa extensamente para modelar regiones y texturas.

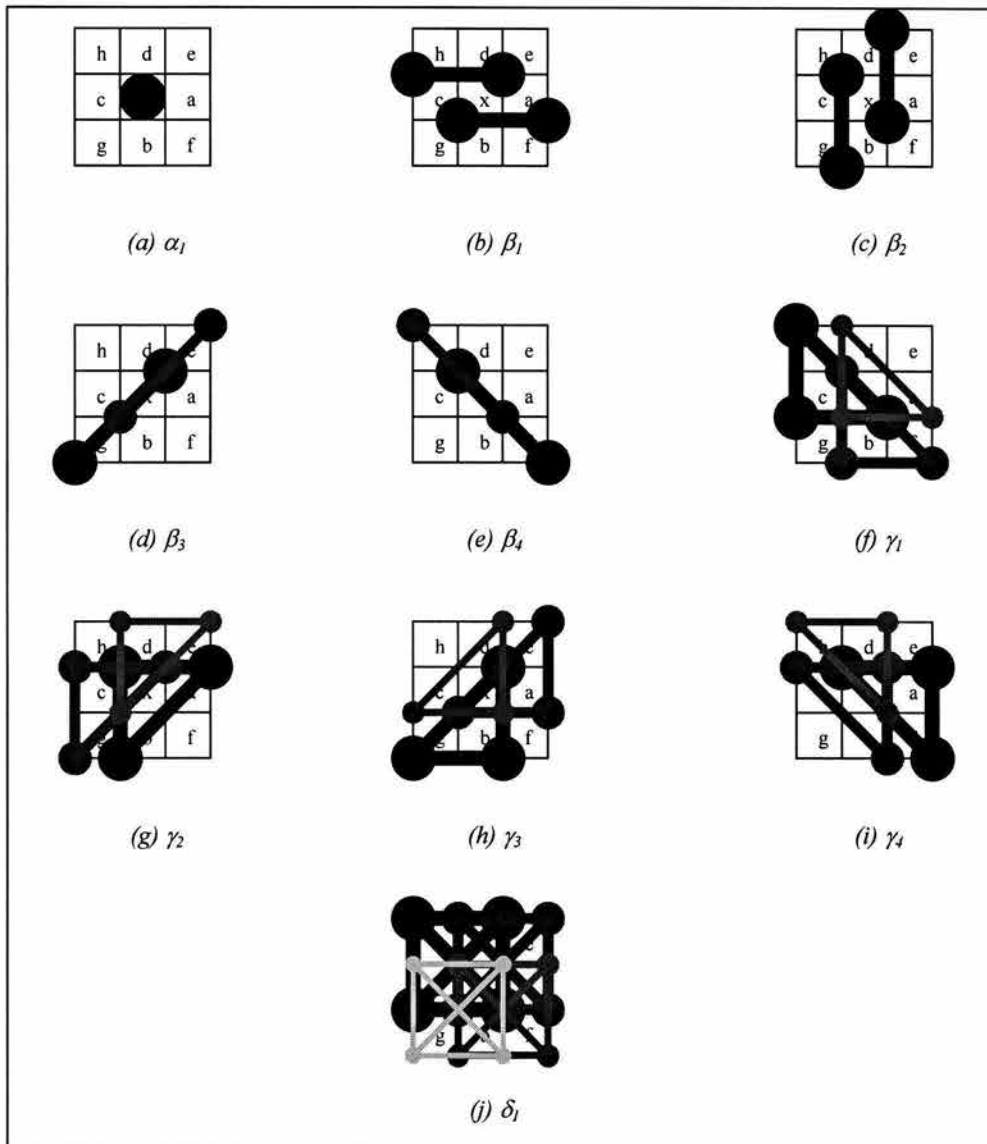


Figura 5- 3 (Tipos de cliques y parámetros potenciales asociados en sistemas de 8-vecinos (segundo orden). Los estados son los puntos y las líneas muestran las relaciones entre vecinos) [5]

Cuando el modelo MLL es isotrópico, la probabilidad condicional puede ser expresada como sigue:

$$P(f_i = I | f_{N_i}) = \frac{e^{-\alpha_i - \beta n_i(I)}}{\sum_{l=1}^M e^{-\alpha_i - \beta n_i(l)}}$$

Ecuación 5 - 27



Donde $n_i(I)$ es el número de estados en N_i que están etiquetados por I . Particularmente cuando sólo hay dos etiquetas, 0 y 1, el modelo se reduce al modelo de Ising. [5]

5.3.3 EJEMPLO DE MODELO CAM PARA SEGMENTACIÓN DE IMÁGENES

La segmentación de imágenes es un proceso que divide una escena en un conjunto de regiones disjuntas basándose en características similares como intensidad, color o textura. La segmentación es el primer nivel en la tarea de entendimiento de la imagen y afecta severamente al proceso posterior de interpretación de la imagen, proporcionando estructuras útiles tales como regiones y bordes. [5]

Como se había mencionado previamente, para segmentar una imagen, la imagen en cuestión, tienen que ser modelada en diferentes tipos de regiones, cada uno de los cuales debe seguir una distribución normal caracterizada por un valor diferente de μ_i y varianza σ_i^2 . Si tomamos en cuenta la distribución de Gibbs de la región en proceso, y estableciendo $T = 1$, se puede escribir una medida de probabilidad generalizada de que el píxel x , pertenezca a algún tipo de región:

$$P(f_i = I | f_{N_i}) \propto \exp \left\{ -\frac{1}{2\sigma_i^2} (f_{N_i} - \mu_i)^2 - \sum_{c \in C} V_c(f_i) |_{f_i=I} \right\}$$

Ecuación 5 - 28

Este modelo se compone de dos partes; la primera, obliga a que la intensidad de los píxeles que pertenecen a una misma región sea casi idéntica. La segunda, depende de las características de los píxeles vecinos al píxel central, y establece continuidad espacial. De acuerdo a la definición de la función de energía, es claro que si el número de píxeles que pertenecen a los tipos de regiones i en el vecindario son exactamente los mismos, el segundo término de la ecuación anterior tendrá el mismo valor para todos los tipos de regiones. Esto no cambiara el orden relativo de los valores de probabilidad y la característica del píxel bajo consideración será determinada solamente por estos datos. Por el contrario, si estos números son diferentes unos de otros, el valor de probabilidad correspondiente al máximo de ellos obtendrá una incremento mayor y el píxel central será más probable que sea asignado al tipo de región afín a este. Si el valor del término dependiente llega a ser insignificante, en el caso de que β sea muy grande por ejemplo, la característica de ese píxel será decidida principalmente por la característica de sus vecinos. En pocas palabras, la fuerza espacial tendrá efecto sólo cuando el número de píxeles pertenecientes a algún tipo de región i en el grupo de vecinos del píxel central difieran uno de otro y esto causará que la característica de cada píxel en la segmentación de la imagen sea más parecida con las de la mayoría de sus vecinos. Finalmente, tomando la probabilidad logarítmica de la forma anterior, puede obtenerse fácilmente un tipo de clasificación de máxima verosimilitud. [7]



6. ESQUEMA MIXTO DE SEGMENTACIÓN: ANÁLISIS BAYESIANO Y CAMPOS ALEATORIOS DE MARKOV

El modelo de segmentación usando un Análisis Bayesiano resulta muy útil y práctico en la tarea de la clasificación; sin embargo, puede tener problemas de clasificación errónea debido a que en muchos de los casos la probabilidad de pertenencia de un píxel a una clase determinada es muy baja. Esto es lo que nos lleva a crear un esquema mixto de segmentación en el que se defina una sexta **clase de rechazo**, tal que si $P(\omega_i | X) \leq 0.09$, el píxel analizado será asignado a esta clase, finalmente esta será segmentada usando Campos Aleatorios de Markov para asegurar que estos píxeles se clasifican correctamente, de ahí el término de segmentación semisupervisada. En la figura 6 - 1 podemos observar un diagrama que ejemplifica el proceso de segmentación mixto llevado a cabo.

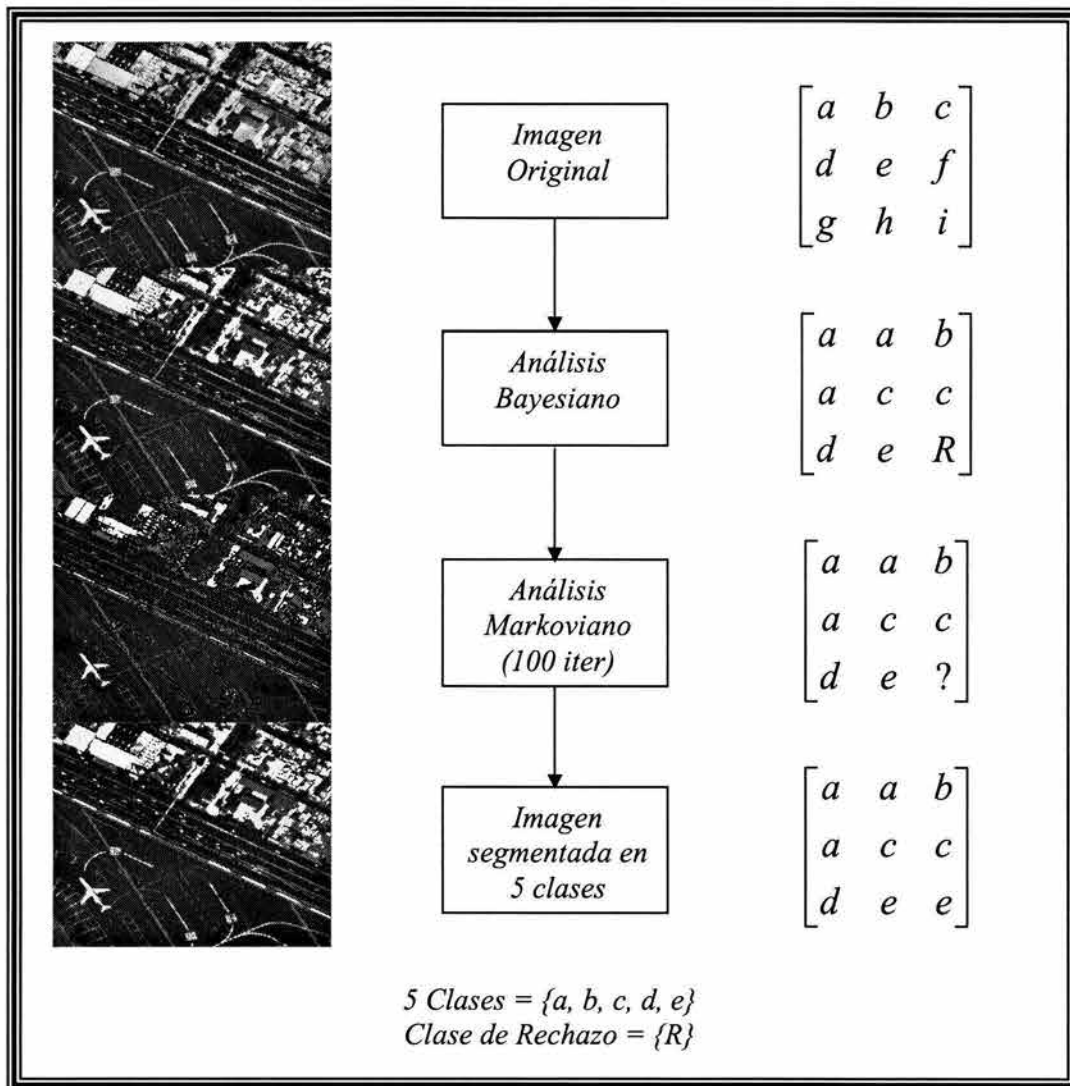


Figura 6 - 1 (Diagrama de segmentación mixta)



6.1 SEGMENTACIÓN CON ANÁLISIS BAYESIANO

Se consideró la regla de Bayes $P(\omega_i | X) = \frac{P(X | \omega_i)P(\omega_i)}{P(X)}$, siendo X la imagen

original y ω_i las clases, con $i = 0, 1, 2, \dots, 4$, donde:

$P(\omega_i | X)$ representa la probabilidad a posteriori

$P(X | \omega_i)$ es la probabilidad conjunta de X dado ω_i

$P(\omega_i)$ es la probabilidad a priori de la clase ω_i

$P(X)$ es la probabilidad total de X

Debe notarse que no es necesario calcular $P(X)$ en la regla de Bayes, ya que por ser término común, se puede eliminar del procedimiento.



Figura 6 - 2 (Diagrama de bloques del proceso de Segmentación con Análisis Bayesiano)

Debe tenerse en cuenta que para este diagrama se supuso que el sistema dispone ya de un módulo de adquisición de datos, y nuestro proceso de segmentación se concentra únicamente en los pasos posteriores a la obtención de la imagen, es por ello que el primer paso es leer la imagen. Las imágenes que se usaran para nuestro propósito son imágenes obtenidas a través de la fotografía aérea y corresponden a regiones semiurbanas del sur y oriente de la Ciudad de México, las imágenes se encuentran definidas en 256 niveles de gris, y en esta parte del esquema sólo se busca encontrar las 5 clases típicas que caractericen cada imagen y este proceso se lleva a cabo, como se verá posteriormente, por medio de la observación del usuario.

PROCEDIMIENTO

1. Proceso de LECTURA DE IMAGEN: DF1_PRI.RAW, DF1_IZQ.RAW, DF3_512.RAW.
2. Proceso de SELECCIÓN DE CLASES:
 - a) Sobre cada imagen se definieron 5 ventanas que identificaban clases típicas (vegetación, calles, techos de construcciones, sombras, agua). Posteriormente se calculó la media sobre cada ventana, obteniendo m_i , con $i = 0, 1, 2, \dots, 4$.



b) Se aproximó $P(X|\omega_i)$ mediante las funciones siguientes:




Figura 6 - 3 (Términos de probabilidad condicional o conjunta)

Estas funciones indican la probabilidad condicional de que un píxel dado pertenezca a la clase ω_i .

3. Proceso de PRECLASIFICACIÓN:



- a) Se empleó la aproximación de la regla de Bayes:

$$P(\omega_i | X) \approx P(X | \omega_i)P(\omega_i)$$

Ecuación 6 - 1

- b) Se consideraron como equiprobables a las probabilidades de ocurrencia de las clases $P(\omega_i)$.
- c) Se analizó píxel por píxel la imagen X , clasificando de acuerdo a los valores máximos de probabilidad a posteriori.
4. Proceso de CLASIFICACIÓN:
- a) Se actualizaron las probabilidades de ocurrencia de las clases, $P(\omega_i)$.
- b) Se repitió el proceso de SELECCIÓN DE CLASES a partir del inciso (b), y el proceso de PRECLASIFICACIÓN completo.
5. Proceso de OBTENCIÓN DE CLASE DE RECHAZO:
- a) Se definió una sexta clase de rechazo para cada imagen, de tal forma que para la primera imagen (DF1_PRI.RAW) si $P(\omega_i | X) \leq 0.09$, el píxel analizado sea asignado a la clase de rechazo, para la segunda imagen (DF1IZQ.RAW) si $P(\omega_i | X) \leq 0.09$, el píxel analizado sea asignado a la clase de rechazo de esta imagen y para la tercera imagen (DF3_512.RAW) si $P(\omega_i | X) \leq 0.12$, el píxel analizado sea asignado a su clase de rechazo correspondiente.

6.2 SEGMENTACIÓN CON CAMPOS ALEATORIOS DE MARKOV

Para esta parte, se tomaron en cuenta las clases que ya se habían obtenido a través del Análisis Bayesiano, para posteriormente reclasificar los píxeles obtenidos en la clase de rechazo (Matriz R) a través del método de Campos Aleatorios de Markov, usando el algoritmo del **Recocido Simulado**.

PROCEDIMIENTO

1. Proceso de OBTENCIÓN FUNCIONES DE ENERGÍA: Para ello se aproximaron las probabilidades conjuntas del numerador de la regla de Bayes mediante las funciones de energía mostradas a continuación, ellas indican la probabilidad condicional de que un píxel dado pertenezca a la clase ω_i . Se empleó el modelo de Potts para el cálculo de la energía **a priori** de clase, empleando vecindades en 8-conexidad y cliques de segundo orden.

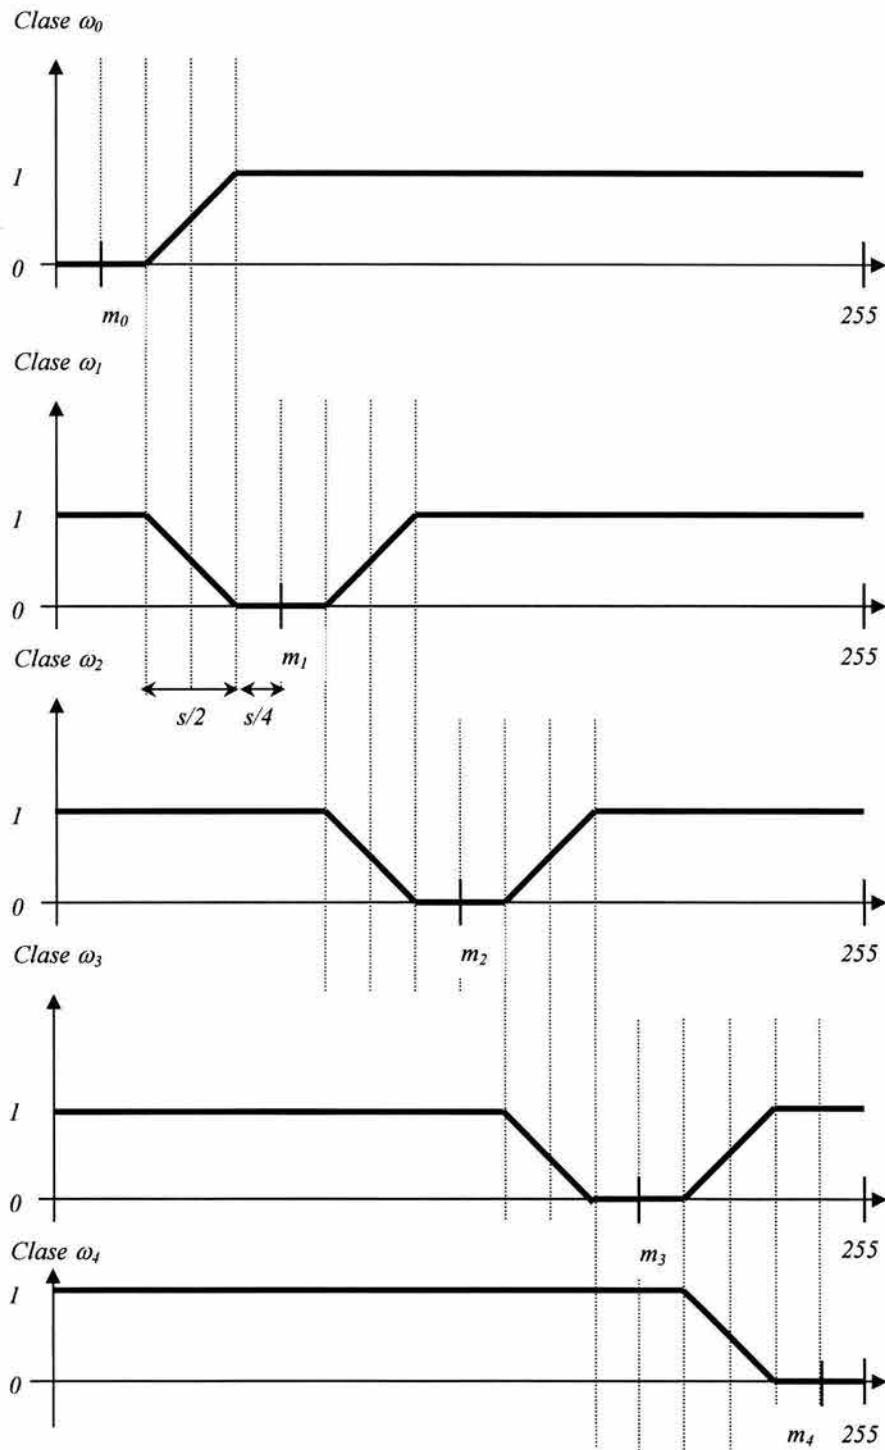


Figura 6 - 4 (Términos de energía $U(X | \omega_i)$)



2. Proceso de CLASIFICACIÓN:

- a) Se empleó la aproximación de la regla de Bayes $P(\omega_i | X) \approx P(X | \omega_i)P(\omega_i)$ para calcular la energía a posteriori:

$$U(\omega_i | X) \approx U(X | \omega_i) + U(\omega_i)$$

Ecuación 6 - 2

- b) Se analizó píxel por píxel la imagen X , clasificando al aplicar el algoritmo de recocido simulado que se muestra a continuación, para ello se uso una constante $\beta = 0.04$ y una $T_{inicial} = 4$.

6.2.1 RECOCIDO SIMULADO (SIMULATED ANNEALING)

El algoritmo de recocido simulado se basa en una analogía entre el recocido de sólidos y la problemática de resolver problemas de optimización combinatoria de gran escala. Por esta razón el algoritmo se conoce como recocido simulado. Recocido denota un proceso de calentamiento de un sólido a una temperatura en la que sus granos deformados cristalizan para producir nuevos granos. La temperatura de recocido o de recristalización, depende del tipo de material, del grado de deformación del mismo. Seguida a la fase de calentamiento, viene un proceso de enfriamiento en donde la temperatura se baja poco a poco. De esta manera, cada vez que se baja la temperatura, las partículas se acomodan en estados de más baja energía hasta que se obtiene un sólido con sus partículas acomodadas conforme a una estructura de cristal.

En general, encontrar el mínimo global de una función objetivo con muchos grados de libertad sujeta a restricciones es un problema completo, ya que la función objetivo tiende a tener varios mínimos locales.

Un procedimiento para resolver problemas de optimización difíciles debe muestrear valores de la función objetivo de forma tal que se tenga una alta probabilidad de encontrar soluciones cerca del óptimo y debe también poder implementarse de manera eficiente. El recocido simulado es una técnica que cumple con estos requerimientos.

Inicializar T y f ;
 Repetir
 muestrear aleatoriamente f de $N(f)$ bajo T ;
 decrementar T ;
 mientras ($T \rightarrow 0$);
 regresar f ;

Figura 6 - 5 (Algoritmo de recocido simulado)



Inicialmente T es fijada en un valor alto y f es una configuración que se inicializa de manera aleatoria.

En la práctica, el algoritmo de Recocido Simulado, emplea un **algoritmo de Metrópolis**, con un esquema de temperatura variable, a fin de minimizar la función de energía a posteriori $U(X|Y)$. El objetivo del problema de optimización consiste en encontrar un elemento de Ω_0 donde $\Omega_0 = (\varpi \in \Omega, \text{donde } \varpi \text{ es de energía mínima})$.

U^* es la energía máxima en todas las configuraciones y U_* es la energía mínima, la desviación entre las dos energías es $\Delta U = U^* - U_*$.

Al emplear un muestreador de Gibbs con una temperatura T_n , que varía después de cada barrido, la variación de la temperatura debe seguir el esquema:

$$T_n \rightarrow 0 \text{ cuando } n \rightarrow \infty$$

$$T_n = \frac{N\Delta U}{\log(n)} \text{ para } n \geq 2$$

Donde N es el número de píxeles en la imagen.

Para toda configuración inicial η (de la imagen) y para toda la configuración de una interacción cualquiera ϖ , se tiene

$$\lim_{n \rightarrow \infty} P(Y^{(n)} = \varpi | Y^{(0)} = \eta) = \pi(\varpi)$$

Ecuación 6 - 3

Donde $\pi(\varpi)$ corresponde a la medida de probabilidad de Gibbs definida por los Campos Aleatorios de Markov. Así, existe una convergencia hacia una realización dada, con una probabilidad que sigue la distribución de Gibbs global.

El Algoritmo de Recocido Simulado aplicado al CAM quedaría como sigue:

1. Inicialización
 - Determinación aleatoria de la solución $Y^{(0)}$
 - Escoger una temperatura inicial $T^{(0)}$ suficientemente elevada
2. Barrido secuencial de la Imagen

En cada etapa (n)

 - Escoger un píxel:

$r=s^{(n)}$ su valor es $Y_r^{(n)}$ y su configuración de vecindad es $V_r^{(n)}$
 - Efectuar sorteo:

Variable aleatoria con distribución uniforme $\xi \in \Omega$



3. **Criterio de Metrópolis usando un análisis en 8-conexidad**

- Calcular variación de la energía local asociada al píxel r :

$$\Delta U = U(\xi | V_r^{(n)}, X) - U(Y_r^{(n)} | V_r^{(n)}, X)$$

Ecuación 6 - 4

- Pueden surgir dos casos

$$\text{Si } \Delta U \leq 0 \Rightarrow Y_r^{(n+1)} = \xi$$

$$\text{Si } \Delta U > 0 \Rightarrow Y_r^{(n+1)} = \xi \text{ con probabilidad } \xi = e^{-\frac{\Delta U}{T}}$$

4. Continuar con la etapa 2

5. Serie de temperaturas decrecientes hacia 0, por lo que $\lim_{n \rightarrow \infty} T_n = 0$

La expresión $\Delta U = U(\xi | V_r^{(n)}, X) - U(Y_r^{(n)} | V_r^{(n)}, X)$ representa tanto la variación local de energía, como la variación global de la energía asociada a la transición $Y_r^{(n+1)} = \xi$. De forma práctica, se simula la probabilidad dada por $p = e^{-\frac{\Delta U^{(n)}}{T^{(n)}}}$, efectuando el sorteo aleatorio de una variable distribuida uniformemente, $\eta \in [0,1]$

$$Y_r^{(n+1)} = \begin{cases} \xi & \text{si } 0 \leq \eta \leq p \\ Y_r^{(n)} & \text{otro caso} \end{cases}$$

Ecuación 6 - 5

Para minimizar la función de energía a posteriori es necesario decrementar la temperatura para cada configuración, ya que para temperaturas altas, las configuraciones mas aleatorias están presentes. Para asegurar la convergencia a un mínimo global, el esquema de decremento de temperatura, que deberá ser de las siguientes condiciones:

$$\lim_{t \rightarrow \infty} T^{(t)} = 0$$

Ecuación 6 - 6

$$T^{(n)} \geq \frac{m \times \Delta}{\ln(1+n)}$$

Ecuación 6 - 7



Donde $\Delta = \max E(f) - \min E(f)$ y m es el número de píxeles, entonces el sistema converge al mínimo global, la desventaja de esta ecuación es la lentitud, de manera heurística se han adoptado los siguientes esquemas:

1. El primero, establecía una velocidad de enfriamiento de la temperatura de tipo geométrico, $T^{(n+1)} = \alpha \cdot T^{(n)}$ como $0 < \alpha < 1$. Las evidencias empíricas señalaban que valores elevados de α comprendidos entre 0.8 y 0.99 eran los que mejores resultados proporcionaban.
2. Según el segundo esquema de enfriamiento, se ejecuta una sola iteración para cada temperatura, pero por el contrario la temperatura se reduce a una velocidad muy lenta según la fórmula $T \rightarrow \frac{T}{1 + \beta \cdot T}$, siendo β muy pequeño.
3. Entre los esquemas de descenso de temperatura también se encuentran los de la forma $T^{(n)} = \frac{c}{\log(n+1)}$, donde n es el número de iteraciones.

Si la temperatura decrece lo suficientemente lento, el proceso converge a la solución óptima, sin embargo, una función de reducción de temperatura que garantice esa convergencia al óptimo global, requeriría unos tiempos de cálculo prohibitivos. [55]



7. RESULTADOS DE SEGMENTACIÓN

En esta parte de la Tesis se muestran las 3 imágenes que se usaran para nuestro propósito son imágenes obtenidas a través de la fotografía aérea y corresponden a regiones semiurbanas del sur y oriente de la Ciudad de México, las imágenes se encuentran definidas en 256 niveles de gris.

7.1 REGIONES URBANAS DEL DISTRITO FEDERAL

7.1.1 SEGMENTACIÓN CON ANÁLISIS BAYESIANO

7.1.1.1. Imagen DF1_PRI.RAW

Con los siguientes vectores de medias y probabilidades de clase actualizadas se obtuvieron los siguientes resultados (Figura 7 – 1 y Figura 7 – 2):

$$m_i = [78 \quad 96 \quad 116 \quad 161 \quad 244]$$

$$P_{wi} = [0.4106 \quad 0.1506 \quad 0.1483 \quad 0.1809 \quad 0.1096]$$

Definiendo la sexta clase de rechazo con:

$$P(\omega_i | X) \leq 0.09$$




Figura 7 - 1 (Imagen Original DF1_PRI.RAW)

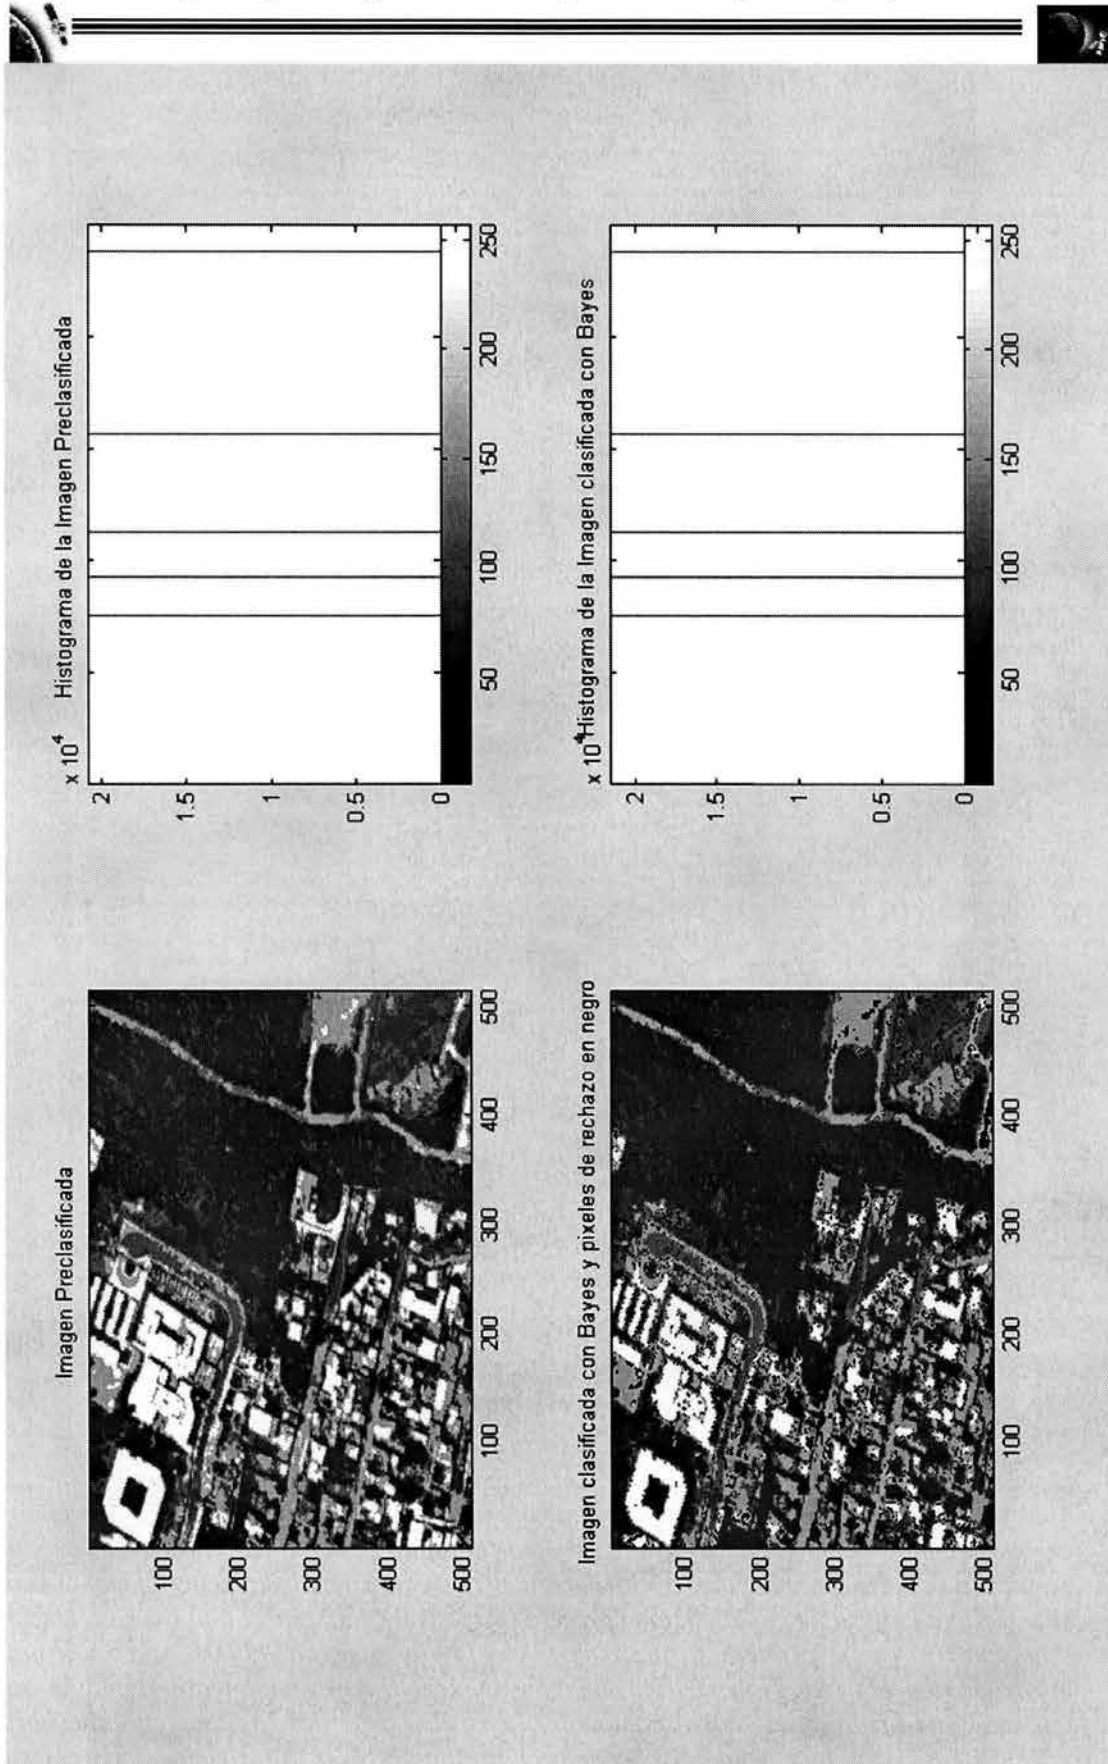


Figura 7 - 2 (Resultados de Análisis Bayesiano)



7.1.1.2. Imagen DF11ZQ.RAW

De la misma forma que en la imagen anterior usando los siguientes vectores de medias y probabilidades de clase actualizadas se obtuvieron los siguientes resultados:

$$m_i = [87 \ 123 \ 132 \ 173 \ 228]$$

$$P_{wi} = [0.4564 \ 0.1433 \ 0.1066 \ 0.1473 \ 0.1465]$$

Definiendo la sexta clase de rechazo con (Figura 7 - 3 y Figura 7 - 4):

$$P(\omega_i | X) \leq 0.09$$




Figura 7 - 3 (Imagen Original DF11ZQ.RAW)

Para este análisis, se obtuvieron cuatro resultados importantes (Figura 7 - 4), en el primero se observa la imagen preclasificada y su histograma correspondiente, la cual ya nos muestra una segmentación buena, pero existe el riesgo de clasificar zonas erróneamente y de tener zonas aisladas, es por ello que se actualizan probabilidades y se crea la sexta clase, que nos permite clasificar correctamente los píxeles en los que no se tiene una certeza de clasificación correcta; este nivel se da por el umbral de rechazo escogido, y estos píxeles se muestran en la imagen en color negro siendo aproximadamente: 15,173 para la imagen DF11ZQ.RAW; finalmente, también se muestra el histograma correspondiente. En el caso de la imagen anterior, DF1_PRI.RAW, el número de píxeles de rechazo fue de 12,783 aproximadamente, y se obtuvieron resultados muy similares.

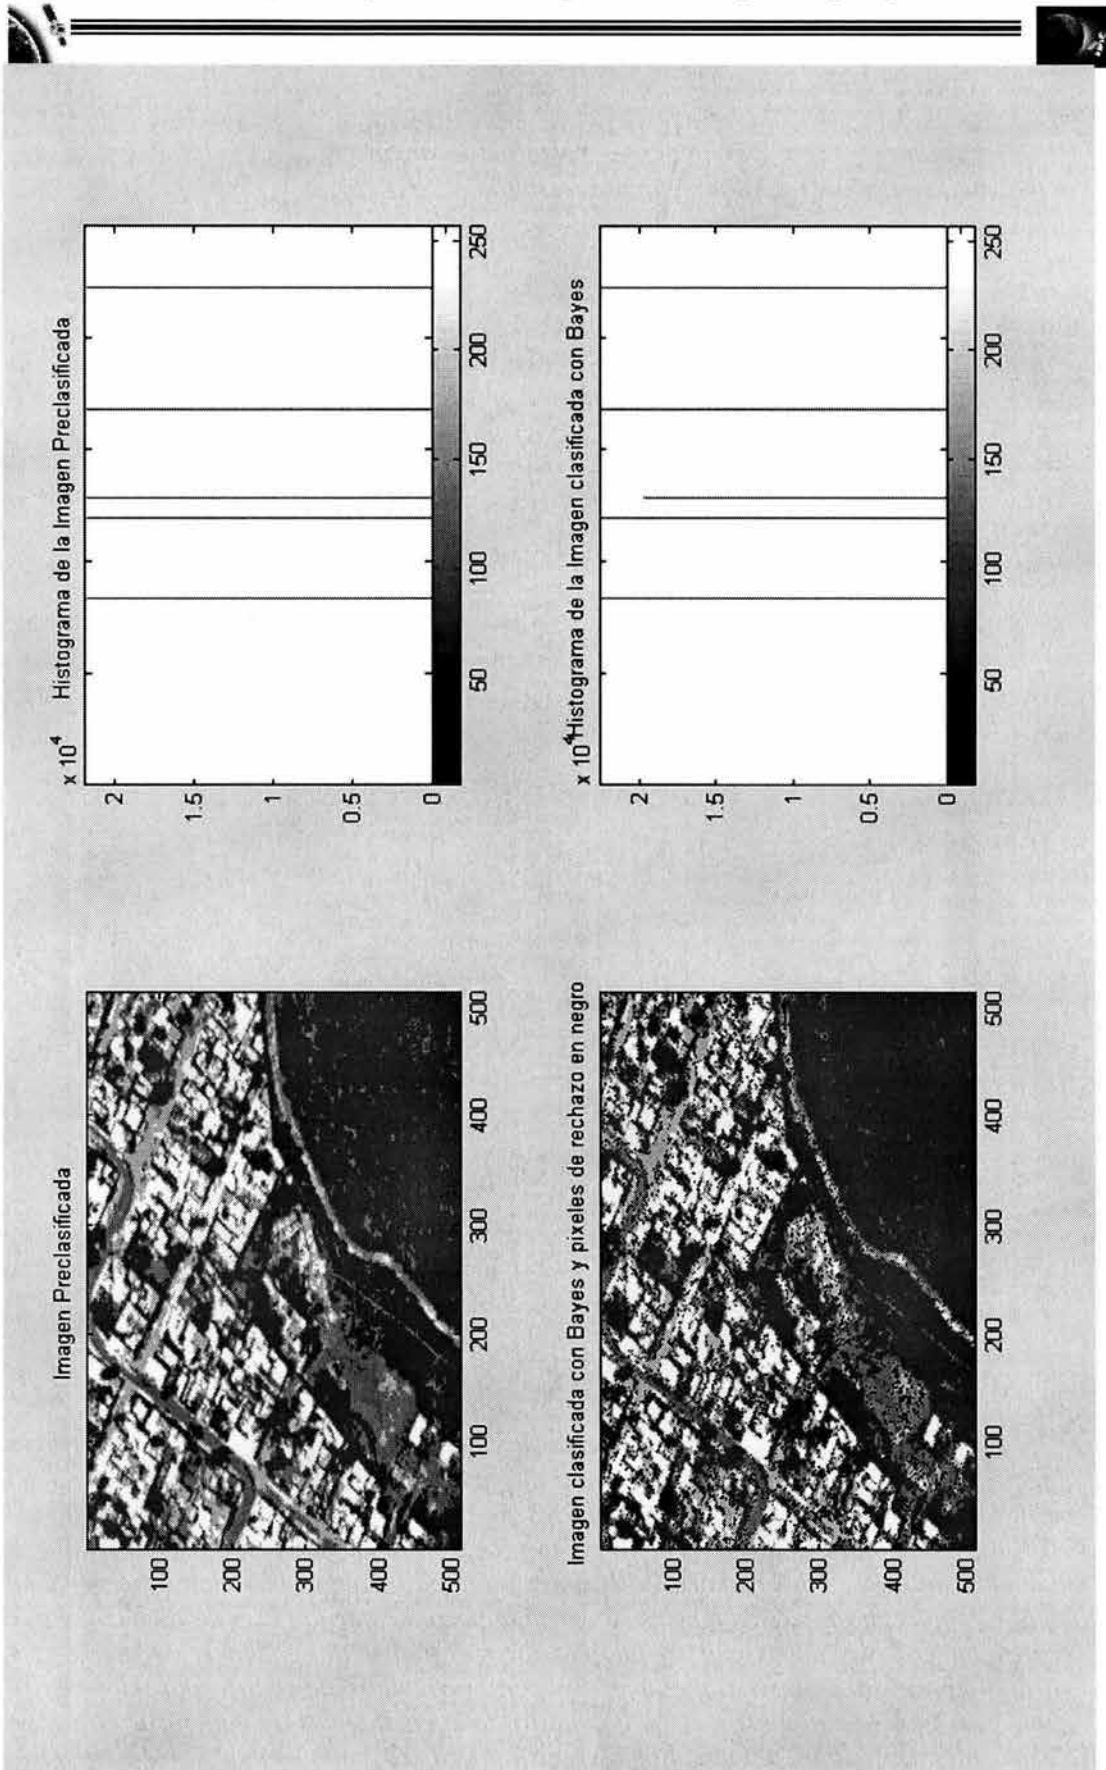


Figura 7 - 4 (Resultados de Análisis Bayesiano)



7.1.1.3. Imagen DF3_512.RAW

Finalmente, con los siguientes vectores de medias y probabilidades de clase actualizadas se obtuvieron los siguientes resultados:

$$m_i = [63 \quad 68 \quad 87 \quad 111 \quad 234]$$

$$P_{wi} = [0.1660 \quad 0.2961 \quad 0.2076 \quad 0.2024 \quad 0.1280]$$

Definiendo la sexta clase de rechazo con (Figura 7 – 5 y Figura 7 – 6):

$$P(\omega_i | X) \leq 0.12$$




Figura 7 - 5 (Imagen Original DF3_512.RAW)

Esta última imagen que difiere de las dos anteriores, porque se observa la diferencia de clases muy claramente en el aeropuerto, nos permitió aplicar el análisis markoviano a un mayor número de píxeles de rechazo, que en este caso resultó de 26,333 píxeles, debido a que el umbral de rechazo cambió de ser 0.09 para las dos imágenes anteriores a ser ahora 0.12. En esta última imagen se pueden observar muy bien las zonas en la que los píxeles se agrupan para formar la clase de rechazo, y que corresponderá al análisis markoviano clasificar. Finalmente, podemos decir que este ya muy conocido Análisis Bayesiano nos permitió definir de una forma muy fácil y rápida las bases en la clasificación de nuestra imagen, además de minimizar el tiempo de procesamiento, pues si todo el análisis se hubiera realizado usando CAM, se tendría que haber invertido más tiempo para barrer la imagen completa.

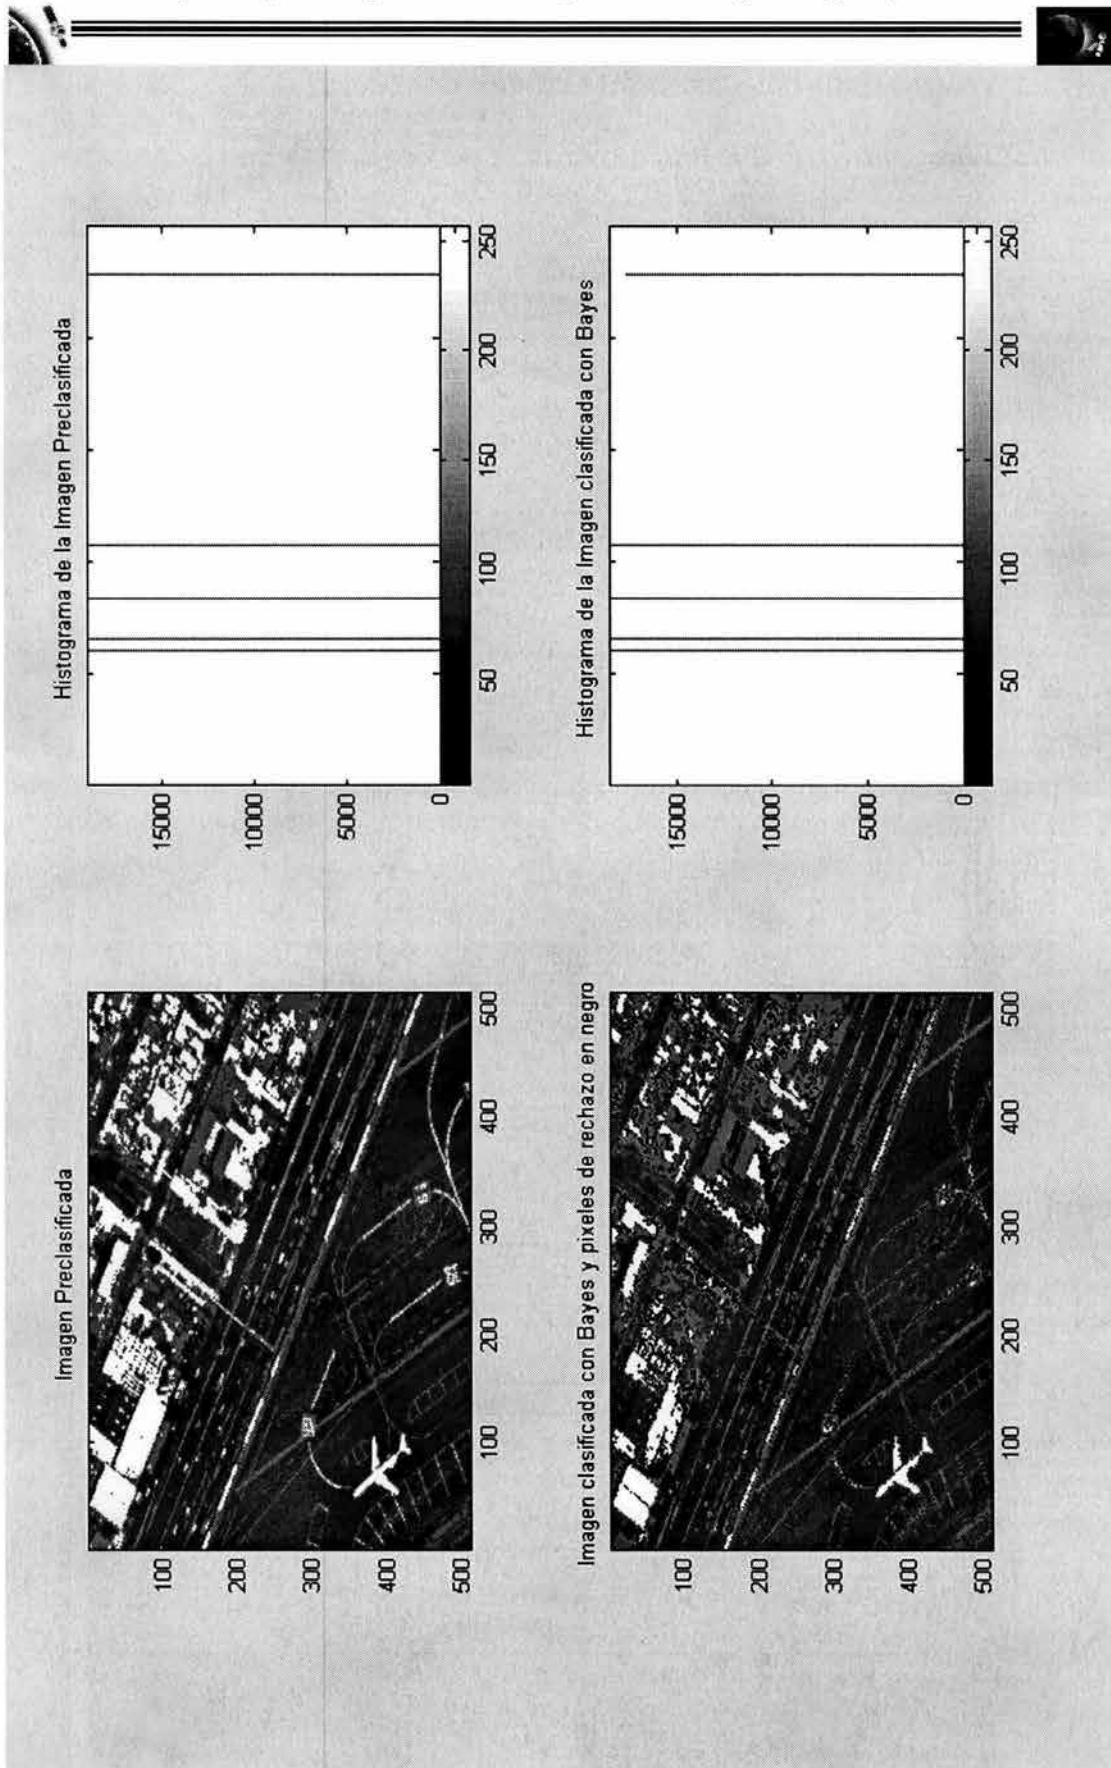


Figura 7 - 6 (Resultados de Análisis Bayesiano)



7.1.2 SEGMENTACIÓN CON CAMPOS ALEATORIOS DE MARKOV

7.1.2.1. Imagen DF1_PRI.RAW

En esta parte del Análisis usando Campos Aleatorios de Markov se obtuvieron 5 resultados para cada iteración, en la primera imagen podemos observar el primero de ellos para la imagen DF1_PRI.RAW, en el que se muestran la parte del algoritmo correspondiente a la obtención de las funciones de energía (Figura 7 - 7), en la segunda figura se muestra a la imagen una vez analizada con 10 iteraciones (Figura 7 - 8), en la que sólo se observan los píxeles que se han clasificado con CAM, es decir, los píxeles de rechazo, el resto de los píxeles (los analizados con Análisis Bayesiano) se muestran en color negro (Nivel de gris=0), posteriormente podemos ver el histograma de la imagen (Figura 7 - 9) anterior a manera de complemento. Finalmente se muestran las últimas dos imágenes que corresponden a la última fase del procedimiento, que es la segmentación mixta, en la que se unen las dos imágenes previas, la primera obtenida a través del Análisis Bayesiano dejando los píxeles de rechazo en color negro, y la segunda que se obtuvo recientemente a través del Análisis con CAM, por último sólo se suman ambas imágenes y se obtiene el resultado que se muestra en la Figura 7 - 10, con su correspondiente histograma que se observa en la Figura 7 - 11. Cabe resaltar que para este análisis el tiempo de procesamiento disminuyó bastante, pues sólo se barrían los píxeles de rechazo, llegando a tener tiempos de 10 minutos 37 segundos como tiempo promedio máximo para 100 iteraciones, sólo en el Análisis Markoviano usando una PC Pentium 3 a 800 KHz.




Figura 7 - 7 (Funciones de energía para DF1_PRI.RAW)




Figura 7 - 8 (Píxeles de rechazo clasificados con Markov)

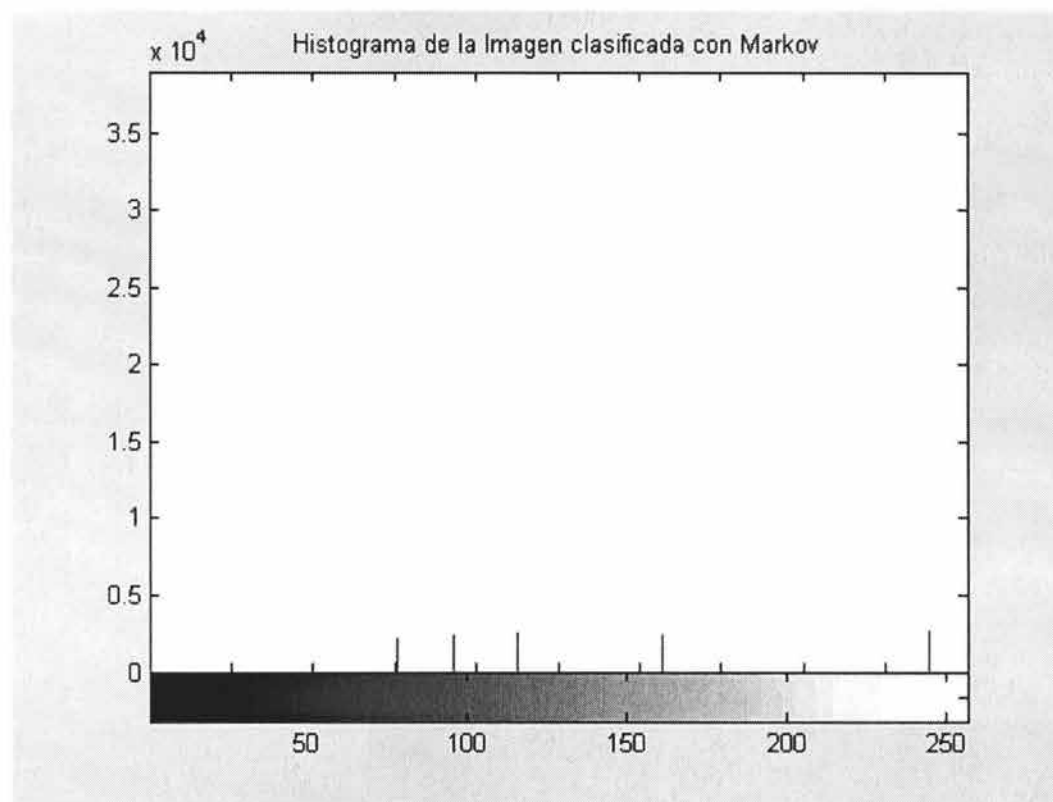


Figura 7 - 9 (Histograma de la imagen anterior)




Figura 7 - 10 (Imagen con segmentación mixta)

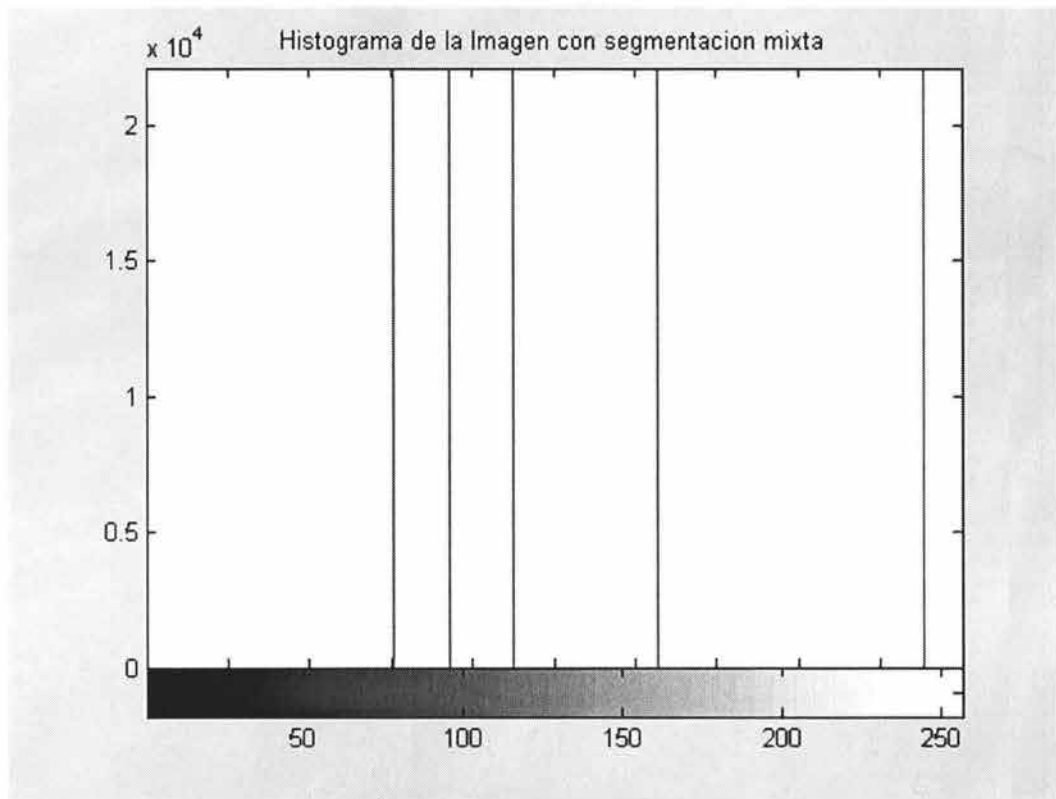


Figura 7 - 11 (Histograma de la imagen anterior)



Como se mostró en el Capítulo 6, el Análisis Markoviano es iterativo, es por ello que con cada iteración se obtienen mejores resultados, y esto depende en gran medida del coeficiente de convergencia (β). Es por ello que en las siguientes imágenes sólo se mostrarán los resultados obtenidos con las iteraciones: 20, 40, 60, 80 y 100.

Tomando como referencia la primera imagen que es resultado de 10 iteraciones, podemos observar muchos puntos blancos, que son resultado de una clasificación errónea, debido a que como el análisis llevado a cabo es un proceso aleatorio, esos píxeles aislados aún no han tomado el nivel de gris correcto.

La primera (10 iteraciones), segunda (20 iteraciones), tercera (30 iteraciones) y cuarta (40 iteraciones) imágenes no difieren mucho entre sí, se observan cambios muy ligeros en los niveles de gris de la imagen, pero los agrupamientos nos se hacen tan notorios sino hasta la iteración número 60, en donde ya se observan menos puntos blancos y más zonas homogéneas.

Pero es en la iteración número 80 en la que se observan puntos aislados contados y las zonas casi homogéneas, y en la iteración número 100 se observan las zonas homogéneas perfectamente bien definidas y todo lo anterior se puede observar en la gráfica de la Figura 7 – 18, en la que se tabulan las iteraciones contra la energía a posteriori. De esta forma podemos reafirmar lo que se muestra en las figuras con las iteraciones mostradas, y observar como entre más se acerca la $U(\omega_i | X)$ a cero, se obtienen mejores resultados, como es el caso de la iteración número 100, en la que la función de energía a posteriori es casi cero.

Con 20 iteraciones:




Figura 7 - 12 (20 Iteraciones)



Con 30 iteraciones:




Figura 7 - 13 (30 Iteraciones)

Con 40 iteraciones:




Figura 7 - 14 (40 Iteraciones)



Con 60 iteraciones:




Figura 7 - 15 (60 Iteraciones)

Con 80 iteraciones:




Figura 7 - 16 (80 Iteraciones)



Con 100 iteraciones:




Figura 7 - 17 (100 Iteraciones)




Figura 7 - 18 (Función de energía a posteriori)




Figura 7 - 19 (Comparación final)



En esta última imagen (Figura 7 - 19) se muestra de manera muy didáctica la comparación entre la imagen original, la imagen preclasificada con Análisis Bayesiano, la imagen clasificada con probabilidades actualizadas y el mismo tipo de análisis que la imagen anterior y finalmente se muestra el resultado que se obtiene al mezclar la imagen anterior con los píxeles clasificados usando un Análisis Markoviano de 100 iteraciones.

Con circunferencias en color verde se han señalado los puntos en donde hay mejoras en la clasificación y que no existían en la etapa previa a la segmentación mixta, y con circunferencias rojas los puntos en donde se tienen pérdidas de información que se tenían definidas en la etapa anterior.

Como podemos observar son más las mejoras que las pérdidas; y aunque en esta imagen no se pueden apreciar muy fácilmente los cambios, debido a que el número de píxeles de rechazo es pequeño, podemos observar que el Análisis Bayesiano nos da muy buenos resultados, pues en zonas en donde se tenía incertidumbre acerca de la clasificación, con el Análisis Markoviano estas dudas se aclaran y muchas de las zonas con píxeles de rechazo se conservan como en la clasificación previa, y algunas otras (las marcadas con la circunferencia verde) se mejoran, pudiéndose comprobar lo anterior si se compara cada una de las zonas con la imagen original.

Estas comparaciones se llevaron a cabo para cada una de las 3 imágenes analizadas, y como se ha estado mencionando, el análisis Markoviano nos arrojó mejores resultados con la última imagen, pues es la que tiene el mayor número de píxeles de rechazo.

Las ventanas que se tomaron de las imágenes, para la comparación en cada caso fueron de 128 x 128 píxeles, y se escogieron las zonas en donde se observaban más claramente los resultados, siendo mucho más fácil detectarlas en la última imagen y menos fácil en la primera.

7.1.2.2. Imagen DF11ZQ.RAW

La imagen DF11ZQ.RAW es muy similar a la anterior (DF1_PRI.RAW), y por ende se obtuvieron resultados muy parecidos, las imágenes que se muestran en esta parte son con el mismo propósito que las de la imagen anterior, claro que como las medias cambian, también se modifican un poco las Funciones de Energía como se muestra en la Figura 7 – 20.

La explicación de las figuras siguientes es la misma que la de la imagen anterior, con la diferencia de que esta imagen tiene un número mayor de píxeles de rechazo, y por tanto el tiempo de procesamiento en este caso aumenta, pero no considerablemente.

Finalmente también se muestran los resultados para 20, 30, 40, 60, 80 y 100 iteraciones, y se observan resultados muy similares a los de la imagen anterior, de hecho también es en la iteración número 60 en la que se observan cambios notables en la agrupación de los píxeles, pero es con la iteración número 100, con la que se obtienen los mejores resultados, con zonas homogéneas perfectamente bien definidas.




Figura 7 - 20 (Funciones de energía para DFHIZQ.RAW)

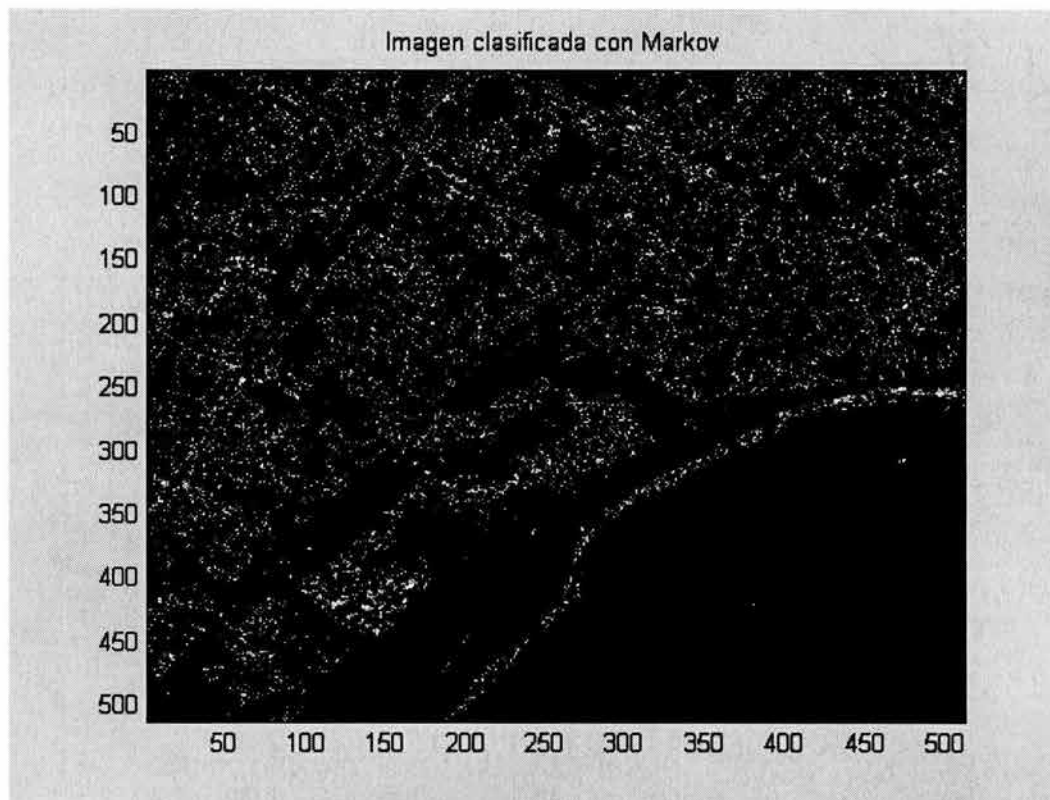


Figura 7 - 21 (Píxeles de rechazo clasificados con Markov)




Figura 7 - 22 (Histograma de la imagen anterior)




Figura 7 - 23 (Imagen con segmentación mixta)




Figura 7 - 24 (Histograma de la imagen anterior)

Con 20 iteraciones:




Figura 7 - 25 (20 Iteraciones)



Con 30 iteraciones:




Figura 7 - 26 (30 Iteraciones)

Con 40 iteraciones:




Figura 7 - 27 (40 Iteraciones)



Con 60 iteraciones:




Figura 7 - 28 (60 Iteraciones)

Con 80 iteraciones:

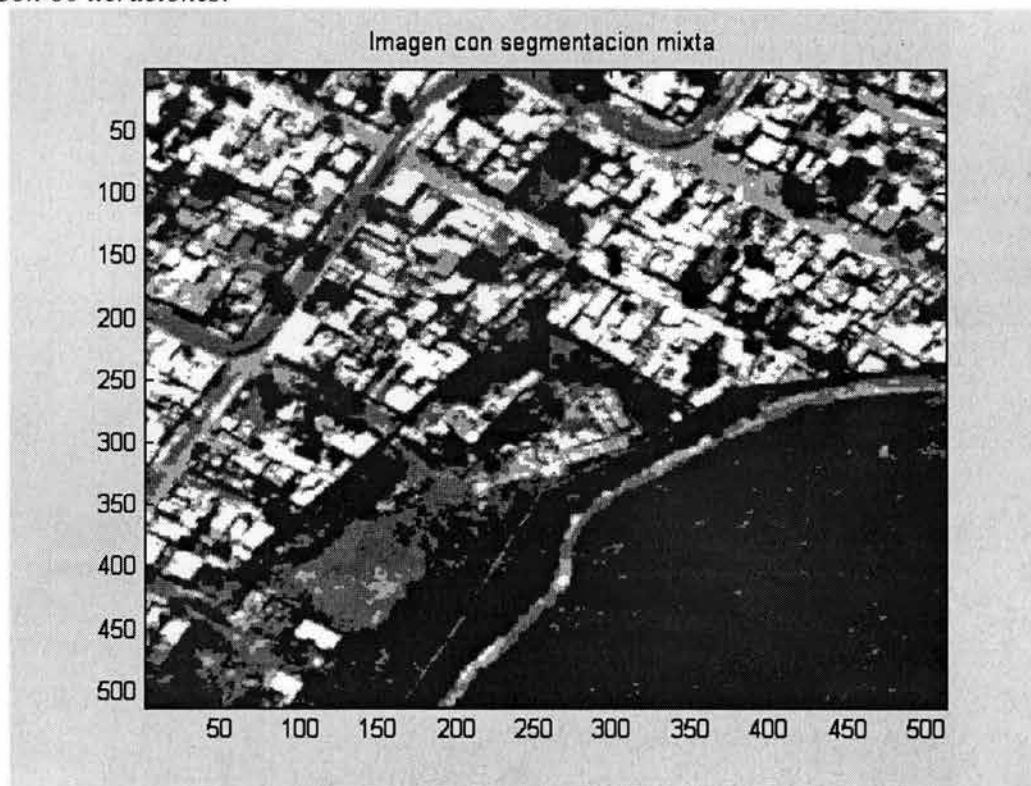


Figura 7 - 29 (80 Iteraciones)



Con 100 iteraciones:




Figura 7 - 30 (100 Iteraciones)

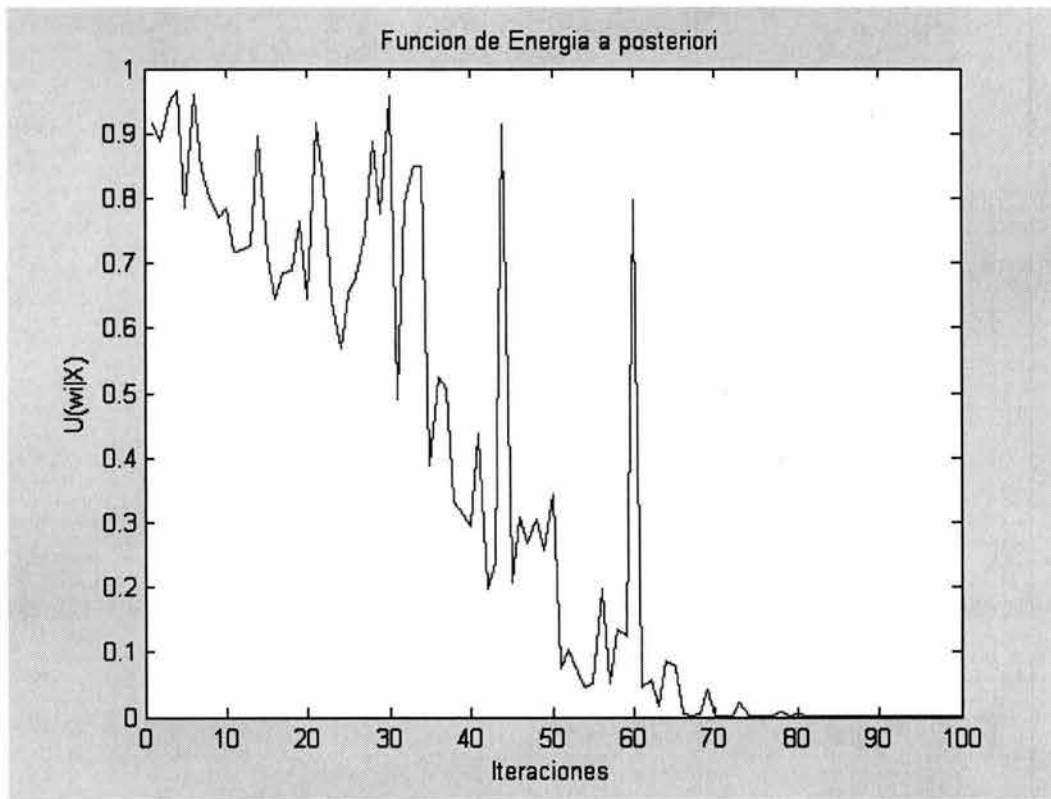


Figura 7 - 31 (Función de energía a posteriori)




Figura 7 - 32 (Comparación final)



7.1.2.3. Imagen DF3_512.RAW

En esta última imagen fue donde pudimos observar claramente el análisis markoviano, pues además de tener más píxeles de rechazo para barrer, se tuvieron agrupaciones de píxeles que se concentraban en un mismo lugar, y aquí es donde pudimos observar como algunos límites o contornos que anteriormente con el análisis bayesiano se tenían bien definidos, en esta parte del análisis se perdían y las zonas se veían más homogéneas, observando de esta forma una de las desventajas del análisis markoviano, que es la pérdida de bordes, como se puede ver en la zona de la esquina superior izquierda de cada una de las figuras con imágenes con segmentación mixta.

Al igual que con las dos imágenes anteriores, se muestran 5 figuras de resultados previos a la segmentación mixta con 10 iteraciones, en los que se observan las funciones de energía, la imagen clasificada con Markov y píxeles clasificados con Análisis Bayesiano en color negro, el histograma correspondiente a la figura anterior y finalmente la imagen con segmentación mixta y su correspondiente histograma en el que podemos apreciar la segmentación en 5 clases.

Por último, se muestran 6 figuras más, cada una de ellas muestra los resultados obtenidos a través 20, 30, 40, 60, 80 y 100 iteraciones. Teniendo resultados notorios a partir de la iteración 60, teniendo un resultado casi óptimo en la iteración 80 y el óptimo en la iteración número 100. Lo anterior se comprueba mediante la grafica de la Figura 7 - 44 en la cual observamos que la energía decrece con cada iteración, convergiendo hacia el nivel de segmentación óptimo.




Figura 7 - 33 (Funciones de energía para DF3_512.RAW)

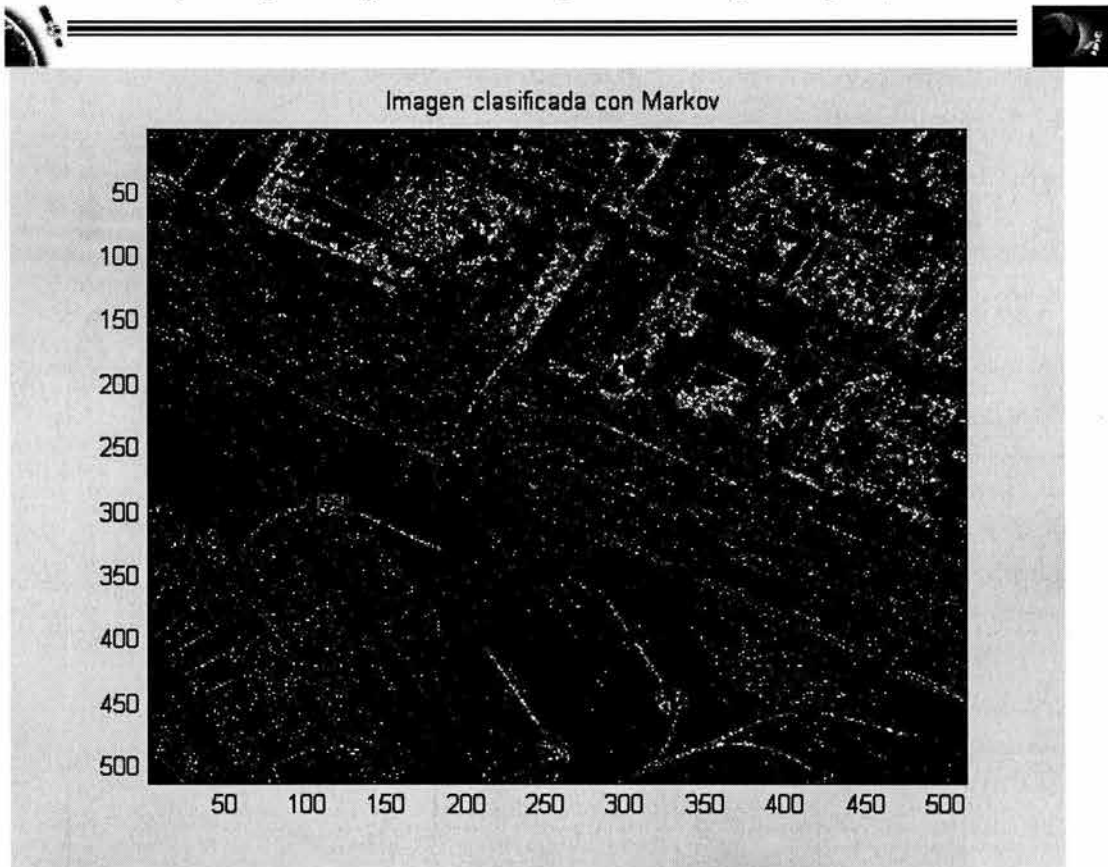


Figura 7 - 34 (Píxeles de rechazo clasificados con Markov)




Figura 7 - 35 (Histograma de la imagen anterior)




Figura 7 - 36 (Imagen con segmentación mixta)




Figura 7 - 37 (Histograma de la imagen anterior)



Con 20 iteraciones:




Figura 7 - 38 (20 Iteraciones)

Con 30 iteraciones:




Figura 7 - 39 (30 Iteraciones)



Con 40 iteraciones:




Figura 7 - 40 (40 Iteraciones)

Con 60 iteraciones:

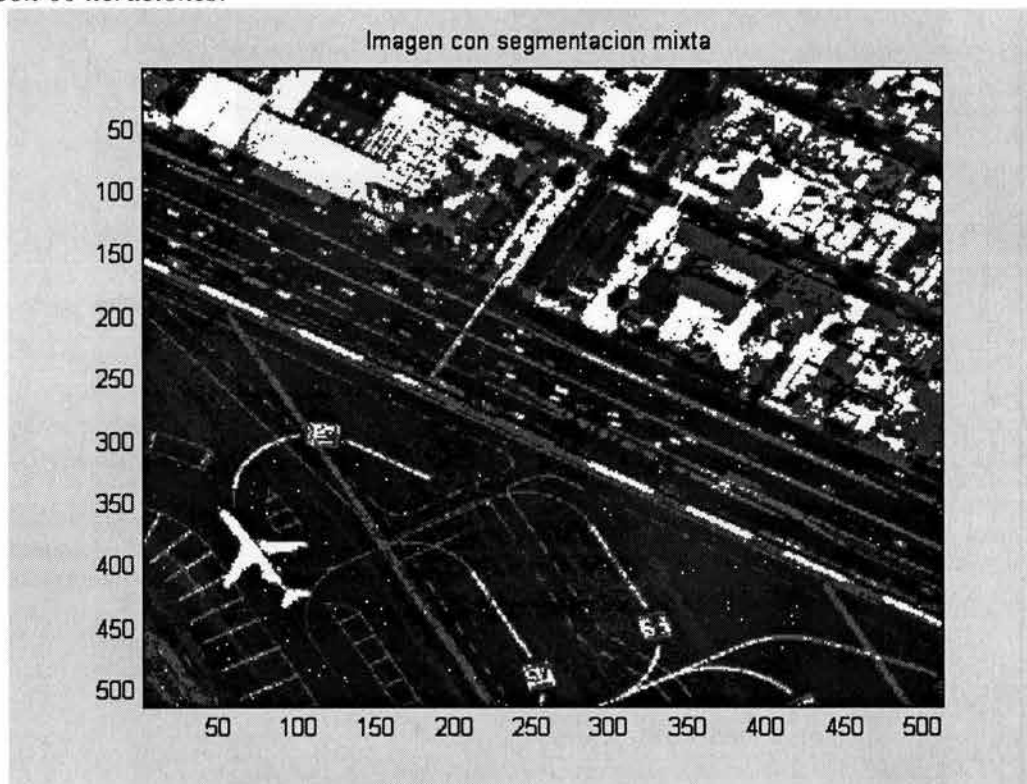


Figura 7 - 41 (60 Iteraciones)



Con 80 iteraciones:




Figura 7 - 42 (80 Iteraciones)

Con 100 iteraciones:




Figura 7 - 43 (100 Iteraciones)

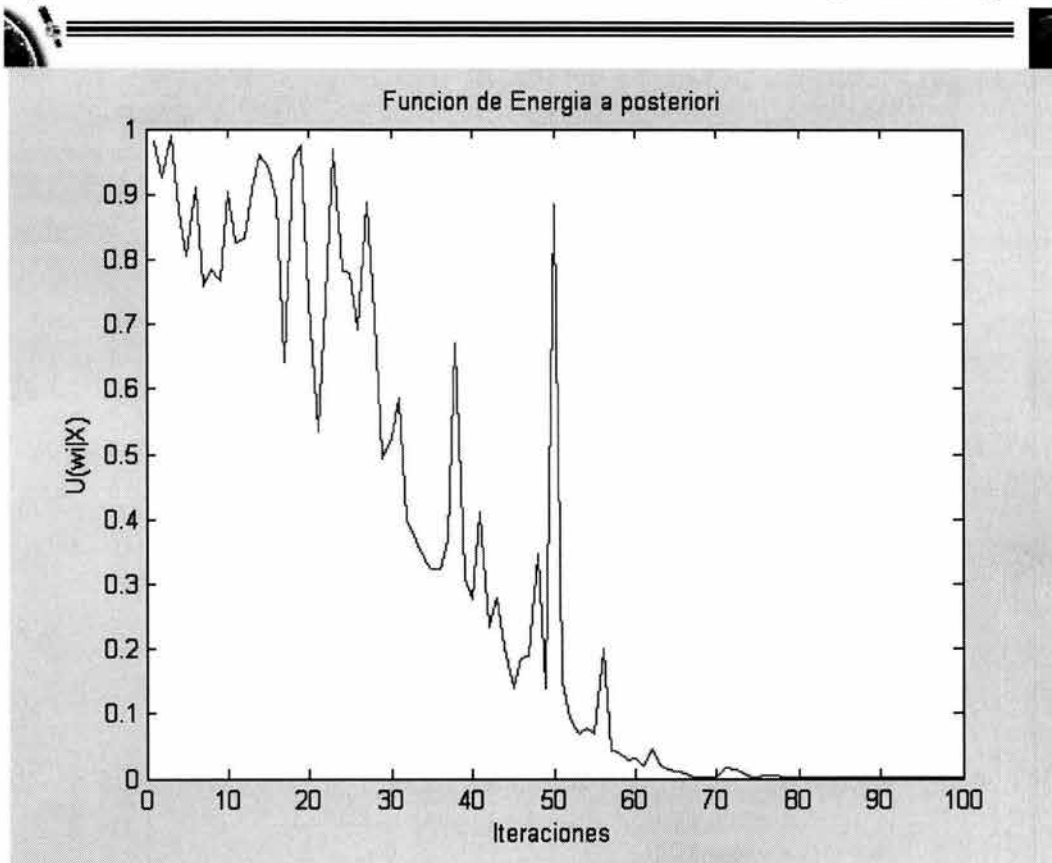


Figura 7 - 44 (Función de energía a posteriori)

De las tres imágenes que hemos analizado, esta última resulta ser particularmente interesante porque en ella podemos observar fácilmente los resultados que el Análisis Markoviano nos ofrece, pues muchos detalles que con el Análisis Bayesiano no eran posibles apreciar si se pueden ver en la figura final de esta imagen.

Algunos de estos detalles, al igual que en las dos imágenes anteriores, fueron remarcados con circunferencias en color verde, y los detalles que en la imagen original existían y que con el Análisis Markoviano se perdieron se marcaron con color rojo.

En la figura siguiente observamos que a pesar de que se tienen pérdidas de información en la imagen, estas se compensan con las mejoras que se obtienen, y esto es más apreciable cuando se tiene un número mayor de píxeles de rechazo, pues lo que se observó fue que muchos de los errores que se tenían en la clasificación, se arrastraban desde la clasificación con Análisis Bayesiano. Esto no quiere decir que el Análisis Bayesiano no sea un método bueno en estos casos, sino que al igual que el Análisis Markoviano, se tienen mejoras a cambio de algunas pérdidas.

En mi punto de vista, considero que la segmentación mixta llevada a cabo usando un esquema basado en estos análisis (Bayes-Markov) es un método que optimiza primeramente el tiempo de procesamiento, y finalmente nos ofrece detalles finos con el Análisis Bayesiano y homogeneidad en las zonas de concentración de píxeles de rechazo al aplicar un Análisis Markoviano, convirtiendo a este proceso en un método óptimo para la segmentación de imágenes de percepción remota (Fotografía Aérea en este caso).




Figura 7 - 45 (Comparación final)



8. CONCLUSIONES

El problema principal en la segmentación de imágenes, y de una forma más general en la clasificación, es la extracción de información relevante para que esta pueda ser interpretada a detalle. En la primera parte de esta tesis se investigaron las bases para la comprensión de la percepción remota, posteriormente se realizó la búsqueda de información relevante sobre técnicas de segmentación y en base a ello se definió un esquema de segmentación mixta. Lo que se pretendía con este esquema era realizar una mejora en la clasificación basada en un Análisis Bayesiano, añadiendo una etapa de post-clasificación con un Análisis Markoviano.

Dentro de las principales ventajas en el uso de un Análisis Bayesiano se tiene que con un análisis muy simple, usando conceptos básicos de probabilidad y estadística, se puede llegar a obtener una clasificación rápida de los píxeles con un nivel de efectividad alto. Sin embargo, se tiene la desventaja de poseer (como todo método basado en la probabilidad y estadística) la probabilidad del error, esto es que existen ciertos píxeles con probabilidades muy bajas de pertenecer a la clase que se les ha asignado; por lo que no se tiene una certeza aceptable de ser clasificados correctamente en alguna de las clases. Es por esto que tiene lugar una etapa de post-procesamiento, en la que los píxeles que bajo cierto umbral de rechazo no tienen la seguridad de ser clasificados de forma correcta son enviados a este módulo.

La etapa de post-procesamiento se llevó a cabo usando un Análisis Markoviano basado en el Algoritmo de Recocido Simulado. En la práctica, el Algoritmo de Recocido Simulado, emplea un algoritmo de Metrópolis, con un esquema de temperatura variable, a fin de minimizar la función de energía a posteriori. Para minimizar la función de energía a posteriori es necesario decrementar la temperatura para cada configuración, ya que para temperaturas altas, las configuraciones más aleatorias están presentes. Cabe resaltar que debido a que en esta etapa sólo se procesaron los píxeles de rechazo, los tiempos de procesamiento disminuyeron notablemente en comparación con otros trabajos realizados en los que se barrió la imagen completa usando un algoritmo similar [55].

Fueron 3 las imágenes que se usaron, todas provenientes de la fotografía aérea de alta resolución, del orden de 20 x 20 cm. el tamaño del píxel. Cada imagen era de 512 x 512 píxeles (262,144 píxeles en total en la imagen), definida en 256 niveles de gris y pertenecían a diferentes escenas del Distrito Federal. Las dos primeras corresponden a regiones semiurbanas del sur de la Ciudad de México, y la última al oriente (Aeropuerto) de la misma.

Para la primera imagen (DFI_PR1.RAW), se consideró un umbral de rechazo, tal que si $P(\omega_i | X) \leq 0.09$, los píxeles se agrupaban en la clase de rechazo, en este caso el número de píxeles de rechazo fue de 12,783 píxeles, lo que nos indica que el porcentaje de píxeles de la imagen de los que no se tiene la certeza de que sean clasificados correctamente es 4.9%, siendo este el porcentaje correspondiente a la probabilidad de error. Por tanto la efectividad del método basado en el Análisis Bayesiano es del 95.1%, pues fue el porcentaje de acuerdo al número de píxeles que se pudieron clasificar con una probabilidad mayor al umbral de rechazo.



En el caso de la segunda imagen (DF11ZQ.RAW), el umbral de rechazo fue el mismo que en la imagen anterior, y los píxeles agrupados en la clase de rechazo fueron 15,173 píxeles. Como podemos observar este número de píxeles es mayor que en la imagen anterior, y por lo tanto el porcentaje correspondiente a la probabilidad de error es mayor también, siendo de 5.8%. En consecuencia, la efectividad del método basado en el Análisis Bayesiano es en este caso de 94.2%.

Finalmente tenemos el caso de la última imagen (DF3_512.RAW), en la que el umbral de rechazo fue tal que si $P(\omega_i | X) \leq 0.12$, los píxeles se agrupaban en la clase de rechazo, y en este caso el número de píxeles de rechazo fue de 26,333 píxeles, lo que nos indica que el porcentaje de píxeles de la imagen correspondiente a la probabilidad de error es 10%. Por tanto la efectividad del método basado en el Análisis Bayesiano es del 90%.

Se debe de tener en cuenta que para determinar el umbral de rechazo se tomó una probabilidad menor a la probabilidad de clase más pequeña, para de esta forma poder tener las 5 clases que se querían con distribución homogénea; pues si se tomaba un umbral de rechazo con probabilidad mayor, los píxeles que poseían probabilidades de clase menores a las del umbral eran tomados como pertenecientes a la clase de rechazo y por consiguiente no se obtenían las 5 clases deseadas.

En cuanto al Análisis Markoviano, resultaba más difícil la determinación de los píxeles que se clasificaban correctamente para obtener la probabilidad de error; sin embargo, si se pudo obtener una gráfica, para cada imagen (Figura 7 – 18, Figura 7 – 31 y Figura 7 – 44), en la que se comprobaba como decrecía la energía a posteriori con cada iteración, convergiendo hacia el nivel de segmentación óptimo.

En las imágenes finales de 10, 20, 30, y 40 iteraciones observamos que estas no difieren mucho entre sí, se observan cambios muy ligeros en los niveles de gris de la imagen, pero los agrupamientos nos se hacen tan notorios sino hasta la iteración número 60, en donde ya se observan menos puntos blancos y más zonas homogéneas. Sin embargo, es hasta la iteración número 80 en la que se observan puntos aislados contados y las zonas casi homogéneas, y en la iteración número 100 se observan las zonas homogéneas perfectamente bien definidas.

En la última imagen (Imagen del Aeropuerto) fue donde pudimos observar claramente el trabajo del Análisis Markoviano, pues además de tener más píxeles de rechazo para barrer, se tuvieron agrupaciones de píxeles que se concentraban en un mismo lugar, y aquí es donde pudimos observar como algunos límites o contornos, que anteriormente con el Análisis Bayesiano se tenían bien definidos, se perdían y las zonas se veían más homogéneas, observando de esta forma una de las desventajas de este análisis, que es la pérdida de bordes.

A pesar de que se tienen pérdidas de información en la imagen post-procesada, estas se compensan con las mejoras que se obtienen, y esto es más apreciable cuando se tiene un número mayor de píxeles de rechazo; pues lo que se observó fue que muchos de los errores que se tenían en la clasificación, se arrastraban desde la clasificación con Análisis Bayesiano. Esto no quiere decir que el Análisis Bayesiano no sea un



método bueno en estos casos, sino que al igual que el Análisis Markoviano, se tienen mejoras a cambio de algunas pérdidas.

En mi punto de vista, considero que la segmentación mixta llevada a cabo usando un esquema basado en estos análisis (Bayes-Markov) es un método que reduce drásticamente el tiempo de procesamiento, y que nos ofrece detalles finos con el Análisis Bayesiano y homogeneidad en las zonas de concentración de píxeles de rechazo al aplicar un Análisis Markoviano, convirtiendo a éste proceso en un método óptimo para la segmentación de imágenes de percepción remota y en nuestro caso particular de imágenes de fotografía aérea de alta resolución.



9. BIBLIOGRAFÍA Y REFERENCIAS ELECTRÓNICAS

- [1] BOW Sing-Tze, *Pattern Recognition and Image Preprocessing*, Marcel Dekker, Inc., E.U.A., 1992.
- [2] CHUVIECO Emilio, *Fundamentos de Teledetección Espacial*, Ediciones RIALP, S.A., España, 1990.
- [3] HARNETT Donald & MURPHY James, *Introducción al análisis estadístico*, Addison-Wesley Iberoamericana, México, 1987.
- [4] MOCTEZUMA Flores Miguel, *Apuntes de Análisis de Señales Aleatorias*, FI – UNAM, 2001
- [5] PUJOL M. & ET AL, *Aplicación de los modelos de campos aleatorios de Markov en visión artificial*, Revista Electrónica de Visión por Computador (Octubre 2000), No. 4, 1 - 23.
- [6] SCHOWENGERDT Robert, *Remote Sensing. Models and Methods for Image Processing (Segunda Edición)*, Academic Press, E.U.A., 1997.
- [7] ZHANG D.B., VAN GOOL L. & OOSTERLINCK A., *Coastline Detection from SAR Images*, Katholieke Universiteit Leuven (1994), 5 - 8.
- [8] <http://www.teledet.com.uy/quees.htm>
- [9] <http://www.oas.org/usde/publications/Unit/oea65s/ch09.htm>
- [10] <http://www.ciat.cgiar.org/dtmradar/teledeteccion-concepto.htm>
- [11] http://www.esa.int/export/esaCP/GGGHQDNZ0GC_Spain_0.html
- [12] <http://www.conida.gob.pe/labrad/SOLTIERRA/diaconex.htm>
- [13] <http://oceanografia.cicese.mx/oceansat/preoceansat2000.html>
- [14] <http://nmp.jpl.nasa.gov/news/news.html>
- [15] <http://www.gsfc.nasa.gov/topstory/20020624eo1.html>
- [16] <http://nmp.jpl.nasa.gov/espanol.html>
- [17] http://nmp.jpl.nasa.gov/ds1/spanish/Deep_Space_1.html
- [18] <http://www.ea1uro.com/envisat.html>
- [19] http://www.esa.int/competition/esp/what_is_envisat.html
- [20] <http://www.esa.int/envisat/>



- [21] <http://www.ltid.inpe.br/selper/image/espanhol/landsat2.html>
- [22] <http://geo.arc.nasa.gov/sge/landsat/landsat.html>
- [23] <http://www.earth.nasa.gov/history/landsat/landsat.html>
- [24] <http://ls7pm3.gsfc.nasa.gov/mainpage.html>
- [25] <http://www.earth.nasa.gov/history/landsat/landsat1.html>
- [26] <http://www.earth.nasa.gov/history/landsat/landsat2.html>
- [27] <http://www.earth.nasa.gov/history/landsat/landsat3.html>
- [28] <http://www.earth.nasa.gov/history/landsat/landsat4.html>
- [29] <http://www.earth.nasa.gov/history/landsat/landsat5.html>
- [30] <http://www.earth.nasa.gov/history/landsat/landsat6.html>
- [31] <http://www.friends-partners.ru/partners/mwade/craft/landsat6.htm>
- [32] http://www.landsat.org/Earth_from_space/Effects_of_war.htm
- [33] <http://landsat7.usgs.gov/gallery/>
- [34] <http://snig.igeo.pt/Portugues/RedesTematicas/Rot/rot2/spot.html>
- [35] http://www.efn.uncor.edu/otros/foto/teoria_fotoin.htm
- [36] <http://www.spot.com/home/system/introsat/seltec/welcome.htm>
- [37] http://www.cnes.fr/activites/programmes/spot/lsommaire_spot.htm
- [38] <http://smc.cnes.fr/SPOT/Fr/>
- [39] <http://spot5.cnes.fr/index2.htm>
- [40] http://www.spotimage.com.cn/spot5/ensavoirplus/eng/plus_satel.html
- [41] http://spot4.cnes.fr/spot4_gb/index.htm
- [42] <http://spot5.cnes.fr/actualites/54.htm>
- [43] <http://www.sisea.co.th/kionos/overview.html#>
- [44] <http://www.sisea.co.th/kionos/characteristics.html>



- [45] <http://www.spaceimaging.com/gallery/ioweek/archive/99-10-18/index.htm>
- [46] <http://www.spaceimaging.com/gallery/ioweek/archive/99-12-13/index.htm>
- [47] <http://www.spaceimaging.com/gallery/ioweek/archive/99-11-08/index.htm>
- [48] <http://www.si-eu.com/faqs.asp>
- [49] http://www.csc.noaa.gov/crs/rs_apps/sensors/ikonos.htm
- [50] http://www.skyrocket.de/space/index_frame.htm?http://www.skyrocket.de/space/doc_sdat/ikonos.htm
- [51] <http://www.geotecnologias.com/space/>
- [52] <http://www.geosystems.cc/space.htm>
- [53] http://www.com.uvigo.es/asignaturas/scvs/trabajos/curso0001/biblio/LA_NDSAT/LANDSAT.pdf
- [54] http://www-etsi2.ugr.es/depar/ccia/rf/www/tema1_00-01_www/node5.html
- [55] **LÓPEZ LÓPEZ LUDWIN VENTURA, *Esquema markoviano para la detección remota de derrames petroleros*, UNAM – FI, México, 2004.**



APÉNDICES

APÉNDICE A

IMAGENES DE SATELITE APLICADAS A EVALUACIONES DE PELIGROS NATURALES

	TERREMOTOS	ERUPCIONES VOLCANICAS	DESGLIZAMIENTOS DE TIERRAS	TSUNAMIS	DESERTIFICACION	INUNDACIONES	HURACANES
INFORMACION A SER OBTENIDA	Mapas de uso de tierras, mapas geológicos	Mapas de áreas vulnerables a flujos de lava, caída de ceniza, derrubios e incendios	Mapas de pendientes, estabilidad de pendientes, elevación geológica, tipos de suelo, áreas de embalse de agua, mapas para uso de tierras	Mapas barométricos/topográficos	Mapas para uso de tierras, contenido de humedad en el suelo, condición de la cosecha y de la vegetación natural	Mapas de demarcación de las llanuras de inundación, clasificación de uso de tierras, datos históricos, cobertura del suelo y humedad del suelo	Mapas para uso de tierras
BANDA ESPECTRAL	Visible e IR cercano	Visible, IR cercano e IR térmico	Visible	Visible, incluyendo el azul e IR cercanos	Visible, IR cercano y microondas	IR cercano, IR térmico y microondas	Visible a IR cercano
RESOLUCION ESPACIAL	20-80m	30-80m	10-30m	30m	80m-1km	20m (para rasgos culturales), 30-80m (para uso de tierra); 1 Km. (para cobertura de nieve y humedad del suelo)	20m (para rasgos culturales); 30-80m (para uso de tierra)
AREA DE COBERTURA	Área grande	Área larga	Área larga	Área costera grande	Área regional grande	Área regional grande	Área grande
CAPACIDAD EN TODO CLIMA	No	No	No	No	No	No	No
VISION SINOPTICA	Si	Si	Si	Si	Si	Si	Si
CAPACIDAD ESTEREO	Si	Si	Si	Si	Si	No	
FRECUENCIA DE OBSERVACION PARA USO EN EL ESTUDIO DE PLANIFICACION	1 a 5 años	1 a 5 años	1 a 5 años	Mensualmente	Estacional (excepto para cobertura de nieve y humedad del suelo)	Annual	

Fuente: Adaptado de Richards, P.B. *The Utility of LANDSAT-D and other Satellite Imaging Systems in Disaster Management* (Washington, DC: Naval Research Laboratory, 1986).

Tabla A - 1 (Evaluación de Peligros Naturales) [8]



APÉNDICE B

<i>Instrumento</i>	<i>Propósito General</i>
<i>Global ozone monitoring by occultation of stars (GOMOS)</i>	<i>Observar la concentración de ozono en la estratosfera.</i>
<i>Scanning Imaging Absorption Spectrometer for Atmospheric Cartography (SCIAMACHY)</i>	<i>Medir la concentración de aerosoles y gases en la atmósfera.</i>
<i>Michelson interferometer for passive atmospheric sounding (MIPAS)</i>	<i>Recolectar información acerca de los procesos químicos y físicos en la estratosfera, así como aquellos que afectarán la concentración de ozono en un futuro.</i>
<i>Medium resolution imaging Spectrometer (MERIS)</i>	<i>Medir la radiación en 15 bandas de frecuencia para dar información acerca de la biología del océano, calidad del agua marina, vegetación en la tierra, nubes y vapor de agua.</i>
<i>Advanced synthetic aperture Radar (ASAR)</i>	<i>Capturar imágenes vía radar en todos los climas, de día y de noche.</i>
<i>Advanced along track scanning radiometer (AATSR)</i>	<i>Medir la temperatura de la superficie del mar, que es un parámetro clave en la determinación de la existencia y/o extensión del calentamiento global.</i>
<i>Radar Altimeter (RA-2)</i>	<i>Medir la distancia del satélite a la Tierra. De esta forma se puede medir la altura de la superficie del mar, que es una medida importante en el monitoreo de fenómenos como el Niño, por ejemplo.</i>
<i>Microwave radiometer (MWR)</i>	<i>Permite hacer correcciones en los datos del altímetro del radar.</i>
<i>Doppler Orbitography and Radio positioning integrated by satellite (DORIS)</i>	<i>Da la posición del satélite en su órbita, esto es muy importante para entender las medidas de los demás instrumentos.</i>
<i>Laser retro-reflector (LRR)</i>	<i>Refleja pulsos de un láser a las estaciones terrestres para ayudar a determinar la posición exacta del satélite en su órbita.</i>

Tabla B - 1 (Instrumentos y sistemas que componen al ENVISAT) [19]



Fecha y Lugar de Lanzamiento	<i>1 Marzo 2002 (CET), Guayana Francesa (Kourou)</i>
Lanzador	<i>Ariane 5</i>
Masa	<i>8200 kg</i>
Masa de Carga (instrumentos)	<i>2050 kg</i>
Duración prevista de la misión	<i>5 años</i>
Número de instrumentos	<i>10</i>
Órbita	<i>Sincrónica solar, altitud 800 km</i>
Inclinación	<i>98 grados</i>
Tiempo de órbita	<i>101 minutos</i>
Ciclo	<i>Cada 35 días, aunque muchos de los instrumentos del ENVISAT observan grandes zonas de la Tierra, por lo que puede observarse el planeta entero en pocos días.</i>
Costo	<i>Cerca de 2 mil millones de Euros</i>
Países participantes	<i>Austria, Bélgica, Canadá, Dinamarca, Francia, Finlandia, Alemania, Italia, Noruega, España, Suecia, Suiza, Países Bajos y Reino Unido</i>

Tabla B - 2 (Especificaciones Técnicas del ENVISAT) [19]



<i>Características</i>	<i>SPOT 1</i>	<i>SPOT 2</i>	<i>SPOT 3</i>	<i>SPOT 4</i>	<i>SPOT 5</i>
<i>Entidad Responsable</i>	<i>CNES (Centre National d'Études Spatiales)</i>				
<i>Lanzamiento</i>	<i>22/Febrero/1986</i>	<i>22/Enero/1990</i>	<i>26/Septiembre/1993</i>	<i>24/Marzo/1998</i>	<i>4/Mayo/2002</i>
<i>Vehículo de Lanzamiento</i>	<i>Ariane 2/3</i>	<i>Ariane 2/3</i>	<i>Ariane 2/3</i>	<i>Ariane 4</i>	<i>Ariane 4</i>
<i>Fin de operación</i>			<i>14/Noviembre/1996</i>		
<i>Tiempo de Vida</i>	<i>3 años</i>	<i>3 años</i>	<i>3 años</i>	<i>5 años</i>	<i>5 años</i>
<i>Estado actual</i>	<i>Activo</i>	<i>Activo</i>	<i>Inactivo</i>	<i>Activo</i>	<i>Activo</i>
<i>Tipo de Órbita</i>	<i>Circular, casi polar, sincronizada con el Sol</i>	<i>Circular, casi polar, sincronizada con el Sol</i>	<i>Circular, casi polar, sincronizada con el Sol</i>	<i>Circular, casi polar, sincronizada con el Sol</i>	<i>Circular, casi polar, sincronizada con el Sol</i>
<i>Altitud media</i>	<i>822 Km.</i>	<i>822 Km.</i>	<i>822 Km.</i>	<i>822 Km.</i>	<i>822 Km.</i>
<i>Inclinación</i>	<i>98.7°</i>	<i>98.7°</i>	<i>98.7°</i>	<i>98.7°</i>	<i>98.7°</i>
<i>Período</i>	<i>101.4 min.</i>	<i>101.4 min.</i>	<i>101.4 min.</i>	<i>101.4 min.</i>	<i>101.4 min.</i>
<i>Ciclo Orbital</i>	<i>26 días</i>	<i>26 días</i>	<i>26 días</i>	<i>26 días</i>	<i>26 días</i>
<i>Peso</i>	<i>1830 Kg.</i>	<i>1870 Kg.</i>	<i>1907 Kg.</i>	<i>2760 Kg.</i>	<i>3000 Kg.</i>
<i>Hora Local no Nudo Descendente</i>	<i>10:30 a.m.</i>	<i>10:30 a.m.</i>	<i>10:30 a.m.</i>	<i>10:30 a.m.</i>	<i>10:30 a.m.</i>
<i>Aplicaciones</i>	<i>Varias</i>	<i>Varias</i>	<i>Varias</i>	<i>Varias, principalmente enfocado a aplicaciones agrícolas</i>	<i>Varias</i>
<i>Sensores</i>	<i>2 sensores HRV</i>	<i>2 sensores HRV</i>	<i>POAM-II y 2 sensores HRV</i>	<i>VGT y 2 sensores HRVIR</i>	<i>VGT, HRG y HRS</i>

Tabla B - 3 (Características técnicas del programa SPOT) [34]



	SPOT 1, 2 y 3
Instrumentos	2 HRV's
Bandas espectrales y resolución	1 pancromática (10 m) 3 multiespectral (20 m)
Rango espectral	P: 0.50 - 0.73 μm B1: 0.50 - 0.59 μm B2: 0.61 - 0.68 μm B3: 0.78 - 0.89 μm
Resolución de la imagen	60 Km. x 60 Km. a 80 Km.
Dinámica de la imagen	8 bits
Exactitud absoluta de ubicación (sin puntos de control en la Tierra, terreno plano)	< 350 m (rms)
Exactitud Interna relativa a la distancia (nivel 1B)	0.5×10^{-3} (rms)
Programable	Si
Ángulo de incidencia	$\pm 31.06^\circ$
Intervalo de chequeo (dependiendo de la latitud)	1 a 4 días

Tabla B - 4 (Instrumentos sensores de alta resolución de los satélites SPOT 1,2 y 3) [40]

	SPOT 1, 2 and 3
Instrumento	HRV capacidad de vista estereoscópica a través de la línea de visión.
Bandas espectrales y resolución	. 1 pancromática (10 m) . 3 multiespectral (20 m)
Rango espectral	P: 0.50 - 0.73 μm B1: 0.50 - 0.59 μm B2: 0.61 - 0.68 μm B3: 0.78 - 0.89 μm
Resolución de la imagen	60 Km. x 60 Km. a 80 Km.
Dinámica de la imagen	8 bits
Cociente Base/altura (B/H)	0.5 a 1.1
Exactitud absoluta de ubicación (sin puntos de control en la Tierra, terreno plano)	< 350 m (rms)
Tiempo entre dos imágenes	Variable

Tabla B - 5 (Instrumentos estereoscópicos de los satélites SPOT 1,2 y 3) [40]



	SPOT 4
Instrumentos	2 HRVIR's
Bandas espectrales y resolución	1 pancromática (10 m) 3 multiespectral (20 m) 1 onda-corta infrarroja (20 m)
Rango espectral	M: 0.61 - 0.68 μm B1: 0.50 - 0.59 μm B2: 0.61 - 0.68 μm B3: 0.78 - 0.89 μm B4: 1.58 - 1.75 μm
Resolución de la imagen	60 Km. x 60 Km. a 80 Km.
Dinámica de la imagen	8 bits
Exactitud absoluta de ubicación (sin puntos de control en la Tierra, terreno plano)	< 350 m (rms)
Exactitud Interna relativa a la distancia (nivel 1B)	0.5×10^{-3} (rms)
Programable	Sí
Ángulo de incidencia	$\pm 31.06^\circ$
Intervalo de chequeo (dependiendo de la latitud)	1 a 4 días

Tabla B - 6 (Instrumentos sensores de alta resolución del satélite SPOT 4) [40]

	SPOT 4
Instrumento	HRVIR capacidad de vista estereoscópica a través de la línea de visión.
Bandas espectrales y resolución	1 pancromática (10 m) 3 multiespectral (20 m) 1 onda-corta infrarroja (20 m)
Rango espectral	M: 0.61 - 0.68 μm B1: 0.50 - 0.59 μm B2: 0.61 - 0.68 μm B3: 0.78 - 0.89 μm B4: 1.58 - 1.75 μm
Resolución de la imagen	60 Km. x 60 Km. a 80 Km.
Dinámica de la imagen	8 bits
Cociente Base/altura (B/H)	0.5 a 1.1
Exactitud absoluta de ubicación (sin puntos de control en la Tierra, terreno plano)	< 350 m (rms)
Tiempo entre dos imágenes	Variable

Tabla B - 7 (Instrumentos estereoscópicos del satélite SPOT 4) [40]



	SPOT 4
<i>Instrumento a bordo</i>	<i>VEGETATION 1</i>
<i>Bandas Espectrales</i>	4
<i>Espectro electromagnético</i>	B0: 0.45 - 0.52 μm B2: 0.61 - 0.68 μm B3: 0.78 - 0.89 μm B4: 1.58 - 1.75 μm
<i>Resolución</i>	1,000 m
<i>Resolución de la Imagen</i>	2,250 Km.
<i>Dinámica de la imagen</i>	10 bits
<i>Exactitud absoluta de ubicación (sin puntos de control en la Tierra, terreno plano)</i>	< 350 m (rms)
<i>Intervalo de chequeo</i>	1 día

Tabla B - 8 (Instrumento colector de imágenes VEGETATION del satélite SPOT 4) [40]

	SPOT 5
<i>Instrumentos</i>	2 HRG's
<i>Bandas espectrales y resolución</i>	2 pancromáticas (5 m), combinadas para generar un producto de 2.5 metros 3 multiespectral (10 m) 1 onda-corta infrarroja (20 m)
<i>Rango espectral</i>	P: 0.48 - 0.71 μm B1: 0.50 - 0.59 μm B2: 0.61 - 0.68 μm B3: 0.78 - 0.89 μm B4: 1.58 - 1.75 μm
<i>Resolución de la imagen</i>	60 Km. x 60 Km. a 80 Km.
<i>Dinámica de la imagen</i>	8 bits
<i>Exactitud absoluta de ubicación (sin puntos de control en la Tierra, terreno plano)</i>	< 50 m (rms)
<i>Exactitud Interna relativa a la distancia (nivel 1B)</i>	0.5×10^{-3} (rms)
<i>Programable</i>	Si
<i>Ángulo de incidencia</i>	$\pm 31.06^\circ$
<i>Intervalo de chequeo (dependiendo de la latitud)</i>	1 a 4 días

Tabla B - 9 (Instrumentos sensores de alta resolución del satélite SPOT 5) [40]



SPOT 5		
Instrumento	<i>HRS capacidad de vista estereoscópica a todo lo largo de la línea de visión.</i>	<i>HRG capacidad de vista estereoscópica a través de la línea de visión.</i>
Bandas espectrales y resolución	<i>1 pancromática (10 m) (vuelta a muestrear cada 5 m a lo largo de la pista) => 10 m a lo largo de la pista, 5 m a través de la pista</i>	<i>2 pancromáticas (5 m), combinadas para generar un producto de 2.5-metros 3 multiespectrales (10 m) 1 onda-corta infrarroja (20 m)</i>
Rango espectral	<i>P: 0.49 - 0.69 μm</i>	<i>P: 0.48 - 0.71 μm B1: 0.50 - 0.59 μm B2: 0.61 - 0.68 μm B3: 0.78 - 0.89 μm B4: 1.58 - 1.75 μm</i>
Resolución de la imagen	<i>600 Km. x 120 Km.</i>	<i>60 Km. x 60 Km. a 80 Km.</i>
Dinámica de la imagen	<i>8 bits</i>	<i>8 bits</i>
Cociente Base/altura (B/H)	<i>~ 0.84 ($\pm 20^\circ$)</i>	<i>0.5 to 1.1</i>
Exactitud absoluta de ubicación (sin puntos de control en la Tierra, terreno plano)	<i>< 15 m (rms)</i>	<i>< 50 m (rms)</i>
Tiempo entre dos imágenes	<i>90 segundos (simultáneos)</i>	<i>Variable</i>

Tabla B - 10(Instrumentos estereoscópicos del satélite SPOT 5) [40]

SPOT 4	
Instrumento a bordo	<i>VEGETATION 2</i>
Bandas Espectrales	<i>4</i>
Espectro electromagnético	<i>B0: 0.45 - 0.52 μm B2: 0.61 - 0.68 μm B3: 0.78 - 0.89 μm B4: 1.58 - 1.75 μm</i>
Resolución	<i>1,000 m</i>
Resolución de la Imagen	<i>2,250 Km.</i>
Dinámica de la imagen	<i>10 bits</i>
Exactitud absoluta de ubicación (sin puntos de control en la Tierra, terreno plano)	<i>< 50 m (rms)</i>
Intervalo de chequeo	<i>1 día</i>

Tabla B - 11(Instrumento colector de imágenes VEGETATION del satélite SPOT 5) [40]



Altitud	423 millas o 681 Km.
Inclinación	98.1 grados
Velocidad	4 millas/seg. (17,500 millas/hr.) o 7 Km. /seg. (26,000 km. /hr.)
Tiempo de Cruce en Nodo Descendente	10:30 a.m.
Tiempo Orbital	98 minutos
Tipo de Órbita	Casi polar, en sincronía con el sol

Tabla B - 12(Características de la órbita del satélite IKONOS) [44]

Sensor	Multiespectral Pancromático	
Resolución	Resolución terrestre para cada banda:	
	-	1 metro pancromático (nominal a < 26 grados del nadir)
	-	4 metros multispectrales (nominal a < 26 degrees del nadir)
	-	El software de procesamiento en la Tierra tiene la capacidad de acelerar el proceso y obtener mosaicos de imágenes, para de esta forma crear imágenes muy similares, a distancias de muestreo constantes y consistentes.
Respuesta Espectral de la Imagen	Pancromática: 0.45 – 0.90 microns Multiespectral: (igual que en LANDSAT 4 y 5 TM Bandas 1 a 4)	
	#1	Azul 0.45 – 0.52 microns
	#2	Verde 0.52 – 0.60 microns
	#3	Rojo 0.63 – 0.69 microns
	#4	Infrarrojo Cercano 0.76 – 0.90 microns
Ancho de la resolución	11 km.	
Frecuencia de chequeo	2.9 días a 1 metro de resolución 1.5 días a 1.5 metros de resolución Estos valores se usan para objetivos a latitudes de 40 grados de latitud. Los tiempos de chequeo serán más frecuentes para latitudes más altas y menos frecuentes para latitudes más cercanas al ecuador.	
Rango Dinámico	11 u 8 bits	

Tabla B - 13(Características del sensor del satélite IKONOS) [44]