

40



**UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO**

**FACULTAD DE INGENIERÍA**

**ANÁLISIS Y CLASIFICACIÓN SEMI-AUTOMÁTICA  
DE ESCENAS URBANAS DEL DISTRITO FEDERAL**

**T E S I S**

QUE PARA OBTENER EL TÍTULO DE:  
**INGENIERO EN COMPUTACIÓN**

P R E S E N T A :  
**ELIUD FERNÁNDEZ AGUIRRE**

DIRECTOR DE TESIS: D.I. MIGUEL MOCTEZUMA FLORES



MÉXICO, D. F.

2002

**TESIS CON  
FALLA DE ORIGEN**



Universidad Nacional  
Autónoma de México

Dirección General de Bibliotecas de la UNAM

**Biblioteca Central**



**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.

## **AGRADECIMIENTOS**

A la **Universidad Nacional Autónoma de México** por abrirme sus puertas y depositar su confianza en mí, para dar mi mejor esfuerzo en beneficio de la institución misma y del país. A la **Facultad de Ingeniería** por brindarme la oportunidad de un desarrollo intelectual, productivo y personal. A la **División de Estudios de Posgrado de la Facultad de Ingeniería, División Eléctrica**.

Pueden tener la seguridad de que siempre llevaré su nombre muy en alto.

POR MI RAZA HABLARÁ MI ESPÍRITU.

Al **Dr. Miguel Moctezuma Flores** por aceptar, amablemente, dirigir este proyecto de tesis. Por todos sus consejos, motivación y gran apoyo que me brindo durante la realización de este trabajo.

A:

**Dr. Jesús Savage Carmona**

**Dr. Victor García Garduño**

**Dra. Ana María Vázquez Vargas**

**Ing. Jorge Valeriano Assem**

Por su honorable participación como miembros del jurado evaluador.

El presente trabajo de tesis fue desarrollado mediante el otorgamiento de una beca por parte del **Consejo Nacional de Ciencia y Tecnología (CONACYT)** en el proyecto **Fusión de Datos y Clasificación Contextual para el Análisis de Escenas de Percepción Remota**.

## A ti mi Señor y Dios

Por tu inmenso amor, gran misericordia y eterna fidelidad. Por que tu diestra siempre me ha sostenido con fuerza y con poder. Por ser mi luz, mi fortaleza y mi esperanza. Gracias.

## A mis padres

*Felipe Fernández Perez*  
*María Guadalupe Aguirre Castillo (†)*

Por sus enseñanzas, ejemplo, amor y apoyo incondicional para lograr cada una de mis metas. Por enseñarme el camino de verdad y vida.

## A mis hermanas

*Adareli Fernández Aguirre*  
*Blanca Ivett Fernández Aguirre*

Por ser no solo hermanas sino también amigas. Por su apoyo y comprensión en todo momento difícil.

## A todos mis profesores

Por su contribución en mi formación académica y profesional, así como por su ética y profesionalismo.

## A todos mis amigos y compañeros

Por brindarme su apoyo y compañerismo en las diferentes etapas y circunstancias durante el transcurso de mi carrera.

El haber conseguido alcanzar esta meta no es solamente un logro personal sino también de todos ustedes. Una vez más, GRACIAS.

*Eliud Fernández Aguirre*

El principio de la sabiduría es el temor de Jehová. Buen entendimiento tienen todos los que practican sus mandamientos. Su locor permanece para siempre.

*Salmo 111:10*

... el conocimiento de Santísimo es la inteligencia

*Proverbios 9:10*

Con Dios está la sabiduría y el poder. Suyos el consejo y la inteligencia

*Job 2:13*

... a fin de conocer el misterio de Dios el Padre y de Cristo el Hijo, quien están escondidos todos los tesoros de la sabiduría y del conocimiento

*Colosenses 2:2-3*

---

## TABLA DE CONTENIDO

---

<b>CAPÍTULO 1. Introducción</b> .....	1
<b>CAPÍTULO 2. Fundamentos de Percepción Remota</b> .....	5
2.1 Historia de la Percepción Remota .....	6
2.2 Principios básicos de la Percepción Remota .....	8
2.3 Sistemas de adquisición.....	10
2.3.1 Resolución de un sistema sensor .....	10
2.3.2 Resolución espacial .....	11
2.3.3 Resolución espectral .....	11
2.3.4 Resolución radiométrica .....	12
2.3.5 Resolución temporal .....	12
2.3.6 Relación entre los tipos de resolución .....	13
2.4 Tipos de sensores.....	14
2.4.1 Sensores pasivos.....	14
2.4.1.1 Sensores fotográficos.....	14
2.4.1.2 Sensores optoelectrónicos.....	15
2.4.1.2.1 Exploradores de barrido .....	15
2.4.1.2.2 Exploradores de empuje .....	16
2.4.1.2.3 Cámaras de vidición .....	17
2.4.1.2.4 Radiómetros de microondas .....	17
2.4.2 Sensores activos.....	18
2.4.2.1 Radar.....	18
2.4.2.2. LIDAR (Light Detection and Ranging).....	18
2.5 Características de los datos en la Percepción Remota.....	19
2.6 Energía Electromagnética .....	20
2.6.1 Propiedades de las ondas electromagnéticas .....	20
2.6.2 Proceso de interacción entre la energía electromagnética y la materia.....	21
2.6.3 El Espectro Electromagnético.....	21
2.6.3.1 Regiones de longitudes de ondas y bandas.....	22
2.6.3.2 Características de los distintos intervalos espectrales .....	23
2.7 Aplicaciones de los sistemas de Percepción Remota .....	23
<b>CAPÍTULO 3. Satélites y Captores</b> .....	26
3.1 Introducción.....	27
3.1.1 Satélites geoestacionarios .....	27
3.1.2 Satélites heliosincronos .....	27
3.1.3 Bandas utilizadas por los satélites .....	28
3.2 Satélite IKONOS .....	28
3.2.1 Principales características del satélite IKONOS.....	29
3.2.2 Cobertura .....	31
3.2.3 Aplicaciones y ventajas de las imágenes IKONOS .....	31
3.3 Satélites LANDSAT .....	32
3.3.1 Landsat 1, 2 y 3.....	33
3.3.1.1 Sistema RBV (Return Beam Vidición).....	34
3.3.1.2 Sistema MSS (Multispectral Scanner System) .....	35

---

---

## TABLA DE CONTENIDO

---

3.3.2 Landsat 4 y 5.....	36
3.3.2.1 Sistema TM (Thematic Mapper) .....	37
3.3.3 Landsat 7.....	39
3.3.3.1 La órbita del Landsat 7 .....	39
3.3.3.2 Bandas espectrales y Resolución espacial .....	40
3.3.3.3 Niveles de corrección geométrica de las imágenes Landsat 7.....	41
3.4 SPOT 5 supermode.....	43
3.4.1 Datos técnicos del programa Spot .....	44
3.4.2 El programa vegetación .....	46
3.4.3 El instrumento vegetación .....	47
3.4.4 Modos y bandas espectrales: PAN, M, XS, XI, P+XS .....	47
3.4.5 Características técnicas del Spot 5.....	48
3.4.6 Cualidades radiométricas y geométricas del Spot 5 .....	48
3.4.7 El instrumento HRS para la alta resolución estereoscópica .....	49
3.5 Imágenes del satélite IKONOS.....	50
3.6 Imágenes de los satélites LANDSAT .....	52
3.7 Imágenes de los satélites SPOT.....	54
<b>CAPÍTULO 4. Técnicas Bayesianas .....</b>	<b>55</b>
4.1 Introducción.....	56
4.2 Reconocimiento estadístico de patrones.....	57
4.3 Bayesianismo.....	57
4.4 Teorema de Bayes.....	58
4.4.1 Evaluación de la hipótesis por técnicas Bayesianas .....	60
4.4.2 Clasificador Bayesiano simple .....	60
4.5 Redes Bayesianas .....	61
4.6 Redes Probabilísticas Visuales .....	63
4.7 Aplicación de métodos estadísticos en la segmentación de imágenes naturales .....	64
<b>CAPÍTULO 5. Teoría de los Campos Aleatorios de Markov (CAM).....</b>	<b>66</b>
5.1 Probabilidad y variables aleatorias .....	67
5.2 Teoría Bayesiana .....	71
5.3 Antecedentes en los Campos Aleatorios de Markov .....	76
5.3.1 El problema del etiquetado en visión .....	77
5.3.1.1 Notación .....	77
5.3.1.2 El problema del etiquetado.....	78
5.3.1.3 Clasificación del problema del etiquetado en visión.....	79
5.3.2 Sistema de vecinos y cliques .....	80
5.3.3 Campos Aleatorios de Markov (MRF).....	82
5.3.4 Segmentación y reconstrucción de imágenes utilizando CAM .....	84
5.3.5 Distribución de Gibbs.....	85
5.3.6 Equivalencia Markov - Gibbs .....	86
5.4 Estimación Bayesiana.....	89
5.4.1 Máximo a Posteriori (MAP).....	90
5.4.2 Modos Marginal a Posteriori (MPM) .....	90
5.4.3 Campo Intermedio (MF).....	91

---

---

## TABLA DE CONTENIDO

---

5.5 Ejemplos de modelos Markovianos.....	91
5.5.1 Auto – modelos.....	91
5.5.2 Modelo logístico multinivel.....	94
5.6 Métodos locales y globales de minimización .....	95
5.6.1 Optimización combinatoria .....	95
5.6.2 Función de energía y su optimización .....	96
5.6.3 Metrópolis.....	97
5.6.4 Recocido Simulado (Simulated Annealing) .....	97
5.6.4.1 Planteamiento para minimizar la función de energía.....	98
5.6.4.2 Algoritmo de Recocido Simulado .....	99
5.6.4.3 Energía y Ley de Temperatura.....	99
5.7 Modelo de Potts.....	101
<b>CAPÍTULO 6. Primera Etapa : Pre – Segmentación Bayesiana.....</b>	<b>103</b>
6.1 Introducción.....	104
6.2 Proceso de segmentación .....	104
6.3 Pre – segmentación Bayesiana.....	106
6.3.1 Algoritmo de pre-clasificación .....	106
6.3.2 Función Bayesiana de clasificación .....	108
6.4 Imágenes de prueba y áreas de estudio .....	109
6.4.1 Área de estudio #1 .....	110
6.4.2 Área de estudio #2 .....	112
6.4.3 Área de estudio #3 .....	114
<b>CAPÍTULO 7. Segunda Etapa : Segmentación Bayesiana .....</b>	<b>116</b>
7.1 Segmentación Bayesiana .....	117
7.1.1 Algoritmo de clasificación (continuación) .....	117
7.2 Segmentación Bayesiana de las áreas de estudio.....	118
7.2.1 Área de estudio #1 .....	118
7.2.2 Área de estudio #2 .....	119
7.2.3 Área de estudio #3 .....	120
7.3 Estudio comparativo entre pre – segmentación y segmentación Bayesiana .....	121
7.3.1 Área de estudio #1 .....	121
7.3.2 Área de estudio #2 .....	122
7.3.3 Área de estudio #3 .....	123
<b>CAPÍTULO 8. Tercera Etapa : Segmentación Markoviana y modelo de Potts.....</b>	<b>124</b>
8.1 Introducción.....	125
8.2 El Recocido Simulado (Simulated Annealing).....	126
8.2.1 Planteamiento .....	126
8.3 Segmentación Markoviana .....	127
8.3.1 Proceso de segmentación.....	127
8.3.2 Función de energía.....	128
8.3.3 Algoritmo de Recocido Simulado .....	130

---

---

## TABLA DE CONTENIDO

---

8.4 Segmentación Markoviana de las áreas de estudio.....	132
8.4.1 Área de estudio #1 .....	132
8.4.2 Área de estudio #2 .....	133
8.4.3 Área de estudio #3 .....	134
<b>CAPÍTULO 9. Resultados .....</b>	<b>135</b>
9.1 Especificaciones de plataforma, software y parámetros utilizados .....	136
9.2 Segmentaciones comparativas de las áreas de estudio .....	136
9.2.1 Área de estudio #1 .....	137
9.2.2 Área de estudio #2 .....	139
9.2.3 Área de estudio #3 .....	141
<b>CAPÍTULO 10. Conclusiones.....</b>	<b>144</b>
<b>APÉNDICE .....</b>	<b>148</b>
Sistemas de Procesamiento Digital de Imágenes.....	149
Lista de satélites de Percepción Remota.....	151
TVFDO – Sistema para el Procesamiento Digital de Imágenes .....	157
Diagrama General de Flujo del Sistema TVFDO .....	163
Diagrama General de Flujo del Proceso de Segmentación Bayesiano-Markoviano.....	164
<b>BIBLIOGRAFÍA .....</b>	<b>165</b>


---



---

# CAPÍTULO 1

## INTRODUCCIÓN



## Introducción.

Estudiar la percepción remota, muy empleado hoy por todas las áreas y disciplinas relacionadas con las ciencias espaciales, es de gran importancia. Dicha importancia es comprensible, si se analiza su gran impacto en las sociedades emergentes, en relación con el conocimiento, el cual es adquirido con la información generada a partir de las imágenes espaciales de la superficie de la tierra.

Desde este enfoque, la información geográfica es la base del conocimiento, que se hace fundamental para el desarrollo económico y social de las naciones. La planeación, a todos los niveles, y la generación de los proyectos de desarrollo en un país, no podrían llevarse a cabo sin la ayuda de esta información, la cual mejora la calidad de las decisiones y constituye un recurso estratégico del estado y sus organizaciones.

La generación de la información geográfica se realiza utilizando las tecnologías como la percepción remota cuya fundamentación teórica es brindada por la *ciencia de la información geográfica*, la cual busca redefinir los conceptos geográficos y su uso en el contexto de la información geográfica y la edad digital.

La gestión de la información geográfica a cualquier nivel global, regional, departamental, local, requiere el manejo de tecnologías como la percepción remota, los GPS y los Sistemas de Información Geográfica (SIG). Las dos primeras, generan los datos e información que sirven de fuente a los SIG. La integración de las tres, brinda el mejor soporte en la toma de decisiones, dentro del manejo del territorio, de los recursos naturales y del medio ambiente.

Puede decirse que la percepción remota como tecnología empezó con la aparición de las primeras fotografías. Uno de los dispositivos más conocidos que han servido como un sensor remoto por más de 150 años es la cámara fotográfica. Durante los años setenta, los primeros sensores de imágenes sofisticados fueron incorporados en satélites de órbita. Al principio, estas eran cámaras básicas de TV que tomaban un gran detalle de cuadros en blanco y negro con acercamientos a la superficie de la tierra. Después se desarrollaron otros tipos de sensores multispectrales que captaban datos más allá del visible en ambos lados del infrarrojo cercano y termal. Actualmente, los satélites de percepción remota están equipados con una variedad de instrumentos sofisticados de detección, especialmente diseñados para registrar los detalles de la superficie terrestre, los océanos y la atmósfera.

La técnicas de percepción remota, a través de las imágenes adquiridas por los satélites, contribuyen al estudio de los fenómenos atmosféricos, expansión de la mancha urbana, deforestación de bosques y una gran variedad de aplicaciones.

El procesamiento digital de imágenes, como campo del conocimiento de la ingeniería, forma parte ineludible de la percepción remota. El proceso necesario para percibir información de un objeto remoto se basa en la recopilación de datos por medio de sensores, mientras que el análisis de dichos datos se realiza a través de técnicas de procesamiento digital. Como consecuencia, se genera la información respectiva a la aplicación realizada. Uno de los procesos a seguir dentro del procesamiento digital es la segmentación.

La segmentación es un proceso que consiste en dividir una imagen digital en regiones homogéneas con respecto a una o más características (como por ejemplo el brillo o el color) con el fin de facilitar su posterior análisis y reconocimiento. Puede verse como un proceso que, a partir de una imagen, produce otra en la que cada píxel tiene asociada una etiqueta distintiva del objeto al que pertenece. Así, una vez segmentada una imagen, se podría formar una lista de objetos agrupando todos los píxeles que tengan la misma etiqueta.

La segmentación termina cuando los objetos que aparecen en una imagen se corresponden unívocamente con las distintas regiones disjuntas resultado del proceso de segmentación. En este caso se habla de segmentación completa de la escena o imagen y en el caso contrario, de segmentación parcial. En una escena compleja, el resultado de la segmentación podría ser un conjunto de regiones homogéneas superpuestas y en este caso, la imagen parcialmente segmentada deberá ser sometida después a un tratamiento posterior con el fin de conseguir una segmentación completa.

En general, el proceso de la segmentación suele resultar complejo debido, por un lado, a que no se tiene una información adecuada de los objetos a extraer y, por otro, a que en la escena a segmentar aparece normalmente ruido. En este trabajo se estudiarán algunos enfoques para realizar el proceso de segmentación, aunque en la práctica se demuestra que la segmentación no tiene reglas estrictas a seguir, y que dependiendo del problema en cuestión puede ser necesario idear técnicas a medida.

Algunos ejemplos típicos de procesos de segmentación se tienen al tratar de separar los caracteres que forman una palabra dentro de una imagen, al detectar ciertos tipos de células en imágenes médicas, al extraer los vehículos que aparecen en una imagen de una carretera, identificar diferentes regiones en una imagen aérea o en general cuando se trata de separar ciertos objetos de un fondo en una imagen cualquiera.

El problema de la segmentación es fundamental en muchas áreas del análisis de datos e imágenes. Este proceso implica, como se mencionó anteriormente, dividir una larga secuencia de datos en pequeños segmentos homogéneos, cuyos límites pueden ser interpretados como cambios físicos en el sistema. Esta aproximación demostró su utilidad en diferentes problemas prácticos surgidos en el reconocimiento orientado al procesamiento de señales. No es de sorprenderse el gran interés teórico y práctico, el cual se ve reflejado en un gran número de estudios.

El propósito del presente trabajo de tesis es realizar aportaciones en la segmentación de fotografía aérea de alta resolución. Diversos estudios se emprenderán, principalmente bajo la teoría de los *Campos Aleatorios de Markov* (MRF). La facilidad para describir el proceso de formación de las imágenes (estadística de datos) y para describir objetos de escena (proceso de etiquetar regiones) son características fácilmente incorporables vía la teoría de los MRF. Contrariamente, la principal desventaja de la segmentación markoviana radica en la pérdida de resolución espacial.

La etapa final de segmentación incorporará un esquema de segmentación por el modelo de Potts, a efectos de proporcionar resultados binarios del tipo urbano y NO-urbano, en fotos aéreas de alta resolución del Distrito Federal.

En el capítulo 1 se desarrolla una breve introducción a este trabajo de tesis con el propósito de ofrecer una panorámica general del mismo.

En el capítulo 2 se da una introducción a los fundamentos y aplicaciones de la percepción remota; su historia, sus principios básicos, los sistemas de adquisición (sensores) y sus características principales, así como las características de los datos adquiridos, la energía electromagnética y sus propiedades.

En el capítulo 3 se realiza una introducción a los satélites y los captores. Se estudian las principales características de los satélites: IKONOS, LANDSAT y SPOT. Entre estas características están: tipo de órbita, resolución pancromática y multispectral, resolución espacial, bandas espectrales, altitud, inclinación, sistemas sensores incorporados, etc. Al final del capítulo se incluye una galería de imágenes obtenidas por cada uno de los satélites mencionados anteriormente.

En el capítulo 4 se abordan las técnicas Bayesianas. Se tratan brevemente: el reconocimiento estadístico de patrones, el Bayesianismo, el teorema de Bayes, el clasificador Bayesiano simple, las redes Bayesianas, las redes probabilísticas visuales y la aplicación de métodos estadísticos en la segmentación de imágenes.

En el capítulo 5 se aborda la teoría de los Campos Aleatorios de Markov (MRF). Se estudian: la probabilidad y las variables aleatorias, la teoría Bayesiana, los antecedentes de los CAM (Campos Aleatorios de Markov), la estimación Bayesiana, ejemplos de modelos Markovianos, métodos locales y globales de minimización y el modelo de Potts.

En el capítulo 6 se realiza la primera etapa del proceso de segmentación de este trabajo de tesis. Se describe, primeramente, todo el proceso de segmentación así como cada una de las partes de las que consta. Esta primera etapa consiste de una pre-segmentación Bayesiana para lo cual se especifica el algoritmo de pre-clasificación y la función Bayesiana de clasificación correspondiente. Finalmente, se presenta el conjunto de imágenes segmentadas, obtenidas en esta etapa en tres diferentes áreas de estudio, y sus respectiva información resumida en tablas.

En el capítulo 7 se efectúa la segunda etapa del proceso de segmentación. Esta consiste en una segmentación Bayesiana idéntica a la etapa anterior, excepto que ahora son utilizadas las probabilidades actualizadas de ocurrencia de clases. Al final se vuelve a incluir el conjunto de imágenes segmentadas que se obtuvieron ahora en esta etapa, así como la información de dicha segmentación resumida en tablas.

En el capítulo 8 se realiza la tercera etapa del proceso de segmentación. En esta etapa se efectúa ahora un proceso de segmentación Markoviano. Este proceso de segmentación requiere del resultado de la etapa anterior, de la función de energía correspondiente y de la utilización del algoritmo de recocido simulado (*simulated annealing*). Al final del capítulo se presenta el conjunto de imágenes segmentadas que se obtuvieron en esta tercera etapa de segmentación. También se muestra la información correspondiente resumida en tablas.

En el capítulo 9 se presentan resumidos los resultados obtenidos en las etapas anteriores. Además, se muestra el resultado de la segmentación por funciones discriminantes óptimas. Esto con el fin de poder establecer criterios de comparación entre los métodos utilizados (Markoviano, Bayesiano y Funciones Discriminantes Óptimas). Asimismo, se presentan zooms (acercamientos) de los resultados de cada segmentación con el propósito de análisis y comparación. Del mismo modo, se presentan las tablas que resumen la información de cada segmentación por área y método de segmentación.


En el capítulo 10 se presentan las conclusiones generales sobre este trabajo de tesis y sobre los resultados obtenidos en el.

Al final del trabajo de tesis se muestra la bibliografía utilizada para el desarrollo de la misma. Esta contiene, además de las referencias bibliográficas, la direcciones electrónicas de Internet que se consultaron.

---

# CAPÍTULO 2

## FUNDAMENTOS DE PERCEPCIÓN REMOTA



*La Estación Espacial Internacional (International Space Station). Fecha: Diciembre del 2001. Crédito: tripulación de la misión STS-108.*

### 2.1 Historia de la Percepción Remota.

La Percepción remota es una técnica aplicada, y como tal muy dependiente del estado tecnológico existente en cada momento. Por cuanto reúne aspectos muy variados – óptica y detectores del sensor, vehículo que lo sustenta, sistemas de transmisión, equipo de tratamiento, etc. – las formas de la percepción remota han variado dramáticamente en las últimas décadas. El crecimiento ha sido realmente vertiginoso, tanto en la cantidad como en la variedad y calidad de la información disponible para campos científicos muy variados.

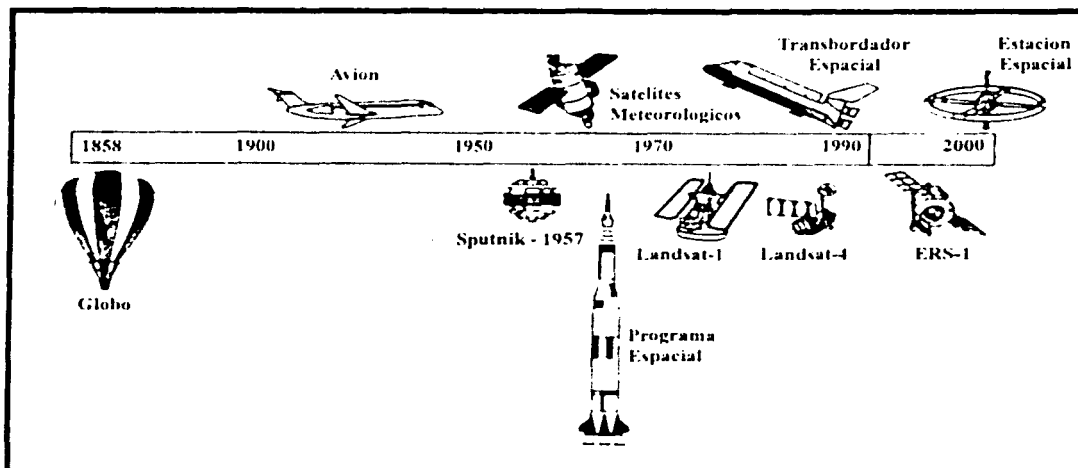


Figura 2.1 – Evolución histórica de los sistemas de Percepción Remota.

Las primeras experiencias de percepción remota se remontan a 1859, cuando Gaspar Félix de Tournachon obtuvo las primeras fotografías aéreas desde un globo cautivo (Hyan, 1988). Al año siguiente, James Wallace repitió la 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.

En los años posteriores se produjo un importante desarrollo de la observación fotográfica desde avión, gracias a los progresos realizados en óptica y emulsiones. En 1909, Wilbur Wright adquirió la primera fotografía aérea, abriendo el camino a una larga historia de observación desde plataformas remotas. La primera cámara aérea, propiamente dicha, se desarrolló durante la 1ª. Guerra Mundial. Concretamente en 1915, por J.T.C. Moore Brabazon. La importancia estratégica de este escrutinio quedó pronto en evidencia, desarrollándose notablemente las técnicas de adquisición y procesamiento fotográfico (Brookes, 1975).

La 2ª. Guerra Mundial implicó un notable desarrollo de las técnicas de percepción remota aérea. El progreso se orientó a mejorar la óptica de las cámaras de reconocimiento, así como las emulsiones utilizadas (de esta época proceden las primeras películas en infrarrojo desarrolladas por *Kodak Research Laboratories*). Asimismo, se introdujeron nuevos sensores como el radar y se mejoraron los sistemas de comunicación. Por otro lado, la aeronáutica prosperó notablemente, lo que aseguró mayor estabilidad a las plataformas de observación.

Todas estas innovaciones se aplicaron posteriormente para usos civiles, desarrollándose las primeras aplicaciones de esta exploración aérea para el conocimiento y control de los recursos naturales. En los años de la posguerra se perfeccionaron los sistemas de radar, introduciéndose el radar lateral aerotransportado (SLAR), y se pusieron a punto los sensores térmicos de barrido.

A finales de los años 50, el desarrollo de los sistemas de navegación permitió concebir los primeros ingenios espaciales. Al lanzamiento del satélite soviético Sputnik, en 1957, le siguen una larga serie de misiones civiles y militares que han permitido no solo la exploración de nuestra Planeta, sino también la Luna y los planetas vecinos.

Poco después de haberse iniciado esta carrera espacial, se puso en evidencia el interés de usar estas plataformas para adquirir valiosos datos de la superficie y atmósfera terrestre.

En 1960, la NASA lanzó el primer satélite de la serie TIROS, pionero de múltiples misiones de observación meteorológica que han permitido un conocimiento y control más ajustados de las condiciones atmosféricas, evitando grandes catástrofes naturales.

Junto a estos satélites artificiales, en los años setentas también se impulsaron misiones tripuladas dedicadas a la exploración del Sistema Solar y la conquista de la Luna. Además de estos fines, aportaron asimismo valiosas imágenes sobre la superficie terrestre. Las primeras fotografías espaciales se tomaron por Alan B. Shepard de forma espontánea y un tanto rudimentaria, durante una de las misiones del Mercury (1961). En los años siguientes se continuaron tomando fotografías desde naves tripuladas, aunque fue la misión Géminis-Titán (1965) la que incluyó los primeros experimentos formales de fotografía espacial, en este caso para usos geológicos y meteorológicos.

Alentada por los brillantes resultados de estos ensayos, la NASA continuó proyectando este tipo de observaciones. Durante los vuelos de Apolo 6 y Apolo 7 se adquirieron diversas series de fotografías verticales, mientras en el Apolo 9 (1969) se abordó el primer experimento multispectral, compuesto por cuatro cámaras Hasselblad con distintos filtros.

Todas estas experiencias, junto al bagaje aportado por los satélites meteorológicos, hicieron concebir a la NASA proyectos dedicados exclusivamente a la cartografía y evaluación de los recursos naturales. El 23 de julio de 1972, supuso la culminación de esta tendencia, con el feliz lanzamiento del primer satélite de la serie ERTS (*Earth Resources Technology Satellite*). Este proyecto, bautizado Landsat con la puesta en órbita del segundo satélite en 1975, resulta el más fructífero hasta el momento para aplicaciones civiles.

A partir de la serie Landsat, el interés de la comunidad científica internacional por esta técnica ha crecido exponencialmente, contándose por miles los estudios desarrollados sobre las imágenes proporcionadas por estos satélites.

A la serie Landsat siguieron otros proyectos específicamente diseñados para la observación medioambiental. Los más conocidos son: el laboratorio espacial tripulado Skylab (1973), el satélite oceanográfico Seasat (1978), el de investigación térmica HCMM (1978), el satélite francés SPOT (1986), el japonés MOS-1 (1987), el indio IRS-1 (1988) y los rusos Soyuz y Salut. La Agencia Espacial Europea y la Canadiense ya han lanzado sus propios satélites al espacio y pronto lo harán la brasileña en colaboración con la china y varios consorcios.

El creciente interés hacia los estudios de cambio climático global permite asegurar el financiamiento de algunos proyectos muy ambiciosos de percepción remota, como es el caso de la

plataforma polar, que incluirá numerosos instrumentos para la observación de la Tierra. Pese a la juventud de esta tecnología, son ya numerosos los centros de producción, enseñanza e investigación que trabajan activamente en este campo. Las tendencias presentes parecen confirmar un creciente desarrollo de su aplicación, tanto en países desarrollados como en aquellos con una situación tecnológica más deficiente.

De acuerdo con Curran (1985), se pueden distinguir cuatro estadios en el desarrollo de cualquier disciplina. El primero vendría dado por un período preliminar de crecimiento, con una tradición investigadora escasa, y pocas o ninguna asociación dedicada a su estudio. El segundo, corresponde a un período de crecimiento exponencial, doblándose el número de publicaciones a intervalos regulares a la vez que se establecen unidades de investigación. En el tercer nivel, el índice de crecimiento comienza a declinar y, aunque no existan importantes aumentos en el volumen de especialistas, el nivel de especialización y controversia aumenta. El último período se caracteriza por un nivel de crecimiento cercano a cero: las unidades de especialización y sociedades profesionales se consolidan y la ciencia adquiere madurez.

Dentro de este esquema, la percepción remota ocupa estadios muy diversos según los países. La mayor parte de los países en desarrollo se encuentran en el primer nivel, la mayor parte de los países europeos en el segundo, y Estados Unidos comienza a entrar en el tercer estadio.

## 2.2 Principios básicos de la Percepción Remota.

El término **Percepción Remota** fue el adoptado en los países de habla hispana como traducción del inglés *remote sensing*<sup>1</sup>, utilizándose a partir del año 1960 para describir las observaciones de un objeto efectuadas sin mediar contacto físico con él. Este tipo de adquisición de información solamente puede ser posible mediante la detección y medida de los cambios que el objeto observado induce en su entorno, bien sean en forma de perturbaciones electromagnéticas, bien como ondas acústicas reflejadas o alteradas, o como perturbaciones del campo magnético o gravitatorio debidas a la presencia del objeto. Con carácter más restrictivo, el término percepción remota se reserva a las técnicas electromagnéticas de adquisición de información en las zonas del espectro electromagnético comprendidas entre las ondas de radio de baja frecuencia y los rayos X, gamma e incluso, cósmicos.

La percepción remota no engloba solo los procesos que permiten obtener una imagen, sino también su posterior tratamiento, en el contexto de una determinada aplicación.

Si definimos la percepción remota como la técnica que permite adquirir imágenes de la superficie terrestre desde sensores instalados en plataformas espaciales, se asume que entre la Tierra y el sensor existe una interacción energética, ya sea por reflexión de la energía solar o de un haz energético artificial. A su vez, es necesario, que ese haz energético recibido por el sensor sea almacenado convenientemente, ya sea a bordo del satélite o en estaciones receptoras, para que posteriormente pueden ser interpretadas para una determinada aplicación.

Definido así, un sistema de percepción remota incluye los siguientes elementos (Figura 2.2):

---

<sup>1</sup> También es traducido como *Teledetección* en varios textos.



1. **Fuente de energía:** que supone el origen de la radiación electromagnética que detecta el sensor. Puede tratarse de un foco externo a éste, en cuyo caso se habla de percepción remota pasiva, o de un haz energético emitido por el sensor (percepción remota activa). La fuente de energía más importante es el sol.
2. **Cubierta terrestre:** formada por distintas masas de vegetación, suelos, agua o construcciones humanas, que reciben la señal energética procedente de (1), y la reflejan o emiten de acuerdo a sus características físicas.
3. **Sistema sensor:** compuesto por el sensor, propiamente dicho, y la plataforma que lo alberga. Tiene como misión captar la energía procedente de las cubiertas terrestres, codificarla y grabarla o enviarla directamente al sistema de recepción.
4. **Sistema de recepción-comercialización:** en donde se recibe la información transmitida por la plataforma, se graba en un formato apropiado y, tras las oportunas correcciones, se distribuye a los interesados.
5. **Intérprete:** que convierte esos datos en información temática de interés, ya sea visual o digitalmente, de cara a facilitar la evaluación del problema en estudio.
6. **Usuario final:** encargado de analizar el documento del resultado de la interpretación, así como dictaminar sobre las consecuencias que de él se deriven.

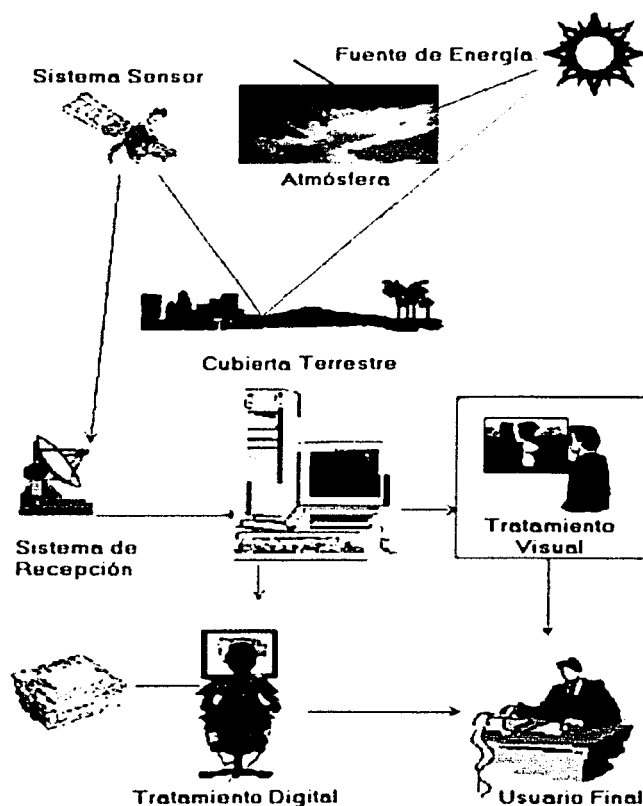


Figura 2.2 – Componentes de un sistema de Percepción Remota.

El simil de la visión humana puede ayudar a entender el significado de estos componentes. El ojo humano (3) recibe un haz energético procedente de los objetos exteriores (2) por reflejo de la luz solar (1). Esa señal se transmite al cerebro (4), que es capaz de formar una serie de imágenes sobre el mundo real que le circunda. El individuo que observa es a la vez intérprete (5) y usuario final (6) de la imagen detectada, lo que le permite tomar decisiones sobre su propio comportamiento. En otras palabras, la visión humana forma un sistema de percepción remota muy sofisticado.

El uso de plataformas ha sufrido un cambio esencial con la incorporación de los satélites artificiales. Esto ha permitido una concepción más general de los temas de estudio, pudiendo abordarse proyectos a escala regional, continental o incluso global.

### 2.3 Sistemas de Adquisición.

Como ya se mencionó anteriormente, un sistema de percepción remota de cualquier fenómeno requiere el concurso de varios elementos: una fuente de radiación electromagnética, la interacción de dicha radiación con la superficie del objeto a estudiar y un sistema de detección que reciba la radiación reflejada.

Los sistemas para adquisición de imágenes remotas constan de un sistema sensor y de una plataforma que lo sustente.

Existen varios tipos de sistemas de percepción remota o *sensores* clasificables de acuerdo a diversos criterios. Según el procedimiento a emplear, los sistemas pueden ser *pasivos* o *activos*. Los primeros son sólo meros receptores de la radiación procedente de un objeto iluminado por una fuente externa, generalmente el Sol, en tanto que los segundos se caracterizan por generar ellos mismos la radiación que posteriormente medirán tras su interacción con la superficie objeto del estudio.

#### 2.3.1 Resolución de un sistema sensor.

Se denomina *resolución* de un sistema a su capacidad para discriminar información de detalle en un objeto detectado. La resolución de un sensor depende del efecto combinado de sus distintos componentes. Una mejora en la lente, por ejemplo, no supondrá necesariamente adquirir fotografías con mayor resolución, si no se acompaña de una película de mayor sensibilidad, o no se modifican las condiciones de exposición. La discriminación entre objetos está en íntima relación con la escala de trabajo y con la complejidad del paisaje. Cuanto mayor sea el contraste entre cubiertas, más fácilmente se distinguirán estas.

En cuanto al significado de información de detalle se refiere no solo al detalle espacial que proporciona el sensor, sino también al número y anchura de las bandas del espectro que alberga, a su cadencia temporal y a su capacidad para distinguir variaciones en la energía que detecta.

El concepto de resolución aplicado a los instrumentos ópticos tradicionales se refiere fundamentalmente al poder de separación espacial del sistema de lentes. Cuando se utilizan sensores remotos a bordo de satélites, el estudio de una cubierta introduce nuevas dimensiones, además de las planimétricas.

La variable altimétrica en determinados casos puede considerarse despreciable, pero sin embargo aparecen, por un lado, la variable espectral, al poder ser adquirida la imagen en varias bandas del espectro, y por otro, la variable temporal, al ser posible el estudio multitemporal de una escena, en virtud de la periodicidad del paso del satélite por la vertical del lugar de estudio.

En percepción remota se emplea el mismo término resolución, pero como extensión del concepto anterior. Así pues, se habla de resolución espacial, espectral, radiométrica y temporal.

### 2.3.2 Resolución espacial.

Se llama *resolución espacial* a la capacidad del sistema para distinguir el objeto más pequeño posible en una imagen. Esta acepción del término coincide con la formulación tradicional, tal como se aplica a otros sistemas analógicos.

En los sensores opto-electrónicos se utiliza el concepto de campo de visión instantáneo (*instantaneous field of view*, IFOV). El IFOV se define como la sección angular, medida en radianes, observada en un momento determinado por el sensor. La resolución espacial de un sensor opto-electrónico depende de factores como: la altura orbital, velocidad de exploración y número de detectores. En cuanto a los sensores de antena, su resolución depende del radio de abertura, de la altura de la plataforma y de la longitud de onda a la que trabajen. Cuanto mayor sea el radio, y menor la altitud y la longitud de onda, la resolución será tanto más detallada.

La resolución espacial tiene un papel protagónico en la interpretación de la imagen por cuanto marca, de alguna forma, el nivel de detalle que esta ofrece. Esta en estrecha relación con la escala de trabajo y con la fiabilidad finalmente obtenida en la interpretación. Cuanto menor sea el tamaño del pixel, menor también la probabilidad de que éste sea un compuesto de dos ó mas cubiertas fronterizas. En el caso de cubiertas urbanas, se ha comprobado que incrementar la resolución espacial puede afectar negativamente a la interpretación, cuando esta se realiza digitalmente, al incrementar excesivamente la heterogeneidad interna en algunas categorías. Queda fuera de toda duda el interés de mejorar la resolución espacial para facilitar una interpretación más certera de la imagen.

### 2.3.3 Resolución espectral.

Se denomina *resolución espectral* a la capacidad del sensor para discriminar la radiancia detectada en distintas longitudes de onda del espectro electromagnético. Es decir, indica el número y anchura de las bandas espectrales que puede discriminar el sensor.

Dada la imposibilidad de la medida de la radiancia espectral, solamente puede aproximarse una estimación de la misma midiendo la radiancia extendida a un determinado intervalo de longitudes de onda denominado *Banda*. La resolución espectral viene determinada por el número de bandas que el sensor puede captar y por la anchura espectral de éstas. A la vez, conviene que esas bandas sean suficientemente estrechas, con objeto de recoger la señal sobre regiones coherentes del espectro. Bandas muy amplias suponen registrar un valor promedio que puede encubrir la diferenciación espectral entre cubiertas de interés.

En términos generales, el sensor será de mayor utilidad cuanto mayor sea el número de bandas que proporcione, ya que las características de determinadas cubiertas requieren estudios multispectrales. Por otro lado, conviene no obtener valores medios de regiones espectrales de diferente significación física.

Los sistemas de menor resolución espectral son los de radar, que suelen trabajar en un solo canal, y los fotográficos, cuya resolución espectral abarca desde películas pancromáticas o infrarrojo blanco y negro hasta las de color natural o infrarrojo color. Los sensores óptico-electrónicos poseen mayores posibilidades en cuanto a resolución espectral, pues presentan una gama desde 3 bandas del SPOT-IRV (verde, rojo e infrarrojo cercano), pasando por las 5 bandas del NOAA-AVHRR, hasta las 7 bandas del LANDSAT-TM (azul, verde, rojo, infrarrojo cercano, medio y térmico).

La elección del número, anchura y localización de las bandas que incluye el sensor está estrechamente relacionado con los objetivos del diseño. Para un sensor dedicado a fines meteorológicos, basta situar una sola banda en el visible. Por el contrario, es conveniente incluir una o dos bandas en el térmico y otra en el infrarrojo medio en donde puede observarse el contenido de humedad en la atmósfera.

#### **2.3.4 Resolución radiométrica.**

La *resolución radiométrica* es la capacidad del sensor para discriminar niveles o intensidades de radiancia espectral, es decir, la sensibilidad del sensor. En los sistemas analógicos como la fotografía, la resolución radiométrica viene determinada por el número de niveles de gris que pueden obtenerse. En los sistemas óptico-electrónicos, la radiancia incidente en el sensor es registrada matricialmente en forma de celdillas, a cada una de las cuales se le asigna un nivel digital (Nd) proporcional a la cantidad de energía electromagnética recibida. Esta asignación es llevada a cabo por un convertidor analógico-digital con el que va equipada la plataforma. LANDSAT-MSS ofrece 128 niveles diferentes, en tanto que el resto de los sensores actualmente en servicio suelen ofrecer una gama de 256 niveles (de 0 a 255), con la excepción de NOAA-VHRR, cuyas imágenes poseen una resolución radiométrica de 1.024 niveles.

Cuanto mayor se la precisión radiométrica, tanto mejor podrá interpretarse la imagen. El número de niveles más adecuado depende del método que se siga en la interpretación. Si esta es visual, conviene considerar que el ojo humano difícilmente percibe más de 64 niveles de gris, y no más de 200,000 tonalidades. Si se opta por la clasificación digital, la sensibilidad radiométrica puede ser mejor aprovechada, ya que la computadora es capaz de distinguir una escala numérica amplia.

#### **2.3.5 Resolución temporal.**

Se denomina *resolución temporal* a la capacidad del sistema para discriminar los cambios temporales sufridos por la superficie en estudio. Este concepto no hace referencia sino a la periodicidad con que el sensor puede adquirir una nueva imagen del mismo punto de la superficie terrestre. La periodicidad de paso por la vertical de un lugar de latitud determinada solamente depende de dos factores: la altura de la órbita, de la que depende la velocidad del satélite y el ángulo de abertura de la observación.

La resolución temporal es un requisito apreciado solamente en los estudios evolutivos de un cierto fenómeno. Carece de interés si la imagen va a ser destinada al cartografiado de nuevas zonas, pero, por el contrario, este tipo de resolución es de importancia esencial en los satélites meteorológicos, mediante los cuales deben detectarse los más mínimos cambios de la situación atmosférica a lo largo del tiempo a efectos de predicción. La mayor resolución temporal es la lograda manteniendo constantemente el satélite sobre la vertical del mismo punto.

Ello solamente es posible en las órbitas geoestacionarias, en las que la velocidad angular del satélite es igual a la de la Tierra.




Figura 2.3 – Resolución temporal de un sistema de Percepción Remota.

### 2.3.6 Relación entre los tipos de resolución.

Existe un cierto antagonismo entre algunos tipos de resolución. A mayor resolución espacial, disminuye habitualmente la temporal, y es previsible que se reduzca también la espectral. El principal problema se encuentra en la transmisión de las imágenes a la superficie terrestre. El aumento en cualquiera de los cuatro tipos de resolución significa también un incremento considerable del volumen de datos a procesar, tanto por el sensor como por la estación receptora.

El caso paradigmático en este sentido es el de los satélites meteorológicos geoestacionarios, cuya resolución temporal es de sólo media hora, y no por razones de orden orbital, ya que permanecen sobre la misma zona observada, sino por ser ése el tiempo necesario para adquirir, procesar y transmitir la información. Por el contrario, su resolución espacial es la más pobre, como consecuencia de la gran altura de su órbita, que en términos relativos es de 5,7 veces el radio de la Tierra.

El extremo opuesto en cuanto a resoluciones lo representa el satélite SPOT, cuya altura orbital permite alcanzar una extraordinaria resolución espacial. Sin embargo, su resolución temporal solamente alcanza los 26 días en latitudes ecuatoriales, que es el tiempo que tarda en volver a pasar por la vertical de un mismo punto, si bien esta debilidad queda paliada por su sistema de mira lateral, como se verá más adelante. La serie de satélites NOAA combina parte de las dos características anteriores y presenta, pues, resoluciones intermedias a las expuestas. Su altura e inclinación orbitales, unidas a la acción conjunta de los dos satélites que operan simultáneamente, permiten obtener resoluciones temporales de 12 horas y resoluciones espaciales de 1 Km.

Por otro lado, el aumento de la resolución, especialmente la espectral, como en el caso de LANDSAT lleva consigo el incremento del número de datos a procesar, hasta el punto de llegar a ser necesaria una constelación de satélites de comunicaciones (TDRSS) sobre los que descargar la información adquirida para su proceso en las estaciones receptoras.

Puesto que los diferentes tipos de resolución están relacionados, cada sistema de percepción remota ofrece unas características particulares en función de los fines para los que se diseña. Si está orientado a la detección de fenómenos efímeros en el tiempo, deberá realizarse su cobertura temporal, aún a costa de perder resolución espacial, como ocurre con los satélites meteorológicos.

Si por el contrario, el sensor se orienta a exploración minera, el detalle espacial y espectral resulta más importante, reduciéndose entonces su ciclo temporal. Un solo sistema no puede cubrir todas la expectativas.

## 2.4 TIPOS DE SENSORES.

### 2.4.1 Sensores Pasivos.

Los *sensores pasivos* recogen la energía electromagnética (radiancia) procedente de la superficie terrestre, ya sea causada por la reflexión o por la emisión de la misma. Existen dos tipos fundamentales de sensores pasivos: los fotográficos y los óptico-electrónicos.

#### 2.4.1.1 Sensores Fotográficos.

La detección remota mediante cámaras fotográficas es el método actualmente más utilizado para la adquisición de datos desde plataformas aéreas. La diversidad de tipos de fotografías depende del *tipo de película utilizada, del número de objetivos, del ángulo de observación con respecto a la superficie y de la altura de observación*. Basan su funcionamiento en la impresión de un objeto sobre emulsiones fotosensibles, con el apoyo de un sistema óptico que permite controlar las condiciones de exposición.

También ha sido utilizada con profusión la fotografía en plataformas orbitales. Comenzando en las primeras misiones espaciales Mercury y Géminis, y desarrollándose en la del Skylab, prácticamente todas los programas espaciales han incluido misiones fotográficas.

Las películas fotográficas empleadas normalmente son las panorámicas (blanco y negro), color, infrarrojo e infrarrojo color. Por su parte, las cámaras pueden ser mono o multibanda, según albergue una o varias regiones del espectro simultáneamente. La fotografía multibanda se logra bien mediante cámaras provistas de varios objetivos utilizando diferentes filtros para cada uno de ellos, o bien mediante el montaje en una misma estructura de varias cámaras verdaderas, cada una de ellas con una combinación diferente de película y filtro. El resto de las características de las cámaras es similar a las empleadas en fotogrametría convencional, distinguiéndose de éstas solamente por su mayor distancia focal para compensar el aumento de altura sin perder excesiva resolución. En lo que se refiere al ángulo de observación, existen dos variantes:

- **La fotografía vertical:** es tomada perpendicularmente al terreno (con 5° de desviación permitida). Es empleada con el debido recubrimiento para la restitución fotogramétrica, así como en estudios temáticos muy variados.
- **La fotografía oblicua:** tiene un ángulo de visión sensiblemente inferior a 90°. Tiene principalmente un fin estético, aunque también puede reportar interesantes conclusiones para el estudio del relieve o los asentamientos humanos.

La altura de observación permite distinguir entre la fotografía aérea y espacial. Las diferencias más significativas entre ambas afectan a su resolución espacial, nitidez, cobertura del terreno y precisión geométrica. Las dos primeras son favorables a la fotografía aérea y las dos últimas a las cámaras espaciales.

### 2.4.1.2 Sensores Óptico-Electrónicos.

Los *sensores óptico-electrónicos* consisten en dispositivos que combinan una óptica similar a la utilizada en fotografía convencional con un sistema de registro electrónico que elimina la necesidad de un soporte de papel. Según la forma de capturar la radiación, se clasifican en: rastreadores de barrido, rastreadores de empuje y cámaras de vidicon.

#### 2.4.1.2.1 Exploradores de barrido.

Los *rastreadores de barrido o scanners*, son sensores que exploran la superficie estudiada mediante el barrido de la escena gracias a un espejo basculante, cuyo eje de oscilación es paralelo a la trayectoria del satélite portador. La imagen real, tras ser dirigida por el espejo, pasa por el sistema óptico y es dirigida hacia los detectores. Éstos son células fotoeléctricas expresamente diseñadas para una longitud de onda determinada, y son los encargados de transformar la radiancia en nivel digital (Nd) de la imagen. Por ello, en percepción remota, en lugar de aplicar el término fotografía, se prefiere hablar de imagen digital de satélite. Antes de ser recogida por los detectores, la señal puede ser descompuesta, mediante una óptica adecuada, en varias bandas cada una de las cuales se envía a un detector diferente, para formar de este modo la imagen multispectral.

Si se conocen los parámetros de calibración del sensor y las condiciones de adquisición, es posible transformar los niveles digitales de la imagen en valores físicos de radiancia (señal analógica original).

Los valores numéricos son almacenados a bordo del satélite para su posterior emisión cuando el mismo se encuentre dentro de zona de cobertura de las estaciones de seguimiento, o transmitidos inmediatamente a la red de antenas receptoras o a otros satélites.

En suma, el sensor convierte una señal analógica (la radiancia recibida) en un valor digital. El número y características de los detectores que incorpora un equipo de barrido es muy importante para explicar las condiciones de la imagen resultante. La señal enviada por el equipo óptico a estos detectores se muestrea a intervalos regulares. Ese intervalo marca el tamaño de la unidad mínima de información adquirida por el sensor que se denomina pixel. La señal detectada por cada pixel está en íntima relación con el tipo de cubierta observada.

Los exploradores de barrido multispectral permiten detectar la misma superficie de terreno en distintas bandas del espectro. La ventajas principales de estos equipos en relación con los sensores fotográficos son:

- Permiten ampliar la banda del espectro detectada a las longitudes de onda mayores del visible.
- Mayor flexibilidad en la calibración y en la corrección radiométrica de los datos.
- Posibilidad de realizar coberturas sistemáticas, y de grandes espacios, gracias a su capacidad de transmitir datos en tiempo real.
- Grabación digital de la información que asegura su fiabilidad y permite su tratamiento asistido por computadora.

Entre sus inconvenientes destacan: su menor resolución espacial y la exigencia de contar con equipos de tratamiento más complejos para su corrección y tratamiento.




Figura 2.4 – Diagrama de un explorador de barrido.

#### 2.4.1.2.2 Exploradores de empuje.

Con la puesta en órbita del satélite SPOT se ha introducido un nuevo sistema de exploración que prescinde del espejo oscilante. Consiste en una serie de detectores CCD (*Charge Coupled Device*) que se disponen en línea, de modo que abarquen todo el campo de visión. Las líneas de detectores se van excitando con el movimiento del satélite, técnica que se conoce con la denominación de *push broom*.

Estos sistemas aumentan la resolución espacial del sensor, pues al eliminar partes móviles minimizan el error introducido por la falta de sincronía entre el movimiento de éstas y el de la plataforma. Además, se gana en rapidez, por cuanto el flujo de datos no se realiza pixel a pixel sino línea a línea.

Por el contrario, presentan el inconveniente de la dificultad en la calibración de sus distintas cadenas de detectores debido al aumento notable en su número, para que entre todas mantengan los mismos coeficientes de conversión de radiancia a escala digital.

Otro problema no resuelto en estos sistemas es el ampliar la información espectral que proporcionan, incluyendo el infrarrojo medio y térmico. Hasta el momento se han diseñado equipos mono y multispectrales, limitados al espectro visible e infrarrojo reflejado. El trabajo en el térmico resulta más complejo por el tipo de detectores que precisa, muy sensibles al calor y de difícil calibración.




Figura 2.5 – Diagrama de un explorador por empuje.



### 2.4.1.2.3 Cámaras de vidicon.

Las *cámaras de vidicon* son dispositivos formadores de imágenes parecidos a las cámaras convencionales de TV. Su funcionamiento está basado en el mismo principio que los CCD; esto es, en láminas de material transparente capaz de modificar su conductividad eléctrica proporcionalmente a la intensidad de radiación que reciba. Los cambios de conductividad a través de la placa regulan el paso de los electrones procedentes de un chorro, que se dirige hacia ella, siendo éstos finalmente convertidos en señal de video. Muy utilizados en las primeras misiones LANDSAT estos dispositivos han sido hoy día reemplazados por el resto de los sensores.

En estos sistemas, la señal de la cámara se derivaba de la porción no utilizada del haz de electrones, que retornaba a lo largo de la misma trayectoria que el rayo incidente y era amplificado electrónicamente. Esto permitió mejorar la resolución espacial de los equipos de barrido y del vidicon convencional.

Más reciente resulta el empleo de las cámaras de video digital como fuente de imágenes en proyectos de gran escala. La videografía se define así como una nueva técnica de percepción remota, ya sea para calibrar las imágenes de satélite o para obtener información de detalle a bordo de globos o aviones de baja altura.




Figura 2.6 – Diagrama de un sistema Vidicon.

### 2.4.1.2.4 Radiómetros de Microondas.

Los radiómetros de microondas son sensores que miden la intensidad radiante en la región espectral de las microondas es decir, entre 1 y 100 mm. Ello hace posible su utilización en condiciones de nubosidad o falta de iluminación. Constan de un sistema de recepción direccional, capaz de recibir y amplificar la señal, y de un detector. La resolución de estos sistemas es directamente proporcional al diámetro de apertura de la antena receptora e inversamente proporcional a la longitud de la onda explorada. Por esta razón se requieren antenas de grandes proporciones para asegurar una resolución aceptable.

Un uso específico en el que los radiómetros de microondas han mostrado gran rendimiento es en la cartografía de las zonas polares, cuya reflectividad en el visible dificulta la observación en esta zona del espectro electromagnético. Sin embargo, las bajas temperaturas características de los círculos polares desplazan los máximos de emisión de radiación, según la ley de Wien, hacia longitudes de onda más largas.

### 2.4.2 Sensores Activos.

Este tipo de sensores son capaces de emitir su propio haz de energía y, por lo tanto, permiten una mayor flexibilidad puesto que no dependen de las condiciones exteriores al sistema sensor-Tierra.

#### 2.4.2.1 Radar.

El radar es un sistema activo que emite pulsos de energía electromagnética de longitud de onda comprendida entre 1 mm y 1 m, y mide la radiación reflejada por la superficie a estudiar. El sistema consiste en un generador de pulsos electromagnéticos que, por un lado, controlan la emisión de energía desde el transmisor, y por otro, accionan un registro en película.

Una misma antena emite el pulso de radar respuesta del terreno. Un conmutador electrónico denominado *duplicador* evita la interferencia entre ambos tipos de pulsos. El receptor es un dispositivo amplificador de las señales captadas por la antena. El pulso recibido, que contiene la información sobre el terreno, puede ser visualizado mediante un tubo de rayos catódicos, y ser registrado sobre una película o sobre cinta magnética en formato digital. En el rango de longitudes de onda propias del radar no existe prácticamente ninguna banda de absorción del agua, lo que hace este sistema muy adecuado para el estudio de las zonas tropicales, normalmente cubiertas por masas nubosas que impiden su detección remota en otras bandas. Una modalidad muy utilizada de los sistemas de radar es el radar lateral aerotransportado, denominado SLAR (*Side Looking Airborne Radar*).

La resolución de este tipo de sistemas puede estimarse calculando el tamaño del menor objeto identificable:

$$R_r = \frac{\lambda}{\phi} H$$

donde:  $\lambda$  es la longitud de onda,  $\phi$  el diámetro de apertura y  $H$  la altura de la observación.

En general, la resolución de los sistemas de radar es baja, necesiándose antenas de grandes proporciones, lo que limita su utilización en plataformas aéreas y, sobre todo, en las orbitales. Para paliar la dificultad que supone la gran altura a la que opera el satélite, se ha ideado el radar de apertura sintética SAR (*Synthetic Aperture Radar*). Éste es un sistema formador de imágenes de radar de alta resolución acimutal, basado en el efecto Doppler que, mediante la composición de los pulsos emitidos hacia un punto de la superficie terrestre desde dos posiciones diferentes de la trayectoria del satélite, permite emular una antena de gran apertura, similar a la distancia existente entre las dos posiciones sucesivas de aquél.

#### 2.4.2.2 LIDAR (*Light Detection and Ranging*).

El lidar es un sistema activo fundamentalmente destinado al estudio de la atmósfera que se caracteriza por la emisión de pulsos de luz polarizada entre el ultravioleta y el infrarrojo próximo mediante un sensor láser. El efecto producido como consecuencia de la interacción atmosférica es recogido a través de un sistema óptico por una célula fotoeléctrica. La señal eléctrica generada es almacenada para su posterior estudio por ordenador.

Existen sistemas de lidar específicos para cada tipo de dispersión atmosférica, por lo que mediante ellos se puede caracterizar la composición en aerosoles de la atmósfera y la cantidad de contaminantes sólidos, así como establecer medidas de la temperatura, humedad y presión del aire y una estimación de la velocidad del viento.

### **2.5 Características de los datos en la Percepción Remota.**

Los datos adquiridos mediante procedimientos de Percepción Remota desde aviones o naves espaciales comprenden siempre tres tipos de informaciones:

1. **Una información espacial**, que representa la organización en el espacio físico de los elementos que constituyen la imagen.
2. **Una información espectral**, que caracteriza y puede conducir al conocimiento de la naturaleza de la superficie de la Tierra.
3. **Una información temporal**, que permite detectar los cambios operados en la superficie de la Tierra con el transcurso del tiempo.

La información elemental que proporciona la percepción remota es el pixel (contracción de "*pictural element*"). La signatura espectral de un pixel se puede considerar como una respuesta que integra la de cada uno de los tipos de cubierta presentes multiplicada por su fracción de área correspondiente. Es decir, la signatura espectral de un pixel será normalmente función de una mezcla de objetos en proporciones desconocidas que tienen a su vez signaturas distintas aunque sean más o menos parecidas.

Las diferencias locales se diluirán en la respuesta promedio y este efecto crea una ilusión sobre la existencia de zonas de transición y zonas de contacto gradual entre distintas unidades de paisaje. Este efecto no se manifiesta cuando existe un contraste brusco entre dos usos del suelo contiguos, por ejemplo un movimiento de tierras reciente en el interior de un bosque cerrado.

La existencia de un contraste brusco puede permitir observar en una imagen objetos cuyas dimensiones sean inferiores a las de un pixel.

La absorción atmosférica tiene un efecto parecido de homogeneización, que varía en función de la longitud de onda, disminuyendo en líneas generales dicho efecto a medida que aumenta la longitud de onda.

En definitiva según TRICART (1979) los datos adquiridos a través de percepción remota se caracterizan por las propiedades siguientes:

- ✓ Permiten obtener información sobre aspectos del medio natural que escapan totalmente a nuestros sentidos. La experiencia "natural" del hombre es, por lo tanto, nula en los dominios espectrales que manejan los sensores remotos y por esta razón se realizan "visualizaciones" que tienen un aspecto análogo a las fotografías aéreas y que se denominan imágenes para evitar la confusión.
- ✓ Estas informaciones que son registradas por los sensores y que miden la cantidad de energía reflejada o emitida por los objetos naturales o antropógenos que componen el paisaje son de tipo numérico y se prestan a los tratamientos matemáticos.

Por otra parte su extremada abundancia obliga a emplear grandes computadoras y métodos de tratamiento de datos muy sofisticados y potentes.

- ✓ Los datos de percepción remota nos revelan ciertos aspectos de los ecosistemas difíciles de estudiar contribuyendo de una forma eficaz al conocimiento de los mismos y de su funcionamiento. (detección de enfermedades en las plantas, efectos del "stress" debido a la falta de agua por transpiración, régimen térmico, etc.)
- ✓ La percepción remota permite seguir la evolución de las grandes extensiones forestales que persisten en la superficie del globo, tener una visión de conjunto sobre los efectos producidos por las grandes catástrofes.

## 2.6 Energía Electromagnética.

Energía electromagnética se refiere a la energía que se extiende con la velocidad de la luz en una forma ondulatoria armónica. La forma ondulatoria armónica se caracteriza por ondas que ocurren en intervalos de tiempo iguales. El concepto ondulatorio explica la propagación de la energía. Solamente la energía, que interactúa con la materia puede ser detectada. En la interacción entre energía y materia, la energía electromagnética se comporta como si se constituyese de muchos cuerpos individuales, llamados fotones, que parecen partículas. La refracción de la luz, que transmite por medios ópticos de diferente densidad óptica (de diferentes índices de refracción) se explica por el comportamiento ondulatorio de la luz.

El concepto de los fotones se emplea por ejemplo para explicar la medición de la intensidad de la luz por un fotómetro. Mediante la medición de la intensidad de la luz por un fotómetro, la interacción de los fotones con un detector sensible a la luz (fotosensible) produce una señal eléctrica, que varía en su intensidad proporcionalmente a la cantidad de los fotones.

### 2.6.1 Propiedades de las ondas electromagnéticas.

Las ondas electromagnéticas se describen por medio de los parámetros: *velocidad, longitud de onda y frecuencia.*

Las ondas electromagnéticas se propagan con la velocidad de la luz en el vacío  $c = 2,9979246 \times 10^8 \text{ m/s} = 299,79246 \text{ km/s} = \text{aprox. } 300,000 \text{ Km/s.}$

La longitud de onda de ondas electromagnéticas es la distancia entre cualquier punto de un ciclo de la onda y el punto con la misma posición en el ciclo sucesivo de la onda (entre dos puntos idénticos sucesivos de la onda). La longitud de onda se expresa por micrómetros ( $1 \mu\text{m} = 10^{-6} \text{ m}$ ) o por nanómetro ( $1 \text{ nm} = 10^{-9} \text{ m}$ ).

Frecuencia  $f$  se define como la cantidad de dorsos de ondas por tiempo. La frecuencia antiguamente fue expresada por ciclos por segundos, hoy día su unidad es Hz = hertz.

La ecuación siguiente relaciona la velocidad con la longitud de onda  $\lambda$  y con la frecuencia de la onda electromagnética  $f$ :  $c = \lambda \times f$ .

Temperatura se expresa en °C o en °K,  $273^\circ\text{K} = 0^\circ\text{C}$  o  $0^\circ\text{K} = -273^\circ\text{C}$ .

### 2.6.2 Procesos de interacción entre la energía electromagnética y la materia.

Energía electromagnética que interactúa con materia sólida, líquida o gaseiforme se denomina radiación incidente. Los procesos de interacción entre materia y energía eléctrica pueden causar cambios en las propiedades siguientes de la radiación incidente:

□ *intensidad, dirección, longitud de onda, polarización, fase.*

Por el método de percepción remota se detectan y graban estos cambios. Al interpretar las imágenes y los datos-resultados se puede determinar las características de la materia en que incidió la energía electromagnética. Los procesos de interacción entre la energía electromagnética y la materia se describe por sus resultados. La radiación incidente puede ser:

**Transmitida:** La energía electromagnética pasa por la sustancia. La transmisión por medios de diferente densidad, como por ejemplo desde el aire al agua, causa un cambio de la velocidad de la radiación electromagnética. La razón de las dos velocidades correspondientes a los dos medios se llama índice de refracción y se la expresa por:  $n_s = c_0/c_s$ , donde  $c_0$  es la velocidad de la radiación electromagnética en el vacío y  $c_s$  es su velocidad en la sustancia  $s$ .

**Absorbida:** La radiación incidente cede su energía en grandes partes para calentar la sustancia, en que incide.

**Emitida:** La radiación es emitida por la sustancia, generalmente en forma de longitudes de onda más largas y en función de su estructura y su temperatura.

**Esparcida o 'scattered':** La radiación incidente es emitida y esparcida en todas las direcciones. 'Scattering' o esparcimiento se produce por superficies con cierto relieve o rugosidad comparable con la longitud de onda de la energía incidente. Por ejemplo, ondas de luz sufren esparcimiento por moléculas o partículas de la atmósfera, cuyos tamaños son parecidos a las longitudes de onda de luz.

**Reflejada:** La energía incidente regresa desde la superficie de la sustancia formando un ángulo con la normal a la superficie igual al ángulo de incidencia. Superficies relativamente planas con respecto a la longitud de onda de la energía incidente pueden causar la reflexión. Además la polarización, es decir, la dirección de oscilación de la energía reflejada puede variar con respecto a la energía incidente.

La emisión, el esparcimiento y la reflexión principalmente son determinados por las propiedades de la superficie, en que inciden, como su color o su rugosidad. A estos procesos de interacción se llama *fenómenos superficiales*. Los procesos de interacción, que son determinados por las propiedades internas de la materia como la transmisión y la absorción, son los *fenómenos de volumen*. La combinación distinta de interacciones superficiales y de volumen con cualquier sustancia depende de la longitud de onda de la radiación incidente y de las propiedades de la sustancia.

### 2.6.3 El Espectro Electromagnético.

El espectro electromagnético describe la sucesión continua de energía, de longitudes de ondas de metros a nanómetros. La energía se extiende con la velocidad de la luz. Toda la materia emite un rango de energía electromagnética.

Si la temperatura de la materia se aumenta, el máximo de intensidad de la energía emitida se caracteriza por longitudes de onda relativamente cortas en comparación a temperaturas más bajas.

Aunque la sucesión de valores de longitud de onda es continua, suelen establecerse una serie de bandas en donde la radiación electromagnética manifiesta un comportamiento similar. La organización de estas bandas de longitudes de onda o frecuencia se denomina espectro electromagnético.

Comprende desde las longitudes de onda más cortas (rayos gama, rayos X), hasta las kilométricas (telecomunicaciones). Las unidades de medida más comunes se relacionan con la longitud de onda.

**2.6.3.1 Regiones de longitudes de ondas y bandas.**

El espectro electromagnético se extiende desde las longitudes de onda muy cortas de la región de rayos gamma (medido en partes de nm) a las longitudes de onda largas de la región radioeléctrica (medido en m). El espectro visible ocupa las longitudes de onda entre 0.4 y 0.7  $\mu\text{m}$  aproximadamente. La energía reflejada por la Tierra durante el día se puede presentar en función de la longitud de onda, el máximo energético es reflejado con longitudes de onda alrededor de 0.5  $\mu\text{m}$  que corresponde a las longitudes de onda de color verde y que se llama alto de energía reflejada (*reflected energy peak*). Además la Tierra emite energía, cuyo máximo se caracteriza por longitudes de onda de 9.7  $\mu\text{m}$ . Este alto de energía radiante corresponde a la parte térmica de la región infrarroja.

La atmósfera absorbe energía en las regiones de los rayos gamma y de los rayos X y en la mayor parte de la región ultravioleta. Por esto, en la percepción remota no se utiliza estas regiones del espectro electromagnético. En la percepción remota terrestre se detectan las regiones de las microondas, visible e infrarroja y las longitudes de onda largas de la región ultravioleta. Intervalos de longitudes de onda caracterizados por una transmisión alta por la atmósfera terrestre se llaman **ventanas atmosféricas** y se les utiliza en la percepción remota para la toma de imágenes. Las regiones principales se subdividen en bandas, como las bandas: azul, verde y roja de la región visible.




Figura 2.7 -- Espectro Electromagnético.

## 2.6.3.2 Características de los distintos intervalos espectrales.

Región	Longitud de onda	Características de los intervalos espectrales
Rayos gammas	< 0,03 nm	Radiación incidente en la Tierra es absorbida completamente por la atmósfera superior, no adecuado para la percepción remota.
Rayos X	0,03 - 30 nm	Completamente absorbidos por la atmósfera, no empleados en percepción remota.
Región ultravioleta	0,03 - 0,4 $\mu\text{m}$	Longitud de onda < 0,3 $\mu\text{m}$ incidente es absorbida completamente por el ozono en la atmósfera superior.
Banda ultravioleta fotográfica	0,3 - 0,4 $\mu\text{m}$	Transmitida por la atmósfera, detectada por rollos y fotodetectores, a menudo esparcimiento atmosférico.
Espectro visible	0,4 - 0,7 $\mu\text{m}$	Grabado por rollos y fotodetectores, incluye el máximo de la energía reflejada por la Tierra a longitud de onda = 0,5 $\mu\text{m}$ .
Región infrarroja	0,7 - 100 $\mu\text{m}$	Interacción con la materia, varía con la longitud de onda, las ventanas de la transmisión atmosférica están separadas por bandas de absorción.
Banda infrarroja reflejada	0,7 - 3,0 $\mu\text{m}$	Radiación solar reflejada, no contiene informaciones acerca de las propiedades térmicas de materia, el intervalo de 0,7 a 0,9 $\mu\text{m}$ se llama banda infrarroja fotográfica y es detectado por rollos.
Banda térmica infrarroja	3 - 5 $\mu\text{m}$ , 8 - 14 $\mu\text{m}$	Ventanas atmosféricas principales de la región térmica, las imágenes de estas longitudes de onda se obtiene por scanners ópticos, mecánicos y vidicons especiales.
Región de microondas	0,1 - 100 cm	Penetran por nubes, neblina, lluvia, imágenes se obtiene por sistemas de barrido activos y pasivos.
Radar	0,1 - 100 cm	Forma activa de percepción remota utilizando las microondas, imágenes de radar.
Radio	> 100 cm	Partes más largas del espectro electromagnético.

Tabla 2.1 – Características de los intervalos espectrales.

## 2.7 Aplicaciones de los Sistemas de Percepción Remota.

Existe un sinnúmero de aplicaciones para las imágenes satelitales. Estos productos son una fuente global de recursos para los gobiernos, las empresas y los ciudadanos particulares. La exquisita riqueza de información que se puede extraer de la siempre cambiante faz de la Tierra, tanto en sus aspectos naturales como culturales, proporciona una nueva dimensión visual de análisis que permite comprender en profundidad los fenómenos del cambio económico, como afectamos el medio ambiente y como nos proyectamos hacia el futuro.

**Geología.**

- Reconocimiento de tipos de roca.
- Cartografía de zonas geológicas.
- Revisión de mapas geológicos.
- Delineación de rocas y suelos no consolidados.
- Cartografía de intrusiones ígneas.
- Cartografía de depósitos de recientes superficies volcánicas.
- Búsqueda de guías de superficie para mineralización.
- Determinación de estructuras regionales.
- Cartografías lineales.

**Agricultura y Bosques.**

- Discriminación de tipos de vegetación: tipos de cultivos, tipos de madera, etc.
- Determinación de la vegetación activa (proceso de creación de clorofila).
- Medición de extensión de cultivos y maderas por especies.
- Clasificación de usos del suelo.

**Recursos Hidrográficos.**

- Determinación de límites, áreas y volúmenes de superficies acuáticas.
- Cartografía de inundaciones.
- Determinación del área y límites de zonas nevadas.
- Medida de regiones glaciales.
- Medida de modelos de sedimentación y alteraciones.
- Determinación de la profundidad del agua.
- Delineación de campos irrigados.
- Clasificación de lagos.
- Detección de zonas de alteraciones hidrotermales.

**Cartografía y Planeamiento Urbanístico.**

- Cartografía y actualización de mapas.
- Clasificación de la fertilidad de la tierra.
- Clasificación de zonas urbanas y rurales.
- Planificación regional.
- Cartografía de redes de transporte.
- Cartografía de límites tierra-agua.
- Cartografía de fracturas.

**Meteorología.**

- Predicción de desastres naturales de origen climático.
- Análisis de masas nubosas y su evolución.
- Modelización climática a diferentes escalas.



**Medio Ambiente.**

- Control de superficies mineras.
- Cartografía y control de contaminación de aguas.
- Detección de contaminación del aire y sus efectos.
- Determinación de efectos de desastres naturales.
- Control medioambiental de actividades humanas.
- Seguimiento de incendios forestales y sus efectos.
- Estimación de modelos de erosión.


**Oceanografía y Recursos marítimos.**

- Detección de organismos marinos vivos.
- Determinación de modelos de alteración y circulación.
- Cartografía térmica de la superficie del mar.
- Cartografía de cambios en límites de las costas.
- Cartografía de costas y áreas superficiales.
- Cartografía de hielos para navegación.
- Estudio de mareas y olas.

---

# CAPÍTULO 3

## SATÉLITES Y CAPTORES



*Para mejorar aún más las futuras imágenes de la Tierra desde el espacio, se lanzó una nave espacial muy particular, denominada Earth Observing-1 (EO-1), en octubre del año 2000. EO-1 está probando algunos instrumentos nuevos muy avanzados. Uno de ellos, denominado el **Hiperión**, es muy sensible a minúsculas diferencias en los colores.*

### 3.1 Introducción.

El advenimiento de los satélites artificiales ha permitido la posibilidad de obtener información detallada de la superficie terrestre. Desde el lanzamiento en 1972 del ERTS-1 (más tarde renombrado Landsat 1), el primer satélite diseñado para la observación en alta resolución de la cubierta terrestre, la teledetección ha alcanzado un alto nivel de desarrollo, beneficiándose de los avances obtenidos en la carrera espacial y desligándose de la fotografía aérea, precursora de la moderna teledetección.

Hoy en día, sensores instalados en satélites nos envían continuamente información sobre la dinámica nubosa, la cubierta vegetal y sus variaciones estacionales, la temperatura superficial oceánica, etc. Incluso eventos de gran escala temporal como las cubiertas de hielo polar, la expansión de los desiertos o la deforestación tropical pueden ser estudiadas exhaustivamente y de manera continua a partir de datos procedentes de sensores situados en el espacio.

Existen múltiples tipos de satélites, de características muy diversas que pueden clasificarse atendiendo a múltiples criterios. Las características del satélite determinan, fundamentalmente, la periodicidad de la observación (resolución temporal) y en menor medida la resolución espacial de las observaciones.

Atendiendo al criterio de la misión, pueden clasificarse como misiones esporádicas y permanentes o semipermanentes.

- **Misiones esporádicas (sistemas tripulados) :** Aviones, Helicópteros, Naves espaciales.
- **Misiones permanentes o semipermanentes:** Órbita polar, Órbita Geoestacionaria.

En la actualidad, gran parte de los esfuerzos están enfocados al procesamiento y compresión de los datos procedentes de los satélites. Que orbitan la tierra, tales como: LANDSAT, SPOT, IKONOS, ERS, NOAA, etc.

#### 3.1.1 Satélites geoestacionarios.

Los satélites geoestacionarios, también llamados *geosíncronos*, se encuentran colocados en órbitas muy altas, lo que les permite sincronizarse al movimiento de rotación de la tierra y observar siempre la misma zona. Además, al contar con un campo amplio de visión pueden observar, en una sola imagen, el disco completo de la tierra que sea visible desde la longitud a la que se encuentren. Al estar situados sobre la misma posición relativa a la tierra, los satélites geoestacionarios proporcionan la mejor resolución temporal posible.

Este tipo de satélites están ubicados a una distancia cercana a los 35,800 Km. (22,300 millas) del Ecuador terrestre. En la actualidad hay activos varios satélites meteorológicos situados en una órbita geoestacionaria. Tal es el caso de los satélites Meteosat o GOES.

#### 3.1.2 Satélites heliosíncronos.

Se trata de satélites que observan sistemáticamente distintas zonas del planeta. Aunque la órbita puede ser elíptica, lo normal es que sea circular, a fin de mantener en lo posible la misma altura de observación para que las imágenes obtenidas sean comparables. Estas órbitas suelen ser polares, es decir, el plano de la órbita del satélite es aproximadamente perpendicular al plano del

Ecuador terrestre. Esto, con el fin de que el satélite se sitúe sobre un mismo punto cada cierto tiempo. Si la tierra rota de Oeste a Este, y el satélite orbita de Norte a Sur de manera constante, esta podrá observar el mismo punto de la tierra transcurrido un tiempo que dependerá de la velocidad y la altura de la órbita. Habitualmente, tanto la altura como la velocidad del satélite se calculan para que esta observe cada porción de la tierra a una hora solar fija.

La elección de la órbita que ocupará un satélite viene determinada por las características de la misión: si se pretende tomar datos de una gran superficie en una sola imagen a fin de observar fenómenos globales y muy dinámicos (como la nubosidad), se trabaja con satélites geoestacionarios (o en todo caso, con satélites polares que cuenten con un amplio campo de visión). Por el contrario, si se pretende un mayor detalle en la observación, se utilizan satélites heliosíncronos.

### 3.1.3 Bandas utilizadas por los Satélites.


Dentro del espectro óptico, donde las longitudes de onda son milimétricas, se tiene la región de microondas que se divide en diferentes bandas utilizadas por los sistemas de radar, cuyos rangos se muestran a continuación en la *tabla 3.1*.

Denominación	Anchura (cm)		Valor Típico	Anchura (GHz)	
<b>Ka</b>	0.75	1.10			
<b>K</b>	1.10	1.67	1.0	10.90	36
<b>Ku</b>	1.67	2.40			
<b>X</b>	2.40	3.75	3.0	5.75	10.90
<b>C</b>	3.75	7.50	5.6	3.90	5.75
<b>S</b>	7.50	15.00	10.0	1.55	3.90
<b>L</b>	15.00	30.00	23.0	0.39	1.55
<b>P</b>	30.00	100.00	70.0	> 0.39	

*Tabla 3.1 - Bandas utilizadas por los sistemas de radar*

## 3.2 Satélite IKONOS

El satélite IKONOS es el primer satélite de tipo comercial que posibilita la captación de imágenes con un metro de resolución espacial. El término "IKONOS" proviene del griego y significa "imagen".



*Figura 3.1 - Satélite IKONOS.*

Estas imágenes son consecuencia directa de la liberación tecnológica promovida en 1994 por el gobierno de los Estados Unidos de América. Anteriormente a esa época esta tecnología estaba disponible para satélites con fines militares. IKONOS colecta información de cualquier área en promedio dos veces al día, cubriendo áreas de 20.000 km<sup>2</sup> en una misma pasada y produciendo como resultado imágenes de 1 metro de resolución cada tres días y de 2 m de resolución todos los días.

El satélite IKONOS pesa unos 720 Kg. y órbita la Tierra cada 98 minutos a una altitud de casi 680 Km. en forma sincronizada con el Sol, pasando sobre un determinado lugar aproximadamente a las 10:30 a.m. hora local. La órbita cubierta por el satélite se concentra lejos del área directamente debajo del recorrido del mismo, y los datos de un lugar determinado puede ser captados casi diariamente, si bien no en todos los casos con 1 m de resolución. El satélite fue diseñado y fabricado por la empresa Lockheed Martin Commercial Space Systems. La empresa Raytheon Company construyó los sistemas de apoyo terrestre, geoprocusamiento digital, manejo de archivos y servicio al cliente, requerido para distribuir la información captada por IKONOS.

El sensor digital de imágenes del satélite está diseñado para producir imágenes con elevado contraste, resolución espacial y precisión, brindando a los clientes un producto preciso y nítido. La compañía Eastman Kodak proveyó el mecanismo electro-óptico, incluyendo su ensamble con el telescopio óptico, los detectores y su ajuste al plano focal.

Incluyendo, asimismo, el mecanismo de procesamiento electrónico de alta velocidad basado en un diseño efectuado por Space Imaging. Resultando todo un suceso, las imágenes de alta resolución del satélite IKONOS son una grata realidad y están revolucionando el mercado satelital. Anteriormente, ningún satélite comercial logró conseguir un nivel de detalle semejante.

### **3.2.1 Principales características del satélite IKONOS.**

- Fecha de lanzamiento del satélite: 24.09.99
- Lugar de lanzamiento: Vandenberg Air Force Base, California /USA
- Altitud: 681 Km.
- Inclinación: 98.1°
- Velocidad: 7km/s
- Sentido de la órbita: descendente
- Duración de la órbita: 98 minutos
- Tipo de órbita: sinerónica con el sol
- Angulo de visada: rápida alternancia entre diferentes ángulos
- Tiempo de revista: 1 a 3 días
- Resolución en el terreno de cada banda:
  - Pancromática: 1m (considerando posición nominal de 26° para el nadir)
  - Multiespectral: 4m (considerando posición nominal de 26° para el nadir)
- Bandas espectrales:
  - Pan: 0.45 - 0.90  $\mu$ m
  - Azul: 0.45 - 0.52  $\mu$ m
  - Verde: 0.52 - 0.60  $\mu$ m
  - Rojo: 0.63 - 0.69  $\mu$ m
  - Infrarrojo próximo: 0.76 - 0.90  $\mu$ m
- Rango Dinámico: posibilita que la información sea almacenada en 11 bits por pixel, con lo cual redundante en un mayor rango dinámico que facilita el contraste y discriminación de la información. Este número de bits por pixel hace posible trabajar con paletas de 2048 tonos

reales de gris. A priori hay quien puede pensar que no es significativo, ya que los sistemas de visualización permiten mostrar 256 niveles, e incluso el ojo humano no es capaz de distinguir más. En resumen, se tiene 8 veces más información que en las imágenes tradicionales. Quizá para interpretación visual solo se a una buena ayuda, pero en estudios temáticos, toda esta información se convierte en una ventaja fundamental. No obstante, los productos pueden ser entregados al usuario en 8 bits por píxel.

Las siguientes tablas muestran: la información técnica resumida del satélite IKONOS (tabla 3.2) y las características de sus Bandas espectrales (tabla 3.3).

Technical Summary	Satellite	Launch Date	End Mission	Altitude	Inclination	Sensors
	ikonos-1	lost on launch				
	ikonos-2	24-sep-99	operational	681 Km	98.1°	PAN, MS
Sensor	Band	Spectral range (µm)	Pixel Size (m)	Quantization	Swath width	
PAN	1	45 - 90	1	11 bit	11 Km	
MS	1 (blue)	45 - 53	4	11 bit	11 Km	
	2 (green)	52 - 61				
	3 (red)	64 - 72				
	4 (VNIR)	77 - 88				

Tabla 3.2 - Información técnica resumida del satélite IKONOS.

Banda	Inferior 50% (nm)	Superior 50% (nm)	Ancho de Banda (nm)	Central (nm)
Pan	525.8	928.5	403	727.1
MS-1 (azul)	444.7	516.0	71.3	480.3
MS-2 (verde)	506.4	595.0	88.6	550.7
MS-3 (rojo)	631.9	697.7	65.8	664.8
MS-4 (VNIR)	757.3	852.7	95.4	805.5

Tabla 3.3 - Bandas espectrales del satélite IKONOS.




Figura 3.2 - Respuesta espectral relativa, satélite IKONOS.


TESIS CON FALLA DE ORIGEN

### 3.2.2 Cobertura.

El satélite Ikonos está equipado con un grabador interno que puede obtener datos de casi cualquier área de la superficie terrestre. Este grabador puede almacenar 64 Giga bits de datos (aproximadamente, 26 imágenes completas de datos de ambos sensores, PAN y MS).

El enlace de descarga de datos es hecha por las estaciones Fairbanks y Tromsøe, en posiciones óptimas gracias a su alta latitud. Además, una red de estaciones de recepción terrestre afiliadas a Space Imaging se han comenzado a construir para habilitar el enlace de la descarga de datos en muchas áreas. Actualmente, las estaciones completamente operativas son: Dubai (Space Imaging, medio este), Japón (Space Imaging, Japón) y Korea (Space Imaging, Asia), Ankara Turkey (Space Imaging, Euroasia).

*Ikonos Ground Station Network*



*Figura 3.3 - Red de estaciones terrestres de recepción del satélite IKONOS.*

### 3.2.3 Aplicaciones y ventajas de las imágenes IKONOS.

Las imágenes IKONOS están revolucionando actualmente las formas de utilización de los productos satelitales. Por el hecho de ser IKONOS el primer satélite comercial que brinda un producto de 1 m de resolución espacial, tenemos la posibilidad de definir los tipos de estándares para imágenes de alta resolución.

Actualmente es posible que:

- Los agricultores puedan monitorear con mayor precisión la condición y vitalidad de sus cultivos y predecir con mayor acierto sus volúmenes de cosecha; además, pueden prevenir problemas y ahorrar importantes sumas de dinero a través de su determinación en estados tempranos.
- Los científicos ambientalistas pueden predecir tendencias en áreas de elevada fragilidad ambiental.
- Los funcionarios de gobierno pueden monitorear, evaluar y planificar políticas de tipos específicos de utilización de la tierra.

- Los planeadores urbanísticos pueden evaluar los avances de planes comunales de viviendas y las compañías de seguros pueden medir y mapear daños a propiedades luego de desastres naturales.
- Los geólogos ya no necesitarán recurrir a vuelos fotográficos para interpretaciones geológico-estructurales. A partir de la posibilidad que ofrece IKONOS de generar productos con elevado nivel de resolución y recubrimiento estereoscópico, estas imágenes resultan comparativamente más ventajosas que las fotografías aéreas. Entre las ventajas merecen citarse:
  1. Mejor calidad métrica y geométrica ya que las fotografías aéreas originalmente no son productos geoméricamente corregidos. Con los productos de IKONOS es posible obtener una ortoimagen que cubra totalmente el área de interés, a partir de sólo unos pocos puntos de control terrestre, reduciendo así considerablemente el tiempo de procesamiento. Dichos puntos de control pueden seleccionarse a partir de información precisa ya existente (intersección de caminos, líneas sísmicas, pozos de petróleo, obras de infraestructura, etc.).
  2. No requieren procesos de mosaicos
  3. Mantienen uniformidad de tonalidades y contraste relacionadas con la estabilidad de las condiciones atmosféricas durante el período de captura del satélite.
  4. Posibilitan la visualización e interpretación estereoscópica tradicional, más la posibilidad de realizar estéreo análisis digital
  5. A diferencia de las fotografías aéreas, no requieren superposición lateral con lo cual se optimiza el costo de los pares, a la vez que se facilita el manejo de los mismos y la consecuente interpretación.
  6. La interpretación estereoscópica digital facilita el relevamiento y la integración de la información en una base de datos georreferenciada, posibilitando la superposición y el modelado espacial.
  7. Permite la utilización de diferentes combinaciones de bandas espectrales, incluyendo productos en infrarrojo, lo que aumenta considerablemente las capacidades de diferenciación y discriminación.
  8. Resultan más versátiles y menos costosas en el momento de extracción de información mediante procesamientos digitales, tanto con filtrados direccionales para detección de estructuras, como clasificaciones o relaciones de bandas orientadas a discriminación litológica.

Posibilitan la obtención de cartografía de alta calidad en diferentes escalas y combinaciones de bandas, a partir de composiciones de mapas que incluyen diferentes capas temáticas superpuestas, símbolos cartográficos, leyendas, etc.

### **3.3 Satélites LANDSAT**

El programa LANDSAT, desarrollado por la National Aeronautics and Space Administration-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.

De la serie LANDSAT ya fueron lanzados los siguientes satélites:

SATÉLITES DE LA SERIE LANDSAT			
SATÉLITE	LANZAMIENTO	FIN OPERACIÓN	SISTEMAS SENSORES
ERTS-1	23 /Julio/ 1972	05 /Enero/1978	MSS e RBV
LANDSAT-2	22 /Enero / 1975	27/Julio/1983	MSS e RBV
LANDSAT-3	05 /Marzo / 1978	07/Septiembre/1983	MSS e RBV
LANDSAT-4	16 /Julio / 1982	fin de 1983	MSS e TM
LANDSAT-5	01 /Marzo / 1984	en operación	MSS e TM
LANDSAT-6	03 /Octubre / 1993	03/octubre/1993	ETM
LANDSAT-7	Abril / 1999		ETM y HRMSI

*Tabla 3.4 - Satélites del Programa LANDSAT.*

Los tres primeros satélites LANDSAT tenían una fisonomía muy similar, con unas dimensiones aproximadas de 3 metros de altura por 1.5 metros de diámetro, que se convertían en 4 metros cuando se extendían los paneles solares. El peso total del sistema rondaba los 960 Kg.

La USGS (U.S. Geological Survey's) a través de la EDC (EROS Data Center) ha administrado los archivos de datos del LANDSAT por más de dos décadas. Estos contienen una amplia información sobre la superficie terrestre.

A continuación se describirán los satélites que componen la serie LANDSAT, dando una descripción de las características más importantes de los instrumentos sensores que los acompañan.

### 3.3.1 LANDSAT 1, 2 y 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 920 Km. Durante su período de operación, los satélites LandSat realizaban una órbita completa alrededor de la Tierra cada 103 minutos y 27 segundos, recubriendo 14 fajas 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.




Figura 3.4 - Satélites LANDSAT 1, 2 y 3.

Estos tres satélites llevaban a bordo dos sistemas sensores:

### 3.3.1.1 Sistema RBV (*Return Beam Vidicon*).

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 LANDSAT 1 y 2 y dos en el LANDSAT 3), operaba en una faja 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 LANDSAT 1 y 2 era de 80 x 80 m, con tres bandas espectrales (verde, rojo e infrarrojo próximo) y en el LANDSAT 3 era de 40x40 m, con una banda espectral (pancromático).

SATÉLITE	CÁMARAS	FAJA ESPECTRAL ( $\mu\text{m}$ )	APLICACIONES
Landsat 1 y 2	1	0,475-0,575 (verde)	Diferenciación entre suelo y vegetación
	2	0,580-0,680 (rojo)	Mapeamiento de vegetación
Landsat 3	3	0,690-0,830 (rojo)	Delineamiento de cuerpos de agua.
	1	0,505-0,750 (pancromático)	Mapeamiento de áreas urbanas, vegetación, agricultura.

Tabla 3.5 - Características espectrales y aplicaciones del sistema RBV.

Los dos primeros satélites Landsat incorporaron un sistema de 3 cámaras RBV, cada una de las cuales registraba información en una banda espectral comprendida entre el verde y el infrarrojo cercano.

Este sistema no funcionó adecuadamente en los dos primeros Landsat, por lo que fue sustituido en el tercero por otro. En este caso, el planeamiento se dirigió más a mejorar la resolución espacial que la espectral, por lo que se montaron dos cámaras pancromáticas de alta resolución, operando simultáneamente con el MSS. Estas cámaras cubrían un abanico espectral de 0.505 a 0.705  $\mu\text{m}$  proporcionando, en cuatro adquisiciones, la misma cobertura del MSS pero con una resolución aproximada de 40m.

El registro entre ambas permitió utilizar el RBV como auxiliar del MSS, especialmente para mejorar la calidad visual de sus imágenes. Para ello se emplearon diversas técnicas de fusión, como la normalización de las bandas MSS a partir de la proporcionada por RBV o la transformación IHS.

En el campo de las aplicaciones temáticas, el RBV se ha utilizado en estudios morfológicos y en la cartografía de la cubierta del suelo, si bien la escasa pervivencia de este sensor ha reducido sensiblemente su rango de aplicaciones.

**3.3.1.2 Sistema MSS (Multispectral Scanner Subsystem - Generador de Imágenes Multiespectrales).**

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 barrido óptico electrónico, que opera en cuatro fajas del espectro electromagnético, dos en el visible (canales 4 y 5) y dos en el infrarrojo próximo (canales 6 y 7). La franja terrestre observada por este sensor representaba un área de 185 Km. Divididos a ambos lados de la vertical de la traza y la resolución espacial era de 80 x 80 m. Su campo total de visión es de 11.56 grados. En el LANDSAT 3 fue agregado un canal en la faja del infrarrojo termal (canal 8), cuya resolución era de 240m, que captaba la radiación emitida por los objetos terrestres.

SATÉLITES	BANDAS	FAJAS ESPECTRALES ( $\mu\text{m}$ )	APLICACIÓN
Landsat 1, 2, 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 3.6 - Características espectrales y aplicaciones del sistema MSS.*

En definitiva, el MSS ha sido el sensor más empleado hasta el momento gracias a la larga serie de imágenes disponibles desde 1972 hasta el día de hoy. En el diseño del sensor MSS se tuvieron en cuenta las medidas espectrales de laboratorio, de tal forma que las 4 bandas finalmente incluidas pretendían realzar la aplicación de este sensor a la detección de masas vegetales, recursos hídricos y mineros.

Con el objeto de acoplar la secuencia de barrido a la velocidad del satélite, el sensor MSS registra seis líneas simultáneamente con cada oscilación del espejo. La radiancia recibida por el sistema focal se transmite a un sistema óptico que la descompone en 4 bandas y la envía a distintos detectores. Por lo tanto, el MSS dispone de 24 detectores (6 líneas \* 4 bandas), compuestos por fotodiodos de silicio (banda 7) y por tubos foto-multiplicadores (bandas 4 a 6). En el caso del Landsat 3, se añadió una banda térmica (banda 8) registrada por detectores de mercurio-cadmio-telurio.

Las señales analógicas que producen los detectores son amplificadas, convertidas a formato digital y enviadas directamente a las estaciones receptoras desde donde se inicia la distribución de las imágenes.

Cuando el satélite no se encontraba en el área de influencia de alguna antena terrestre, los primeros Landsat incorporaban un sistema de grabación denominado WBVTR (*Wide Band Video Tape Recorders*), que permitió adquirir imágenes de estas áreas. En los dos últimos satélites, el flujo de información es tan grande que requieren una red de satélites de comunicación (TDRSS) para enviar a la tierra las imágenes detectadas. Esto ha impulsado el establecimiento de una red de antenas receptoras que hoy cubren, prácticamente, la superficie terrestre. Los actuales MSS codifican las cuatro bandas entre 0 y 255, la medida estándar en un equipo de tratamiento digital.

### 3.3.2 LANDSAT 4 y 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 920 Km. para 705 Km., el ciclo de recubrimiento pasó de 18 días para 16 días, y el periodo orbital pasó de 103 minutos para 98,9 minutos. El horario medio de pasaje por el Ecuador continuó siendo 09:30, horario local.




Figura 3.5 - Satélites LANDSAT 4 y 5.

### 3.3.2.1 Sistema TM (Thematic Mapper).

Tal como su antecesor (el MSS), es un sensor de barrido multispectral 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 en relación al sensor MSS. 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 120 metros en la banda del infrarrojo termal. La escena terrestre registrada por este sensor es también de 185 Km.

Frente al MSS, el TM aumenta el número de detectores de 24 a 100, a la vez que se reduce el IFOV, se aumentan los niveles de codificación y se realiza el barrido en las dos direcciones. En el TM, cada oscilación en el espejo supone 16 líneas de barrido, frente a 6 en el MSS. De esta forma se precisan 16 detectores por banda, salvo la banda térmica que registra una menor resolución (120 m) y solo requiere 4 detectores. Este aumento en el número de detectores complica el proceso de calibración, a la par que aumente el volumen de datos a procesar en comparación con el MSS. Los detectores están formados por tubos de silicio, para las bandas 1 a 4, indio-antimonio para las bandas 5 y 7, y mercurio-cadmio-telurio para la banda 6.

El incremento de la resolución espacial y espectral que ofrece el TM, facilita una mayor precisión para la cartografía temática, mientras permite ampliar el rango de aplicaciones operativas a partir de sensores espaciales. En este sentido, el diseño del TM pretendió paliar las deficiencias observadas en las imágenes MSS, incorporando información de 4 bandas del espectro no contempladas en el MSS (azul, dos en el infrarrojo medio y una en el térmico), mientras se sustituían las bandas 6 y 7 de ese sensor por una sola, sin perder información sustancial.

Con esa nueva configuración, el TM permite una sensible mejora en las aplicaciones terrestres y marinas sobre el sensor MSS. Tal vez su principal problema radica en su coste y en el volumen de datos que ofrece. A modo de referencia, basta indicar que una escena completa del sensor TM septuplica el coste de una adquirida por el MSS (sobre el mismo territorio), mientras que el volumen de datos que incluye alcanza los 231 millones de píxeles frente a los 28 millones de una imagen MSS: Esto ha llevado a comercializar cuartos de escena (100 \* 100 Km.), bandas aisladas y miniescenas (50 \* 50 Km.)

BANDAS	FAJA ESPECTRAL (um)	APLICACIONES
1	0,45-0,52 (azul)	Mapeamiento de aguas costeras, diferenciación entresuelo y vegetación, diferenciación entre vegetación conifera y decidua
2	0,52-0,60 (verde)	Mapeamiento de vegetación, calidad de agua.
3	0,63-0,90 (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 stress térmico en plantas, corrientes marinas, propiedades termales del suelo otros mapeamientos térmicos.
7	2,08-2,35 (infrarrojo medio)	Identificación de minerales, mapeamiento hidrotermal

Tabla 3.7 - Características espectrales y aplicaciones del sistema TM.

La siguiente figura presenta los canales de los sensores RBV, MSS y TM en relación a las curvas típicas de algunos objetos de la superficie terrestre.





Figura 3.6 - Canales de los sensores TM, MSS y RBV en relación a las curvas típicas de algunos objetos de la superficie terrestre

Además del sensor TM, se encuentran en estudio dos nuevos sensores: una versión mejorada del TM denominada ETM (*Enhanced Thematic Mapper*) que incorpora una Banda pancromática de 0.50 - 0.90  $\mu\text{m}$  con una resolución espacial de 15 metros y el sensor denominado HERMSI (*High Resolution Multispectral Stereo Imager*) con una resolución de 5 metros y capacidad para cambiar el ángulo de observación, lo que permite una cobertura estereoscópica y reducir, si fuera posible, la resolución temporal a 3 días. Los costos estimados, en dólares, del programa LANDSAT son de 398 millones para el ETM y 403 millones para el HERMSI.

### 3.3.3 LANDSAT 7.

El LandSat 7 es el satélite operacional mas reciente del programa Landsat, financiado por el gobierno de los Estados Unidos.



*Figura 3.7 - Satélite LANDSAT 7.*

El último satélite fue lanzado en abril de 1999 con un nuevo sensor denominado ETM+ (Enhanced Thematic Mapper Plus). Su operación es administrada por la NASA (National Space and Space Administration) y la producción y comercialización de imágenes depende de la USGS (United States Geological Survey).

Una imagen LANDSAT 7 ETM+ está compuesta por 8 bandas espectrales que pueden ser combinadas de distintas formas para obtener variadas composiciones de color u opciones de procesamiento. Entre las principales mejoras técnicas respecto de su antecesor, el satélite Landsat 5, se destaca la adición de una banda espectral (Banda Pancromática) con resolución de 15 metros. También cuenta con mejoras en las características geométricas y radiométricas y una mayor resolución espacial de la banda térmica para 60 m.

Estos avances tecnológicos permite calificar al LANDSAT 7 como el satélite más interesante para la generación de imágenes con aplicaciones directas hasta una escala de 1:25.000, principalmente en áreas rurales o territorios de grandes extensiones.

Las imágenes generadas por el LandSat 7 adquiridas mediante el sensor ETM+ presentan una mejor relación costo-beneficio que los datos generados por satélites de resolución media ( 15 a 30 metros) actualmente ofrecidos en el mercado.

#### 3.3.3.1 La Órbita del Landsat 7.

El LandSat 7 puede adquirir imágenes en un área que se extiende desde los 81° de latitud norte hasta los 81° de latitud sur y obviamente, en todas las longitudes del globo terrestre. Una órbita del LandSat 7 es realizada en aproximadamente 99 minutos, permitiendo al satélite dar 14 vueltas a la Tierra por día, y cubrir la totalidad del planeta en 16 días. La órbita es descendente, es decir de norte a sur, el satélite cruza la línea del Ecuador entre las 10:00 y 10:15 (hora local) en cada pasaje. El LandSat 7 está "helosincronizado", o sea que siempre pasa a la misma hora por un determinado lugar.

Un factor importante es que el periodo de revolución del LANDSAT 7 es igual que el del Landsat 5 (16 días), y una imagen cubre igual área (185 x 185 Km. por escena). La conservación de estos parámetros técnicos facilita que el proceso de captura de imágenes se pueda realizar con la misma grilla de referencia (WRS2) lo que permite una perfecta integración entre el procesamiento

de las imágenes del LANDSAT 7 con datos históricos del LANDSAT 5 existentes desde 1984. Esto es especialmente útil cuando es necesario utilizar los dos tipos de datos de un mismo lugar en forma simultánea por ejemplo para un estudio multitemporal. Las principales diferencias entre el Landsat 7 y el Landsat 5 son:

- Adición al LandSat 7 de una banda Pancromática con resolución espacial de 15m.
- Perfeccionamiento del sistema de calibración radiométrica de los sensores, lo que garantiza una precisión radiométrica absoluta de  $\pm 5\%$ .

Perfeccionamiento de la geometría de captura, lo que brinda una mayor precisión en imágenes corregidas sólo a partir de datos de efemérides de satélite generadas por el GPS de abordaje, muy próxima a la precisión obtenida con imágenes georreferenciadas con puntos de control cartográficos.

**3.3.3.2 Bandas espectrales y Resolución Espacial**

Las bandas del espectro visible y del infrarrojo mantienen la resolución espacial de 30 m del Landsat 5 (canales 1,2,3,4,5 y 7). Las bandas del infrarrojo térmico (canales 6L e 6H) pasan a ser adquiridas con resolución de 60 metros, contra 120 metros del Landsat 5.

La nueva banda Pancromática (canal 8) tiene 15 m de resolución espacial. El siguiente cuadro comparativo ilustra las diferencias de resolución espectral entre el sensor TM del Landsat 5 y el sensor ETM+ del Landsat 7. Los valores, expresados en micrones, representan los límites de longitudes de onda a los que son sensibles cada banda espectral.

Sensor	Banda1	Banda2	Banda3	Banda4	Banda5	Banda6	Banda7	Banda8
TM	0.45	0.52	0.63	0.76	1.55	10.4	2.08	
	0.52	0.60	0.69	0.90	1.75	12.5	2.35	
ETM+	0.45	0.53	0.63	0.78	1.55	10.4	2.09	0.52
	0.52	0.61	0.69	0.90	1.75	12.5	2.35	0.90

*Tabla 3.8 - Tabla comparativa entre los sensores TM y ETM+.*

**La Banda Pancromática - (Banda 8).**

La banda Pancromática es la mayor novedad del sensor ETM+ en el LandSat 7. Su resolución espacial de 15 m registrado con las demás bandas, permite que las imágenes generadas a través de este sensor sean trabajadas para obtener ampliaciones hasta una escala de 1:25.000.

**La Banda Termal - (Banda 6).**

El Landsat 7 genera la banda 6 con ganancia bajo (Canal 6L) y ganancia alto (Canal 6H). Esto permite varias opciones de análisis y aplicaciones, tales como la medición relativa de temperatura radiante o un cálculo de temperatura absoluta.



### 3.3.3.3 Niveles de corrección geométrica de las imágenes Landsat 7.

En todas las imágenes, y esto es válido para todos los satélites comercialmente disponibles, las correcciones del sistema son algoritmos de rectificación de la imagen cruda aplicada automáticamente en la estación de recepción, usando parámetros espaciales contenidos en los archivos descriptores de imagen (datos de posicionamiento y efemérides del satélite), que consiguen minimizar las variaciones espaciales internas presentes en la imagen en su estado bruto, correcciones del ángulo de curvatura terrestre, variaciones de velocidad, altura y actitud del satélite, desplazamientos orbitales, etc. Las imágenes Landsat 7 están disponibles en 3 niveles de corrección geométrica:

**Nivel 4:** es un nivel de corrección básica donde la imagen es radiométrica y geoméricamente corregida de forma sistemática.

**Nivel 5:** también consiste en una imagen con correcciones sistemáticas, pero que se georreferencia utilizando las efemérides del satélite. Los algoritmos de corrección modelizan la posición del satélite y la geometría del sensor a través de datos que una computadora de a bordo graba sobre la captura. Altitud, efemérides y parámetros de actitud del satélite, descritos en el archivo Payload Correction Data (PCD) y en el archivo Calibration Parameter File (CPF) son los componentes fundamentales usados para la generación de productos nivel 5 y garantizan la fidelidad geométrica general de la imagen.

**Nivel 6:** No es un proceso automático ni una corrección sistemática. Este nivel de procesamiento exige intervención adicional de un operador. La imagen nivel 5 antes descrita es ajustada con puntos de control cartográficos o con puntos de control medidos especialmente con tecnología GPS. Se obtiene una imagen rectificadas a una determinada proyección cartográfica.

#### **Ortoimagen.**

Este nivel de procesamiento exige la intervención de un operador sobre una imagen corregida con puntos de control utilizando también un Modelo Digital de Elevaciones (DEM) para corregir todas las distorsiones. El producto final consiste en una ortoimagen georreferenciada a la proyección cartográfica deseada.

#### **Imagen de Fusión (Merge).**

Es una combinación de buena resolución espacial de la banda Panorámica (15 metros) con la buena resolución espectral de Landsat 7. Una correcta interpretación de la información proveniente de imágenes satelitales depende principalmente de los atributos de textura y color presentes en dicha imagen, fundamentalmente para discriminar áreas que presentan variaciones relevantes, como tipos de vegetación y especies, patrones específicos de uso y ocupación del suelo e interpretaciones ligadas a la morfología.

Las imágenes generadas por el proceso de fusión espectral (merge) reúnen en una única imagen diferentes texturas (calidad geométrica) provenientes del canal de mejor resolución espacial (15 m de la banda PAN) y la información temática de color, resultante de la combinación de los diversos canales espectrales disponibles (en el caso del Landsat 7, 6 bandas espectrales con resolución espacial de 30 m). El resultado es una imagen con 15 metros de resolución, contra los 30 metros del producto original, con tonalidades muy similares a la composición de las bandas originales, o sea, sin alterar el contenido temático.

### Formatos y soportes existentes.

Las imágenes Landsat 7 crudas o derivadas del proceso de fusión están disponibles en formato digital e impreso a requerimiento de los clientes. Cada imagen cubre 185 x 185 Km. (escena completa) pero también es posible fraccionarlas en cuadrantes (1/4 de escena, 90 x 90 Km.) o mini escenas de 50 x 50 Km.




Figura 3.8 - Elementos que componen al satélite LANDSAT 7.

European Space Agency  
Ground Station Network



Figura 3.9 - Estaciones de recepción de la Agencia Espacial Europea (ESA).

El siguiente cuadro resume la información técnica de los sensores en cada uno de los sistemas Landsat.

Sensor	Technical Summary	Satellite	Launch Date	End Mission	Altitude	Inclination	Revisit at equator
REV MSS		Landsat 1	23 Jul 72	8 Jun 78	900 km	99.2°	18 days
REV MSS		Landsat 2	21 Oct 75	8 Feb 82	900 km	99.2°	18 days
REV MSS		Landsat 3	5 Mar 78	31 Mar 83	900 km	99.2°	18 days
MSS, TM		Landsat 4	14 Jul 82	1987	705 km	98.2°	16 days
MSS, TM		Landsat 5	13 Mar 84	operational TM	705 km	98.2°	16 days
ETM+		Landsat 7	17 Apr 99	operational	705 km	98.2°	16 days
<b>MSS</b>							
Band		4	5	6	7		
µm		5-6	6-7	7-8	8-11		
Pixel size(m)		80	80	80	80		
<b>TM &amp; ETM+</b>							
Band		1	2	3	4	5	6 7
							(Thermal IR)
µm		45-52	53-60	63-69	76-90	10.55-11.75	10.42-12.50 2.05-
Pixel size(m)		30	30	30	30	30	120 (ETM+ 60) 30
ESA stations							
for Landsat 7, Band 6 (thermal IR) is provided in both high and low gain. Data from has the thermal band resampled to 30 metre pixels							

Tabla 3.9 – Información técnica resumida de los satélites del programa LANDSAT.

### 3.4 SPOT 5 Supermode

#### (Système Pour l’Observation de la Terre – Sistema Para la Observación de la Tierra)

Uno de los programas de teledetección más novedosos frente al estándar marcado por el programa Landsat, ha sido el proyecto SPOT desarrollados por el CNES francés en colaboración con Bélgica y Suecia.

NOMBRE	VEHÍCULO DE LANZAMIENTO	FECHA DE LANZAMIENTO	OBSERVACIONES
SPOT 1	Ariane	22 Febrero 1986	Se activó el 31 de Diciembre de 1990. Aún activo
SPOT 2	Ariane	22 Enero 1990	Aún en operación
SPOT 3	Ariane	26 Septiembre 1993	Dejó de funcionar el 14 de Noviembre de 1997
SPOT 4	Ariane	24 Marzo 1998	Listo para lanzarse en caso de un fracaso prematuro de los satélites en órbita.
SPOT 5	Ariane	2002	Será lanzado para asegurar la continuidad del programa.

Tabla 3.10 - Satélites del programa SPOT.

## 3.4.1 Datos técnicos del programa SPOT.

Tipo de órbita	circular, síncrono - circular.
Altitud de órbita (sobre el Ecuador)	822 Km.
Periodo Orbital (nominal)	101.4 min.
Inclinación	98.7 grados.
Revoluciones por día	14 + 5/26
Período	101 minutos.
Duración del ciclo	26
Revoluciones por el ciclo orbital	369
Tiempo de vida útil	mayor de 3 años.
Dimensiones de la estructura principal	2m * 2m * 4.5m
Peso total	1907 Kg.

Después del SPOT 4, la familia de SPOT provee un servicio de continuidad con el SPOT 5 para el cual el CNES diseña un nuevo instrumento de alta resolución geométrica o HRG (High Resolution Geometry). SPOT 5 ofrece nuevas capacidades y desempeño para hacer frente a la demanda creciente en cartografía, agricultura, planeación y medio ambiente. La carga útil principal consiste en instrumentos de alta resolución, los cuales son una mejora de la instrumentación del SPOT 4.




Figura 3.10 – Satélites SPOT.

Los adelantos tecnológicos han hecho posible las mejoras de desempeño:

- Sensor lineal de arreglos de 12,000 puntos, estabilidad dimensional de materiales, sistemas de compresión de datos, mayor capacidad de memoria estática.
- Como es el caso de los satélites previos, SPOT 5 es desarrollado con la cooperación de Bélgica y Suecia.
- Continuidad de la Banda espectral y mejoras en la resolución espacial.
- La Bandas espectrales del SPOT 5 serán iguales que las utilizadas por el SPOT 4. La Banda pancromática, sin embargo, volverá a los valores utilizados por el SPOT 1 y 3 (PA 0.51-0.73  $\mu\text{m}$ ).
- Las especificaciones de calidad geométrica requieren una exactitud planimétrica de 10m (rms) y una exactitud de elevación de 5m (rms). Estos requerimientos son compatibles con normas convencionales de planimetría o mapeo a una escala de 1:50,000

SPOT-5, el satélite que actualmente se está desarrollando tendrá una mejora considerable en su resolución espacial, mientras mantenga las mismas capacidades operacionales de su predecesores. La resolución espacial de las imágenes multispectrales será de 10 metros para las bandas 1 (verde visible), 2 (rojo visible) y 3 (infrarrojo cercano) en comparación de 20 metros de SPOT-1 hasta SPOT-4. La banda SWIR mantendrá la resolución espacial de 20 metros. En el modo panorámico la resolución normal será de 5 metros, en comparación con los 10 metros de resolución de su predecesores. Sin embargo, SPOT-5 ofrecerá un modo de alta resolución donde se integrarán dos imágenes con un desfase de 2.5 metros con el fin de producir una imagen con una resolución espacial de 2.5 metros. Obsérvese el siguiente diagrama del procedimiento:




Figura 3.11 - Obtención de una imagen con Resolución Espacial de 2.5 metros.

Obsérvese a continuación la resolución panorámica que actualmente tienen los satélites SPOT (izquierda), la resolución normal de SPOT-5 (centro) y la resolución obtenida en el modo supermode (derecha).



Figura 3.12 - Comparación de resultados en el modo Supermode.

El SPOT-5 tendrá dos instrumentos HRG (High resolution geometric) que pueden ser operados independientemente. Esto con el fin de captar imágenes simultáneamente de áreas distintas o para obtener tanto para el modo multispectral como para el modo panorámico un ancho de banda de 120 Km. (en comparación de 60km para sus predecesores). La programación del satélite será realizada con base en los pronósticos climatológicos de tanto corto plazo como largo plazo, así obteniendo menor cobertura de nubes en las imágenes. También será posible obtener productos de sinergismo combinando el supermode de 2.5 metros de resolución con la información multispectral:



Figura 3.13 – Combinación del Supermode e información multispectral.

El satélite SPOT-5 tiene un sensor "vegetación" con una anchura de banda de 2250 Km. y resolución espacial de 1km para generar información acerca de la vegetación con cobertura diaria para todo el mundo. A continuación se presenta una tabla comparativa de los sensores incluidos en cada uno de los satélites Spot.

Banda espectral		SPOT-1, 2 y 3		SPOT-4		SPOT-5		Vegetation	
Banda	Longitud (µm)	Resolución	Ancho	Resolución	Ancho	Resolución	Ancho	Resolución	Ancho
PA	0.49-0.69	10m	60km	10m	60km	2.5-5m	60km	-	-
B0	0.43-0.47	-	-	-	-	-	-	1km	2250km
B1	0.43-0.61	20m	60km	20m	60km	10m	60km	-	-
B2	0.61-0.68	20m	60km	20m	60km	10m	60km	1km	2250km
B3	0.78-0.89	20m	60km	20m	60km	10m	60km	1km	2250km
SWIR	1.58-1.75	-	-	20m	60km	20m	60km	1km	2250km

Tabla 3.11 – Tabla comparativa de sensores en los satélites SPOT.

### 3.4.2 El programa Vegetación.

El programa vegetación es realizado conjuntamente por Bélgica, Francia, Italia, Suecia y la Comisión Europea. Este programa ofrece actualmente a los usuarios de satélites y clientes de EngeSat:

- Un sensor de observación de la tierra que está a bordo del Spot 4 y del Spot 5.
- Un recorrido diario de la tierra con una resolución de 1 Km.
- Imágenes de satélites de alta calidad técnica, directamente utilizadas en aplicaciones casi en tiempo real.
- Información continua y actualizada desde 1988 para la toma de decisiones y para la elaboración de políticas de aprovechamiento de los recursos y monitoreo del medio ambiente.

**3.4.3 El instrumento Vegetación.**

Un instrumento Vegetación es un sensor óptico con un campo de visión largo, montado a bordo de los satélites Spot 4 y Spot 5 que opera en cuatro Bandas espectrales:

- *Azul*, utilizado principalmente para monitorear cambios atmosféricos.
- *Infrarrojo próximo (Near Infra Red)*. Sensible a actividades fotosintéticas celulares de la vegetación.
- *Infrarrojo corto (Short Wave Infra Red)*. Sensible solamente a la humedad de la vegetación.

Con 1 Km. de resolución, a lo largo de la franja captada de 2,250 Km. las imágenes de vegetación no presentan distorsiones

**3.4.4 Modos y Bandas Espectrales : PAN o M, XS y XI, P+XS**

El satélite SPOT operan en 2 modos espectrales distintos que pueden también ser programados simultáneamente para una misma área: Multiespectral XI o XI, dependiendo del satélite y Pancromático o Monoespectral, dependiendo del satélite. Todas las imágenes del SPOT son codificadas en 8 bits.

Tanto los modos Multiespectrales, como las observaciones son efectuadas en tres bandas espectrales (modo XS) para el SPOT 1,2,3 y 4 bandas para el SPOT 4 (modo XI ), siempre con una resolución de 20 metros.

En el modo Pancromático o Monoespectral, las observaciones son efectuadas por una única banda, de 0,51  $\mu\text{m}$  a 0,73  $\mu\text{m}$ , en caso del SPOT 1-2-3, es de: 0,61 a 0,68  $\mu\text{m}$ . En el SPOT 4, siempre con una resolución de 10 metros.

Sensores	Bandas Espectrales	Resolución
HRV-XS : Multiespectral: 3 bandas en SPOT 1-2-3 HRVIR-XI : Multiespectral: 4 bandas en SPOT-4	Banda-1 : 0.50 ~ 0.59 $\mu\text{m}$ Verde	20m
	Banda 2 : 0.61 ~ 0.68 $\mu\text{m}$ Rojo	
	Banda 3 : 0.79 ~ 0.89 $\mu\text{m}$ Infrarrojo Próximo	
	Banda 4 : 1.58 ~ 1.75 $\mu\text{m}$ Infrarrojo Medio	
HRV-PAN : Pancromático En SPOT 1-2-3 HRVIR-M : Monoespectral En SPOT 4	Banda única: 0.51 ~ 0.73 $\mu\text{m}$ Visible menos Azul Datos comprimidos a bordo ( DPCM 1/4 )	10m
	Banda única: 0.61 ~ 0.68 $\mu\text{m}$ Igual a Banda 2 Datos comprimidos a bordo ( DPCM 1/4 )	

Tabla 3.12 - Características de las Bandas espectrales en los satélites SPOT.

- Un modo Pancromático o Monoespectral es aconsejado para aplicaciones que requieren precisión geométrica y resolución.
- Un modo Multiespectral XS o XI es aconsejado para aplicaciones temáticas, para estudios de vegetación, uso y ocupación de suelos, etc.
- Los modos PAN y XS pueden ser combinados obteniendo una imagen PAN+XS con Bandas de 10m de resolución.

Los modos M y XI del SPOT 4 XS pueden ser combinados obteniendo una imagen PAN+XS, con 4 bandas y 10m de resolución. Las imágenes M y XI del SPOT 4, cuando son adquiridas simultáneamente, están registradas entre si, lo que permite de este procesamiento una tarea mucho más simple y sistemática. Esto es posible en una imagen en modo Monoespectral del SPOT 4, a diferencia de lo que acontece en el SPOT 1-2-3, y es generada por la banda 2 del instrumento XI de 20m de resolución.

Esto permite una completa compatibilidad geométrica con una imagen XI adquirida simultáneamente, pero en el mismo instrumento.

### 3.4.5 Características técnicas del SPOT 5.

<b>Dimensiones, incluyendo paneles solares</b>	3.4 m x 3.1 m x 6 m
<b>Peso</b>	3.000 Kg.
<b>Potencia generada por los paneles</b>	2.400 W
<b>Instrumentos</b>	2 Instrumentos HRG 1 Instrumento HRS Instrumento Vegetación. DORIS ( Posicionamiento Orbital)
<b>Órbita</b>	Helio Sincronizada Altitud de 832 Km. No descendente: 10:30 horas
<b>Capacidades de flujo de datos</b>	5 canales digitales, 50 Mbits/s después de su compresión
<b>Capacidades de cada instrumento HRG</b>	Imagen pancromática, 3 m de resolución Imagen pancromática, 5 m de resolución Imágenes Multiespectrales, 10 m de resolución
<b>Capacidades do Instrumento HRS</b>	Imágenes estereoscópicas, 10 m de resolución
<b>Capacidades de Grabación a bordo</b>	3 canales digitales de 50 Mbits cada uno Incluye 160 escenas multiespectrales (10 m) o pancromáticas (5 m)
<b>Capacidades de transmisión</b>	2 canales digitales, 50 Mbits/s cada uno después de su compresión

### 3.4.6 Cualidades Radiométricas y Geométricas del SPOT 5.

La cualidad geométrica de las imágenes del SPOT 5 son de suma importancia para las aplicaciones cartográficas. El SPOT 5 fue dimensionado para responder a las demandas de los cartógrafos.

Las especificaciones del sistema son como siguen, compatible con aplicaciones cartográficas a una escala 1:50,000

- Precisión planimétrica de 10m.
- Precisión altimétrica de 5m.



La calidad radiométrica de las imágenes (ruido) será idéntica o menor que la del SPOT 4. Los especialistas en aplicaciones temáticas tendrán a su disposición información de cualidades tanto en formatos digitales como Analógicos / Fotográficos.

### 3.4.7 El instrumento HRS para la Alta Resolución Estereoscópica (*High Resolution Stereo*).

#### Especificaciones:

- Banda Panorámica de 0.50 a 0,70  $\mu\text{m}$
- Ángulo entre las dos cámaras: viendo en un ángulo de  $20^\circ$  para el frente y  $20^\circ$  para atrás.
- Resolución espacial de 10m.
- Franja de barrido: 120 Km.
- Longitud máxima de una escena: 600 Km.

#### Especificaciones de los productos generados:

- Precisión relativa (interna): de 5 a 10 m.
- Precisión absoluta (externa): de 10 a 15 m.
- Capacidad operacional: 30 millones de  $\text{Km}^2$  en 5 años.
- Capacidad máxima de recubrimiento diario: 126,000  $\text{Km}^2$ .

Los instrumentos HRS a bordo del SPOT 5 serán una "máquina increíble" para generar Modelos Numéricos de Terreno MNT.

TESIS CON  
FALLA DE ORIGEN

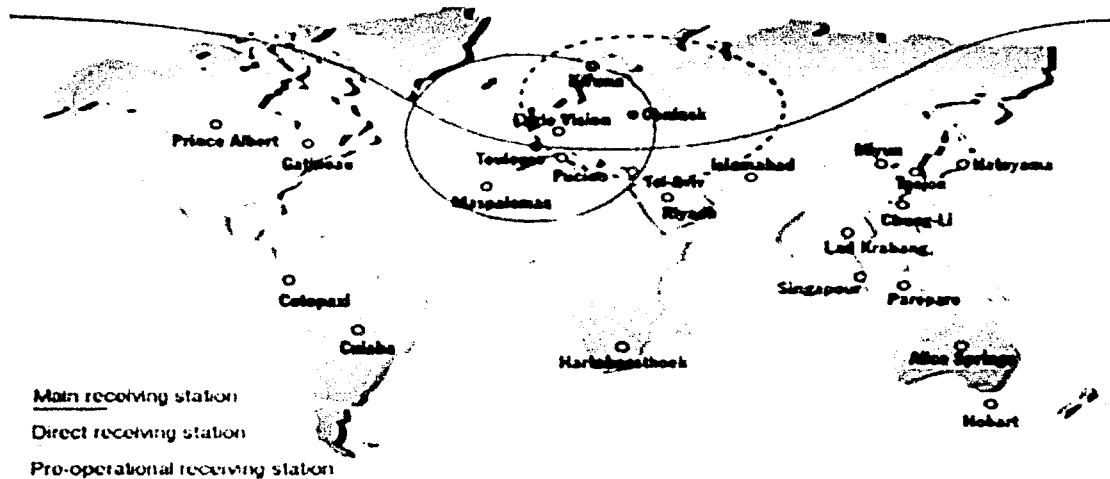


Figura 3.14 - Red de estaciones de recepción del programa SPOT.

3.5 Imágenes del satélite Ikonos.



*Manhattan, New York (color) - Junio 30, 2000  
IKONOS 1-metro (imagen antes del ataque)*



*Manhattan, New York - Septiembre 12, 2001  
IKONOS 1-metro (imagen después del ataque)*



*Manhattan, New York - IKONOS 1-metro  
Blanco y negro (antes del ataque)*



*Manhattan, New York, Septiembre 15, 2001  
IKONOS 1-metro (WTC - Después del ataque)*



Estadio de baseball del Estado de Chihuahua en Cuauhtemoc, México; recepcionada el 12/2/2000 por el sensor pancromático del satélite Ikonos.

La imagen satelital nos muestra además del Estadio, la plaza central y el área del centro comercial.



Esta imagen de resolución de 1 metro color, nos muestra un área residencial de Sydney, Australia recepcionada el 1/12/1999 por el satélite Ikonos de la Empresa Space Imaging.

En la imagen sobresale el aspecto residencial del área, incluyendo árboles, terrenos, casas, colegios, rutas, ríos y parques.



Imagen pancromática de las afueras de Caracas, Venezuela recepcionada el 30/12/1999 por el IKONOS.

Nos muestra los efectos del desplazamiento de lodo ya que fue tomada luego de grandes inundaciones.



Imagen de resolución 1 metro, pancromática de Guayaquil, Ecuador recepcionada el 9/11/1999 por el satélite Ikonos.

Se visualiza una área urbana adyacente a zonas forestales. Nos permite identificar el impacto del desarrollo urbano sobre el medio ambiente.



Bahía de Montego - Jamaica. Imagen Satelital Ikonos de resolución 1 metro. Recolectada por Space Imaging el 10 de Feb. 10 del 2001.




Pentagon, Washington. Fecha de Toma: 28 de Diciembre de 2000 Satélite Ikonos Resolución de 1 metro por pixel Obtenida de Space Imaging

3.6 Imágenes de los satélites Landsat.



*Durban, Sudáfrica  
Vista en 3D de una imagen de  
LandSat 7 sobre un MDT de 20m.*




*Sydney, Australia  
Vista en 3D de una imagen de  
LandSat 7 sobre un MDT de 20m.*



*Bafussam, Camerún  
Vista en 3D de una imagen de  
LandSat 7 sobre un MDT de 20m.*



*Abuja, Nijeria  
Vista en 3D de una imagen de  
LandSat 7 sobre un MDT de 20m.*



Entorno Geográfico de Los Gigantes, lugar turístico de Córdoba, Argentina.

Se visualizan Localidades próximas y waypoints del recorrido turístico a través de los refugios. Imagen del Satélite Landsat 7.



Imagen del Satélite Landsat 7 ETM+, del 25-08-01 que cubre la zona de KABUL, Afganistán.

Obtenida de EngeSat.




Imagen de la ciudad de Mar del Plata, Argentina

Satélite Landsat 7  
Resolución de 30 metros por pixel

Combinación de bandas:

Rojo: Banda 7

Verde: Banda 5

Azul: Banda 2 \*

Obtenida de la CONAE




Imagen de la Ciudad de Córdoba y Alrededores, Argentina

Fecha de Toma: 1º de enero de 2001. Satélite Landsat 7  
Resolución: 30 metros p.p.  
Combinación de bandas:

Rojo: Banda 7

Verde: Banda 5

Azul: Banda 2

Obtenida de Ciampagna & Asociados - GDSIG




Imagen de la Ciudad de Carlos Paz, Valle de Punilla, Córdoba, Argentina

Fecha de Toma: 1º de enero de 2001. Satélite Landsat 7  
Resolución: 30 metros p.p.  
Combinación de bandas:

Rojo: Banda 7

Verde: Banda 5

Azul: Banda 2

Obtenida de Ciampagna & Asociados - GDSIG




Imagen de la Ciudad de Bariloche, Argentina

Satélite Landsat 7  
Resolución de 30 metros por pixel

Combinación de bandas:

Rojo: Banda 7

Verde: Banda 5

Azul: Banda 2

Obtenida de la CONAE

3.7 Imágenes de los satélites SPOT.



Imagen SPOT VEGETACION del 2001. Comercialmente disponible para todas los países o superficies determinadas con una resolución de 1 Kilómetro, abarca toda el área de Sudamérica.

Obtenida de EngeSat.




Imagen de la Ciudad de Corrientes, Argentina  
Satélite francés Spot  
Pancromática

Obtenida de la CONAE



Imagen de la Ciudad de Rio de Janeiro, Brasil

Fecha de Toma: 7 de Septiembre de 1994  
Satélite francés Spot  
Resolución de 10 metros por pixel

PAN+XS

Bandas 3,2,1

Obtenida de EngeSat



Imagen Spot Vegetacion (tipo S-10).

Resolución de 1 Km.

Fecha de toma: 30-09-2000 a 10-10-00.

Bandas 4-3-2 en R-G-B.

Obtenida de EngeSat



Municipio de Hiaras - SP  
Satélite SPOT.

Resolución: de 10 m por pixel. Modo: PAN

Fecha de la toma: 19-08-99

Obtenida de EngeSat



México

Fecha de la toma: 05/12/2000  
Satélite SPOT., Vegetación

Obtenida de EngeSat.

---

# CAPÍTULO 4

## TÉCNICAS BAYESIANAS



*Rev. Thomas Bayes (1702-1761)*

### 4.1 Introducción.

La inferencia Bayesiana es un enfoque alternativo para el análisis estadístico de datos que, en buena medida, se contraponen a los métodos que proceden de lo que se ha denominado "Estadística Frecuentista" y que todos usamos con regularidad. Un elemento cardinal con que predominantemente opera este método alternativo es el manejo subjetivo, no Frecuentista, del concepto de probabilidad.

El interés por el teorema de Bayes trasciende especialmente cuando se amplía a otro contexto en el que la probabilidad no se entiende exclusivamente como la frecuencia relativa de un suceso a largo plazo, sino como el grado de convicción personal acerca de que el suceso ocurra o pueda ocurrir (definición subjetiva de la probabilidad).

Una cuantificación sobre base subjetiva resulta familiar y fecunda para el enfoque Bayesiano. Al admitir un manejo subjetivo de la probabilidad, el analista Bayesiano podrá emitir juicios de probabilidad sobre una hipótesis  $H$  y expresar por esa vía su grado de convicción al respecto, tanto antes como después de haber observado los datos.

En su versión más elemental y en este contexto, el teorema de Bayes asume la forma siguiente:

$$P(H | \text{datos}) = [P(\text{datos} | H) / P(\text{datos})] \cdot P(H)$$

La *probabilidad a priori* de una hipótesis,  $P(H)$ , se ve transformada en una *probabilidad a posteriori*,  $P(H | \text{datos})$ , una vez incorporada la evidencia que aportan los datos. El caso considerado se circunscribe a la situación más simple, aquella en que  $P(H)$  representa un número único; sin embargo, si se consiguiera expresar nuestra convicción inicial (y nuestra incertidumbre) mediante una distribución de probabilidades, entonces una vez observados los datos, el teorema nos "devuelve" una nueva distribución, que no es otra cosa que la percepción probabilística original actualizada por los datos.

Esta manera de razonar de la inferencia Bayesiana, radicalmente diferente a la inferencia clásica o Frecuentista (que desdeña en lo formal toda información previa de la realidad que examina), es sin embargo muy cercana al modo de proceder cotidiano. Debe subrayarse que esta metodología, a diferencia del enfoque Frecuentista, no tiene como finalidad producir una conclusión dicotómica (significación o no significación, rechazo o aceptación, etc.) sino que cualquier información empírica, combinada con el conocimiento que ya se tenga del problema que se estudia, "actualiza" dicho conocimiento, y la trascendencia de dicha visión actualizada no depende de una regla mecánica.

Los métodos Bayesianos han sido cuestionados argumentando que, al incorporar las creencias o expectativas personales del investigador, pueden ser caldo de cultivo para cualquier arbitrariedad o manipulación. Podemos argüir, por una parte, que el enfoque frecuentista no está exento de decisiones subjetivas, de hecho, la subjetividad (algo bien diferente de la arbitrariedad o el capricho) es un fenómeno inevitable. Por otra parte, las "manipulaciones" son actos de deshonestidad, que pueden producirse en cualquier caso (incluyendo la posibilidad de que se inventen datos) y que no dependen de la metodología empleada sino de la honradez de los investigadores.



Aunque las bases de la estadística Bayesiana datan de hace más de 2 siglos, no es hasta fechas recientes cuando empieza a asistirse a un uso creciente de este enfoque en el ámbito de la investigación científica. Una de las razones que explican esta realidad y que a la vez anuncian un impetuoso desarrollo futuro es la absoluta necesidad de cálculo computarizado para la resolución de algunos problemas de mediana complejidad.

Los procedimientos Bayesianos constituyen una tecnología emergente de procesamiento y análisis de información para la que cabe esperar una presencia cada vez más intensa en el campo de la aplicación de la estadística a la investigación científica.

### 4.2 Reconocimiento estadístico de patrones.

El reconocimiento estadístico de patrones comienza con unidades, como una región o segmento proyectado de una imagen; en el que una variedad de medidas pueden hacerse. El propósito del reconocimiento es clasificar cada unidad con base en este vector de medidas. La clasificación encuentra una unidad con esta característica de vector para una categoría "closets".

Esto se hace a través de una regla de decisión. La regla de decisión es proyectada opcionalmente para asociar cada unidad a una clase de la categoría con base en el vector de medidas. Opcionalmente esto puede significar, por ejemplo, un menor error de clasificación para un conjunto dado de medidas y para una complejidad computacional dada en la regla de decisión.

Entonces, las técnicas de reconocimiento de patrones estadísticos incluyen:

1. Técnicas de selección y extracción conjuntas para reducir el número de mediciones que se efectúen o para reducir la dimensión de los vectores que representan las medidas efectuadas por una regla de decisión.
2. Técnicas de construcción de reglas de decisión.
3. Técnicas para estimar el error en las reglas decisión.

### 4.3 Bayesianismo.

El reverendo Bayes sugirió una regla (regla de Bayes) posibilitando que la probabilidad de un evento pudiera ser dada con base en el conocimiento humano. Esto es, en eventos en los que no se puede medir la frecuencia con la que ocurren, la probabilidad puede ser dada con base en el conocimiento que un especialista tiene sobre sí mismo.

La estadística Bayesiana pasó a ser aplicada en sistemas de Inteligencia Artificial al inicio de la década de los 60's (Russell & Norvig, 1995). En aquella época el formalismo en la utilización de probabilidades condicionales no estaba bien definido. Por otro lado, la cantidad de datos era muy grande, lo que dificultaba la manipulación y la utilización de esa teoría. Sin embargo, a partir del inicio de los años 70's y la mitad de la década de 80's, la probabilidad Bayesiana no fue muy utilizada en las investigaciones de IA. Con la publicación de trabajos, la teoría Bayesiana sufrió un grande impulso en el campo de IA.

La probabilidad Bayesiana es una teoría consistente y que permite la representación de conocimientos ciertos e inciertos a través de la distribución de probabilidad conjunta. Tal distribución conjunta puede ser representada por el producto de distribuciones condicionadas.

A través de las redes Bayesianas se pueden representar problemas del mundo real en el que existan relaciones de causa y consecuencia entre las variables. Existen varias aplicaciones que obtuvieron buenos resultados (Doyle y otros, 1996), como por ejemplo el "Intelipath" (Heckerman, 1991), un sistema de diagnóstico de patologías aprobado por la Asociación Americana de Medicina, o "VISTA" (Horvitz y otros, 1992) un sistema de monitoreo y análisis utilizado por la NASA para el control de misiones espaciales y los asistentes de solución de problemas de Microsoft (Heckerman y otros, 1995).

Las Redes Bayesianas tienen la posibilidad de realizar el aprendizaje a partir de datos en el que el aprendizaje, una muestra dada y el sistema, a través de un algoritmo genera una estructura que se adapta mejor a los datos del problema.

#### 4.4 Teorema de Bayes.

No es posible ignorar este importante "descubrimiento" publicado póstumamente a la muerte del reverendo Thomas Bayes (Sokal y Rohlf, 1995). El teorema de Bayes admite un manejo subjetivo de la probabilidad, esto permite emitir juicios de probabilidad sobre la validez de una hipótesis  $H$ . La probabilidad *a priori* de una hipótesis  $P(H)$ , es la que se fija o sugiere antes de tener en cuenta los datos (por eso es *a priori*).

Una vez realizada una observación o experimento, se incorpora la evidencia que aportan los datos al análisis a través del teorema y se obtiene una probabilidad *a posteriori*. Una vez observados los datos, el teorema "devuelve" también una distribución que ha de interpretarse como la nueva percepción, ahora "actualizada" por los datos. El teorema se expresa de la siguiente forma:




Figura 4.1 - Representación de los conjuntos  $H_i$  ( $i = 1, \dots, n$ ) y  $E$ .  $H_i$  son mutuamente excluyentes y  $E$  no es vacío.

La Figura 4.1 representa  $H_i$  como eventos mutuamente excluyentes y cuya unión es el espacio muestral  $Q$ .  $E$  es un evento en  $Q$  con una probabilidad no cero de ocurrencia; además, la probabilidad de obtener  $E$  es:

$$P(E) = E \cap H_1 + E \cap H_2 + \dots + E \cap H_n = \bigcup_{i=1}^{i=n} E \cap H_i \quad \text{----- (4.1)}$$

Considerando la estimación de probabilidades conjuntas  $P(AB)$  cuando los eventos son condicionales, se tiene la siguiente equivalencia:

$$P(H_i | E) = P(H_i)P(E | H_i) = P(E)P(H_i | E) \quad \text{----- (4.2)}$$

por lo tanto:

$$P(H_i | E) = \frac{P(H_i)P(E | H_i)}{P(E)} \quad \text{----- (4.3)}$$

Se puede reformular la parte final de (4.1), i.e.  $P(E) = P(\bigcup_{i=1}^{i=n} E \cap H_i)$  como:

$$P(E) = P\left(\bigcup_{i=1}^{i=n} E \cap H_i\right) = \sum_{i=1}^{i=n} P(E \cap H_i) = \sum_{i=1}^{i=n} P(E | H_i) P(H_i) \quad \text{----- (4.4)}$$

Lo anterior es válido porque los  $E \cap H_i$  son mutuamente excluyentes. El término del denominador en (4.3) se puede sustituir por su valor en (4.4) y se tiene:

$$P(H_i | E) = \frac{P(H_i)P(E | H_i)}{\sum_{i=1}^{i=n} P(E | H_i) P(H_i)} \quad \text{----- (4.5)}$$

Esta fórmula es conocida como: El Teorema de Bayes.

Dado que  $\sum_{i=1}^{i=n} P(E | H_i) P(H_i) = P(E)$ , esta última expresión puede describirse como:

$$P(H_i | E) = \frac{P(H_i)P(E | H_i)}{P(E)} \quad \text{----- (4.6)}$$

Esta fórmula es conocida como: La Regla de Bayes.

En donde cada uno de los elementos tiene el siguiente significado:

$P(H_i | E)$  : Probabilidad de que un vector de características  $E$  pertenezca a la clase  $H_i$ .

$P(E | H_i)$  : Probabilidad de que dada  $H_i$ , el valor de la variable aleatoria sea, precisamente,  $E$ . Dicho en otras palabras, es la función densidad de probabilidad de la clase  $H_i$  considerada como una variable aleatoria.

$P(H_i)$  : Probabilidad *a priori* de que se presente un elemento de la clase  $H_i$ .

$P(E)$  : Probabilidad *a priori* de que se presente un objeto a clasificar con un vector de características igual a  $E$  (considerado un vector numérico concreto o constante de normalización).

Este último elemento puede despreciarse, ya que presenta el mismo valor para un conjunto de  $n$  clases,  $H_1, H_2, \dots, H_n$ , compitiendo por el vector  $E$  a clasificar. Se trata, pues, de un factor de escala que se elimina por no incorporar información discriminante.

**4.4.1 Evaluación de la hipótesis por técnicas Bayesianas.**

- La mejor hipótesis es la más probable.
- Basadas en el teorema de Bayes. Despejan  $P(H_i | E)$ .
- La distribución de hipótesis *a priori*  $P(H_i)$  y la probabilidad de unas observaciones respecto a cada hipótesis  $P(E | H_i)$  deben ser conocidas.
- Permiten acomodar hipótesis probabilísticas.
- Son sólo técnicas evaluadoras aunque si el conjunto de hipótesis  $H_i$  es reducido se pueden utilizar en algoritmos de aprendizaje.
- Muchas veces no se conoce  $P(H_i)$  o incluso  $P(E | H_i)$ . Se hacen suposiciones: distribución uniforme, normal o universal.

**4.4.2 Clasificador Bayesiano Simple.**

Estimar la probabilidad:  $P(E | H)$  es complejo, pero se simplifica si se considera que los atributos son independientes dada la hipótesis:

$$P(E_1, E_2, \dots, E_N | H) = P(E_1 | H) P(E_2 | H) \dots P(E_N | H)$$

Por lo que la probabilidad de la hipótesis dada la evidencia puede estimarse como:

$$P(H | E_1, E_2, \dots, E_N) = \frac{P(H)P(E_1 | H) P(E_2 | H) \dots P(E_N | H)}{P(E)} \quad \text{----- (4.7)}$$

Esto se conoce como el Clasificador Bayesiano Simple.

Como se mencionó anteriormente, no es necesario calcular el denominador:

$$P(H | E_1, E_2, \dots, E_N) \sim P(H) P(E_1 | H) P(E_2 | H) \dots P(E_N | H)$$

- $P(H)$  se conoce como la probabilidad *a priori*.
- $P(E_i | H)$  es la probabilidad de los atributos dada la hipótesis (verosimilitud), y  $P(H | E_1, E_2, \dots, E_N)$  es la probabilidad *a posteriori*.

En su aplicación usual, el modelado Bayesiano es usado para encontrar la estimación máxima *a posteriori* (MAP), es decir, el valor de  $H$  que maximice la probabilidad condicional  $P(H | E)$ . En el caso más general, el estimador óptimo puede ser la solución que minimice el valor esperado de una función de energía con respecto a esta probabilidad condicional.

#### 4.5 Redes Bayesianas.

Las Redes Bayesianas utilizan un enfoque que se basa en la modularidad del mundo que se modela. También se les conoce como redes probabilísticas, causales o de influencia. Una red Bayesiana es un grafo acíclico dirigido, donde el conjunto de nodos o vértices representan variables proposicionales (proposiciones que describen objetos y/o eventos). Cada arco representa las relaciones de causalidad directa entre las variables conectadas y la fuerza de estas influencias es cuantificada por probabilidades condicionales. La variable al final del arco es dependiente de la variable que se encuentra al inicio del mismo (figura 4.2).

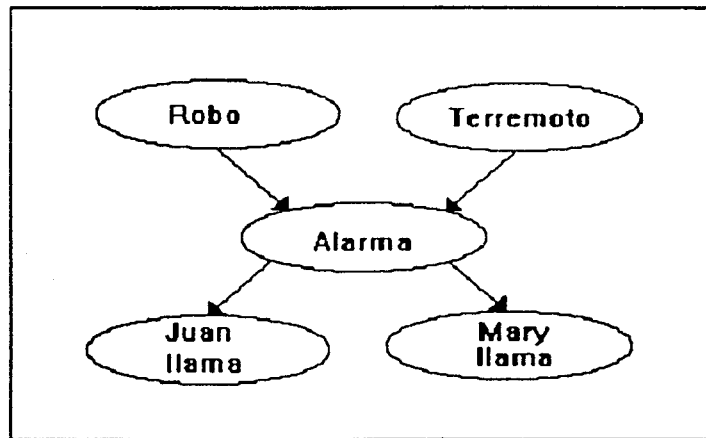


Figura 4.2 – Ejemplo de una Red Bayesiana.

Los nodos del grafo son variables  $X_1, X_2, \dots, X_N$ . Cada variable  $X_i$  tiene un conjunto finito de posibles valores  $\{x_i\}$ . Un arco  $(X_j, X_i)$  del nodo  $X_j$  al nodo  $X_i$  indica que el valor de  $X_j$  es una causa directa del valor de  $X_i$ .  $X_i$  puede tener  $I$  posibles valores, y  $X_j$  puede tener  $J$  posibles valores. Para cada par de valores  $(x_j, x_i)$ , la "fuerza de la causalidad" es la probabilidad condicional  $P(x_i|x_j)$ . Estas probabilidades pueden ser vistas en forma de una matriz de  $J \times I$  asociada con el nodo hijo.

El conjunto de apoyo de un nodo es el conjunto de los predecesores del nodo. Si observamos que el nodo  $X_i$  tiene el conjunto de apoyo  $S_i$ , entonces  $P(X_i|S_i)$  denota la probabilidad de unión condicional de  $X_i=x_i$ , dado el conjunto de valores  $\{S_i\}$  para las variables de apoyo. La distribución conjunta de la red completa es.

$$P(X_1, X_2, \dots, X_N) = \prod_{i=1}^N P(X_i | S_i) \quad \text{----- (4.8)}$$

Al aplicar la regla de Bayes se obtiene:

$$P(X_i | S_i) = \frac{P(S_i | X_i) P(X_i)}{P(S_i)} \quad \text{----- (4.9)}$$

Cuando todos los padres de una variable aleatoria  $X_i$  son instanciados, se dice que esa variable aleatoria es condicionalmente independiente del resto de las variables aleatorias las cuales no son descendientes de  $X_i$ . En la Figura 4.3 podemos observar que  $X_3$  es condicionalmente independiente de  $X_4$  dados  $X_1$  y  $X_2$ .




Figura 4.3 – Ejemplo de independencia condicional.

Una vez que una red Bayesiana es construida, puede ser usada para representar el conocimiento causal genérico de un dominio dado y puede ser consultada para razonar sobre la interpretación de los datos de entrada específicos. El proceso de interpretación comprende instanciar un conjunto de variables correspondientes a los datos de entrada y calcular su impacto sobre las probabilidades de un conjunto de variables diseñadas como hipótesis (actualización de creencias). Alternativamente, podemos buscar identificar la interpretación más probable de los datos, es decir, una asignación de valores al conjunto de hipótesis que obtenga la probabilidad posterior más alta dada la evidencia (revisión de creencias).

Los "padres" de un nodo son aquellos que tienen arcos dirigidos a él. Cada nodo tiene una tabla de probabilidad condicional que cuantifica el efecto de sus padres sobre él. Hay dos diferentes formas en que las proposiciones pueden afectar la probabilidad de otras:

- La primera es que las causas influyen en la probabilidad de sus síntomas.
- La segunda es que al observar los síntomas se afecta la probabilidad de sus posibles causas.

La idea detrás de la estructura de las redes Bayesianas es hacer una distinción clara entre estos dos tipos de influencia. La idea principal de las redes Bayesianas es que no es necesario utilizar una tabla de probabilidades conjuntas enorme en la que se listen las probabilidades de todas las posibles combinaciones de los eventos que se puedan concebir.

La mayoría de los eventos son condicionalmente independientes de otros, por lo cual sus interacciones no deben ser consideradas, en lugar de esto es posible utilizar una representación local en la cual se describan agrupamientos de eventos que interactúan.

La tarea básica de un sistema probabilístico de inferencia es calcular la distribución de probabilidades a posteriori de un conjunto de variables dados ciertos valores de las evidencias, es decir,  $P(\text{variables} / \text{evidencias})$ . Las redes Bayesianas permiten hacer 4 tipos de inferencia:

- ✓ **De diagnóstico (de efectos a causas).** Por ejemplo: Dado que Juan llamó, inferir la probabilidad de que hubo un robo:  $P(\text{robo} / \text{Juan llamó})$ .
- ✓ **Causales (de causas a efectos).** Por ejemplo: Dado que hubo un robo, inferir la probabilidad de que Juan llame:  $P(\text{Juan llame} / \text{robo})$ .
- ✓ **Intercausales (entre causas de común efecto).** Por ejemplo: Dado que la alarma sonó tenemos  $P(\text{robo} / \text{alarma})=0.376$ . Pero si añadimos la evidencia de que hubo un terremoto, entonces  $P(\text{robo} / \text{alarma y terremoto})=0.003$ . Aún cuando los robos y los terremotos son independientes, la presencia de uno provoca que el otro sea menos probable.
- ✓ **Inferencias mixtas (Combinación de dos o más de las anteriores).**

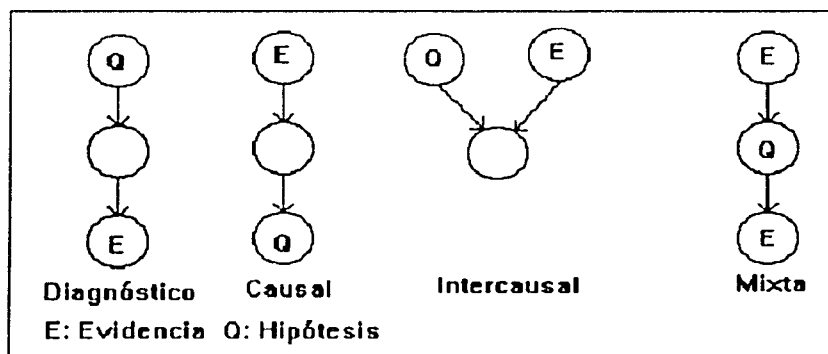


Figura 4.4 – Tipos de inferencia en las Redes Bayesianas.

Las redes Bayesianas son sistemas muy útiles. Las variables en los grafos de tales sistemas pueden ser proposiciones o variables que toman valores de algún otro tipo como: temperatura, presión, etc.

#### 4.6 Redes probabilísticas visuales.

Un sistema de visión basado en conocimiento usa conocimiento del dominio para analizar imágenes de ese dominio. El conocimiento puede ser general o extremadamente específico. Un sistema que trabaja con escenas urbanas podría saber sobre la presencia de casas, caminos y edificios. Un sistema que trabaja con partes mecánicas tridimensionales conocería las posibles estructuras de esas partes. Visión de alto nivel hace uso de este conocimiento para realizar reconocimiento.

El conocimiento puede estar estructurado de una manera jerárquica causal por lo que es necesario construir un modelo, en este caso una red Bayesiana, que represente nuestro conocimiento del dominio y permita realizar inferencia para poder deducir de la información obtenida de la imagen, la identidad y localización de los objetos relevantes.

Para la descripción jerárquica causal de una base de conocimiento visual, podemos pensar en una red dividida en una serie de capas en las cuales los nodos de la capa más baja corresponden a las variables de las características de los objetos y los nodos en la capa más alta a las variables que representan a los objetos.

Las capas intermedias tienen nodos para otras entidades visuales, tales como partes de un objeto o regiones de imágenes; o representan relaciones entre características y objetos. Las flechas apuntan desde los nodos en las capas superiores hacia nodos en las capas inferiores, expresando una relación causal (Sucar & Gillies, 1994). La estructura de una red probabilística para reconocimiento visual se muestra en la Figura 4.5




Figura 4.5 - Red probabilística jerárquica para reconocimiento visual.

El estudio de probabilidad condicional es importantísimo por sí mismo y sus aplicaciones son numerosas.

#### 4.7 Aplicación de métodos Estadísticos en la Segmentación de Imágenes Naturales.

Un ejemplo de la aplicación de las estadísticas en el análisis de imágenes fue investigado y desarrollado por Volker Rehrmann y Lutz Priesse del Laboratorio de Reconocimiento de Imágenes de la Universidad de Koblenz-Landau.


Un paso importante para los sistemas de análisis de imágenes y la segmentación de imágenes, es la identificación de regiones homogéneas en una imagen. Existe una gran variedad de métodos de segmentación en la literatura. Entre ellos están: los de detección de bordes (*edges detection*), los de separación y unión (*split and merge*), crecimiento de regiones (*region growing*) y técnicas de agrupamiento (*clustering*).

Durante tres décadas se desarrollaron métodos de segmentación para imágenes con tonos de gris. Sin embargo, las técnicas y equipos para la adquisición de imágenes en color se han vuelto más baratos y más comunes. El análisis de imágenes en color se vuelve cada vez más importante.

En la segmentación en color normalmente es usado un método de agrupamiento. Actualmente, los métodos estadísticos son aplicados para buscar algunos grupos en este espacio de características. Estos agrupamientos, remapean la imagen, forman los segmentos de color. La ventaja del método de agrupamiento es la visión global de los datos en las formas del histograma.



Sin embargo, esta visión global no refleja la información espacial para que la imagen sea comprendida. La extensión de los agrupamientos en la característica del espacio, muchas veces son ambiguos. Los métodos estadísticos resuelven este problema que es computacionalmente expansivo.



Color Structure Code (CSC)

Split&amp;Merge

Recursive Histogram Splitting


*Figura 4.6 – Ejemplo de la aplicación de métodos estadísticos en la segmentación.*

Para una segmentación por crecimiento de regiones son utilizados los datos locales y globales. Estos datos permiten encontrar resultados muy robustos en la segmentación en color de las escenas naturales.

---

# CAPÍTULO 5

## TEORÍA DE LOS CAMPOS ALEATORIOS DE MARKOV



*Imagen global del planeta tierra vista de noche. En ella se pueden apreciar las luces de las diferentes ciudades del mundo. Esto permite tener una aproximación de las regiones que han alcanzado un mayor aprovechamiento energético*

### 5.1 Probabilidad y variables aleatorias.

Denotamos por  $I$  al evento seguro (al que ocurre en cada prueba). Dado dos eventos  $A$  y  $B$ ,  $A \cup B$  denota el evento que ocurre siempre que  $A$  o  $B$  o ambos ocurren.  $A$  y  $B$  son mutuamente excluyentes si la ocurrencia de uno, dada una prueba, excluye al otro. Ahora, podemos definir la probabilidad de un evento por tres postulados:

**Definición 1.1.1** (Probabilidad). La probabilidad de un evento  $A$  es un número  $P(A)$  asignado a este evento satisfaciendo los siguientes axiomas:

- i.  $P(A)$  es positivo.  $P(A) \geq 0$ .
- ii. La probabilidad del evento seguro es igual a 1.  $P(I) = 1$ .
- iii. Si  $A$  y  $B$  son mutuamente excluyentes, entonces  $P(A \cup B) = P(A) + P(B)$ .

Ahora, examinemos que es un evento. Dados que los eventos pueden combinarse de varias formas para formar otros eventos, los eventos pueden describirse mejor por la *Teoría de Conjuntos*. Los resultados de un simple experimento son objetos bien definidos (eventos elementales) formando un conjunto  $I$  llamado espacio. Los eventos son varios subconjuntos de este espacio que contienen uno o más eventos elementales. Cada evento ocurre cuando uno de estos eventos elementales ocurre. Dos eventos son mutuamente excluyentes si no tienen elementos en común. Es claro que  $I$  es el evento seguro dado que siempre ocurre. El conjunto vacío  $\emptyset$  corresponde al evento imposible, el cual nunca ocurre. Matemáticamente, definimos un experimento de la siguiente forma:

**Definición 1.1.2** (Campo Borel).  $B$  es un campo de Borel si los conjuntos  $A_1, \dots, A_n$  pertenecen al campo, entonces:

$$\bigcup_{i=1}^n A_i \text{ and } \bigcap_{i=1}^n A_i \quad \text{----- (5.1)}$$

también pertenecen al campo.

**Definición 1.1.3** (Experimento). Un experimento  $\varepsilon = (I, B, P)$  está especificado por los tres conceptos siguientes:

- i. Un conjunto  $I$  de resultados llamado espacio o evento seguro.
- ii. Un campo Borel  $B$  consiste de ciertos subconjuntos de  $I$  llamados eventos.
- iii. Un número  $P(A)$  que es asignado a cada evento  $A$ , es llamada *probabilidad* satisfaciendo los axiomas de la definición 1.1.1

A continuación se tratan las variables aleatorias. Las variables aleatorias son funciones que satisfacen algunas condiciones generales, que asignan un número  $X(\varepsilon)$  para cada resultado  $\varepsilon \in I$ .

**Definición 1.1.4** (Variable Aleatoria). Una variable aleatoria  $X$  es una función cuyo dominio es el espacio  $I$  que asigna un número  $X(\varepsilon)$  a cada resultado  $\varepsilon \in I$  del experimento  $\varepsilon = (I, B, P)$  tal que:

- i. El conjunto  $\{X \leq x\}$  es un evento para cualquier número  $x$  o, en otras palabras,  $X$  es medible en el campo  $B$ .
- ii. La probabilidad de los eventos  $X = +\infty$  y  $X = -\infty$  son iguales a cero.

A continuación se definen algunas funciones que caracterizan una variable aleatoria.

**Definición 1.1.5 (Distribución).** Dada una variable aleatoria  $X$ , llamaremos a la función:

$$F_X(x) = P\{X \leq x\} \quad \text{----- (5.2)}$$

la *función de distribución* de  $X$  definida para cualquier número  $x \in \{-\infty, \infty\}$ . Claramente,  $F(-\infty) = 0$  y  $F(\infty) = 1$ .

**Definición 1.1.6 (Densidad).** Dada una variable aleatoria  $X$ , llamaremos a la derivada de esta distribución  $F_X(x)$

$$f(x) = \frac{dF(x)}{dx} \quad \text{----- (5.3)}$$

la *función de densidad* de  $X$ .

La monotonicidad de  $F(x)$  establece que  $f(x) \geq 0$  y:

$$\int_{-\infty}^{\infty} f(x) dx = F(\infty) - F(-\infty) = 1 \quad \text{----- (5.4)}$$

Dado que  $F(x)$  puede no tener una derivada para cada  $x$ , no podemos asociar una función de densidad a todas las variables aleatorias. Casi siempre debemos definir una densidad incluso para este tipo de variable aleatoria discreta para permitir que  $f(x)$  contenga impulsos.  $\delta(x)$  es una función impulso si:

$$\int_{-\infty}^{\infty} \phi(x) \delta(x) dx = \phi(0) \quad \text{----- (5.5)}$$

Cambiando la función original tenemos:

$$\int_{-\infty}^{\infty} \phi(x) \delta(x - x_0) dx = \phi(x_0) \quad \text{----- (5.6)}$$

Usando la ecuación anterior se puede demostrar que la derivada de una función discontinua  $F(x)$  en el punto de discontinuidad  $x_0$  es igual:

$$(F(x_0^+) - F(x_0^-)) \delta(x - x_0) \quad \text{----- (5.7)}$$

De este propiedad se sigue que la función de densidad de una variable aleatoria discreta consiste de impulsos en el punto  $x_i$ .

$$f(x) = \frac{dF(x)}{dx} = \frac{d}{dx} \sum_i p_i = \sum_i p_i \delta(x - x_i) \quad \text{----- (5.8)}$$

La función  $f(x)$  puede considerarse como una masa de probabilidad. Si  $f(x)$  es finito entonces la masa en el intervalo  $(x, x + dx)$  es igual a  $f(x) dx$ .

Los impulsos  $p_i \delta(x - x_i)$  pueden ser considerados como masas de puntos  $p_i$  colocados en  $x_i$ . La masa total en el eje  $x$  es igual a 1. La distribución  $F(x)$  es igual a la masa en el intervalo  $(-\infty, x)$ .

Ahora discutiremos uno de los parámetros más importantes de una variable aleatoria: el valor esperado o media

**Definición 1.1.7** (Valor esperado). El valor esperado de una variable aleatoria  $X$  es la integral:

$$E\{X\} = \int_{-\infty}^{\infty} x f(x) dx \quad \text{----- (5.9)}$$

donde  $f(x)$  es la densidad de  $X$ .

Recordemos que una variable aleatoria no necesariamente es igual a su valor esperado para cualquier resultado experimental. Si  $f(x)$  es interpretado como una masa de probabilidad entonces el valor esperado es el centro de gravedad de esta masa. Si  $X$  es discreto entonces  $E\{X\}$  está dado por la sumatoria  $\sum x_n p_n$  el cual está expresado en términos de los valores  $x_n$  y la probabilidad  $P\{X = x_n\}$ . En el caso continuo podemos expresarla por la integral de Lebesgue:

$$E\{X\} = \int x dP \quad \text{----- (5.10)}$$

Otro parámetro importante es la *varianza* que da una noción acerca de la concentración de la función de densidad cercana al valor esperado.

**Definición 1.1.8** (Varianza). La varianza de una variable aleatoria con media  $\mu$  está dada por:

$$\sigma^2 = E\{(X - \mu)^2\} = \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx \quad \text{----- (5.11)}$$

La raíz cuadrada de  $\sigma$  es llamada *desviación estándar*.

De la ecuación anterior podemos obtener la relación importante:

$$\sigma^2 = E\{X^2 - 2X\mu + \mu^2\} = E\{X^2\} - 2\mu E\{X\} + \mu^2 = E\{X^2\} - \mu^2 = E\{X^2\} - E^2 X \quad \text{----- (5.12)}$$

Para especificar las estadísticas de una variable aleatoria, podemos usar los *momentos*.

**Definición 1.1.9** (Momentos). Dada una variable aleatoria  $X$ , sus *momentos*  $m_k$  están dados por:

$$m_k = E\{X^k\} = \int_{-\infty}^{\infty} x^k f(x) dx \quad \text{----- (5.13)}$$

Es claro que  $m_0 = 1$  y  $m_1 = E\{X\}$ .

**Definición 1.1.10** (Momento Central). La constante

$$\eta_k = E\{(X - \mu)^k\} = \int_{-\infty}^{\infty} (x - \mu)^k f(x) dx \quad \text{----- (5.14)}$$

es llamada *momento central*.

Tenemos  $\eta_0 = 1$ ,  $\eta_1 = 0$  y  $\eta_2 = \sigma^2$ . Podemos expresar los momentos centrales en términos de los momentos  $m_k$ .

$$\eta_k = \sum_{r=0}^k \binom{k}{r} (-1)^r \mu^r m_{k-r} \quad \text{----- (5.15)}$$

y similarmente determinamos  $m_k$  para los momentos centrales.

$$m_k = \sum_{r=0}^k \binom{k}{r} \mu^r m_{k-r} \quad \text{----- (5.16)}$$

También tenemos el *momento absoluto*  $M_k = E\{X^k\}$  y el *momento generalizado*  ${}_a m_k = E\{(X - a)^k\}$  y  ${}_a M_k = E\{X - a^k\}$  con respecto a  $a$ .

A continuación se considerarán dos variables aleatorias y se definirá su distribución conjunta y sus funciones de densidad.

**Definición 1.1.11** (Distribución conjunta). La función de distribución conjunta de una variable aleatoria  $X$  y una variable  $Y$  está definida por:

$$F_{XY}(x, y) = P\{X \leq x, Y \leq y\} \quad \text{----- (5.17)}$$

Las distribuciones  $F_X(x)$  y  $F_Y(y)$  son llamadas *marginales*.

En general, la distribución conjunta no puede determinarse desde las marginales, pero se relacionan entre ellas. De hecho:

$$F_{XY}(x, \infty) = F_X(x) \text{ y } F_{XY}(\infty, y) = F_Y(y) \quad \text{----- (5.18)}$$

dado que  $\{y \leq \infty\}$  {respecto  $\{x \leq \infty\}$ } es el evento cierto.

**Definición 1.1.12** (Densidad conjunta). Asumiendo que  $F_{XY} = \{x, y\}$  es parcialmente diferenciable hasta de segundo orden, la función de densidad conjunta está dada por:

$$f_{XY}(x, y) = \frac{\partial^2 F_{XY}(x, y)}{\partial x \partial y} \quad \text{----- (5.19)}$$

Como en el primer caso dimensional, podemos definir  $f(x, y)$  como una función de masa de probabilidad, extendiéndolo a variables aleatorias cuya distribución conjunta es no diferenciable:

**Definición 1.1.13** (Covarianza). La covarianza de dos variables aleatorias está definida por:

$$\text{cov}_{XY} = E\{(X - \mu_X)(Y - \mu_Y)\} \quad \text{----- (5.20)}$$

y la relación:

$$r = \frac{E\{(X - \mu_X)(Y - \mu_Y)\}}{\sqrt{E\{(X - \mu_X)^2\}E\{(Y - \mu_Y)^2\}}} = \frac{\text{cov}_{XY}}{\sigma_X \sigma_Y} \quad \text{----- (5.21)}$$

es llamada *coeficiente de correlación*.

Dos variables aleatorias  $X$  e  $Y$  son *independientes* si los eventos  $\{X \leq x\}$  y  $\{Y \leq y\}$  son independientes. Esto es,  $F_{XY}(x, y) = F_X(x)F_Y(y)$  y  $f_{XY}(x, y) = f_X(x)f_Y(y)$ . Además,  $X$  e  $Y$  son no *correlacionadas* si  $E\{XY\} = E\{X\}E\{Y\}$  y son *ortogonales* si  $E\{XY\} = 0$ .

### 5.2 Teoría Bayesiana.

Mientras es relativamente fácil estimar la distribución de una variable aleatoria dentro del ensamble de un conjunto de datos, este problema no se presenta en el procesamiento de imágenes. Típicamente, solo se tiene un conjunto de datos y donde se intenta determinar los parámetros. Para resolver este problema se requiere de una interpretación amplia dentro de la teoría de la probabilidad. Este interpretación se llama *Teoría de Probabilidad Bayesiana*. Nombrada así posteriormente al Reverendo Thomas Bayes, un matemático del siglo XVIII. De él se obtuvo el llamado *Teorema de Bayes*, el cual es el punto de partida para todos los cálculos Bayesianos.

El concepto básico en la teoría de probabilidad Bayesiana es que *todas* las probabilidades son condicionales. El uso de  $P(A)$  no tiene sentido hasta que la evidencia en la cual está basado se da. No obstante, se usará esta notación por la brevedad con la observación que representa  $P(A | \cdot)$  donde " $\cdot$ " Es el evento en el cual  $A$  esta basado.

**Definición 1.3.1** (Probabilidad Condicional). *Dado un evento C con una probabilidad no cero, la probabilidad condicional del A dada C está definida por:*

$$P(A|C) = \frac{P(A \cap C)}{P(C)} \quad \text{----- (5.22)}$$

De hecho, si  $A$  y  $C$  son mutuamente excluyentes entonces  $P(A|C) = 0$  y si  $A \subset C$  entonces  $P(A \cap C) = P(A)$ . Dado un evento  $C$ , las probabilidades condicionales  $P(\cdot|C)$  satisfacen los axiomas en la Definición 1.1.1 Este hecho nos permite definir un nuevo experimento:

**Definición 1.3.2** (Experimento Bayesiano). *Dado un experimento  $(I, B, P(A))$  y un evento  $C$  con una probabilidad no cero, definimos un nuevo experimento  $(I, B, P(A|C))$  al cual llamamos Experimento Bayesiano.*

Este experimento tiene los mismos resultados y los mismos eventos pero una nueva medida de probabilidad.

Hay dos reglas básicas para manipular probabilidades: La *regla del producto* y la *regla de la suma*.

$$\text{Regla del producto : } P(A, B|C) = P(A|C)P(B|A, C)$$

$$\text{Regla de la suma : } P(A \cup B|C) = P(A|C) + P(B|C) - P(A, B|C)$$

La regla de la suma tiene un papel importante en el teorema siguiente sobre la probabilidad total. (Por simplicidad, escribiremos  $P(A)$  en lugar de  $P(A|C)$ ). Este teorema es usado para evaluar  $P(B)$  en términos de  $P(B|A_i)$  y  $P(A_i)$ .

**Teorema 1.3.1** (Probabilidad total). *Dado  $n$  eventos mutuamente excluyentes  $A_1, \dots, A_n$  de los cuales la suma es el evento seguro.*

$$A_i \cap A_j = 0 \quad \forall i \neq j, \quad i = 1, \dots, n$$

$$\bigcup_{i=1}^n A_i = I \quad \text{----- (5.23)}$$

La siguiente ecuación es válida para cualquier evento arbitrario de  $B$ :

$$P(B) = \sum_{i=1}^n P(B|A_i)P(A_i) \quad \text{----- (5.24)}$$

Observamos que el teorema anterior todavía es válido aún si la suma de los eventos de  $A_i$  no es el evento seguro, con tal de que:

$$\bigcup_{i=1}^n A_i \supset B \quad \text{----- (5.25)}$$



A continuación se presentará el teorema de Bayes que es el teorema más importante en la teoría de la probabilidad Bayesiana. Como mencionamos anteriormente, es la base de todos los cálculos Bayesianos.

**Teorema 1.3.2 (Bayes).**

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad \text{----- (5.26)}$$

La probabilidad de  $P(A|B)$  es llamada *probabilidad a posteriori* y  $P(A)$  es la *probabilidad a priori* de  $A$ .

A continuación se definirá la *distribución condicional* y la *densidad*. Esto no es más que la interpretación de las definiciones correspondientes en el *experimento Bayesiano*  $(I, B, P(AC))$ . Como un ejemplo redefiniremos la distribución:

**Definición 1.3.3 (Distribución Condicional).** *Dado un evento  $C$  con probabilidad no cero, la distribución condicional de una variable aleatoria  $X$  está dada por:*

$$F_X(x|C) = P\{X \leq x|C\} = \frac{P\{X \leq x, C\}}{P(C)} \quad \text{----- (5.27)}$$

La *densidad condicional* es la derivada de la distribución como en el caso clásico.

Consideremos ahora la condición  $C$ . Si la expresamos en términos de la variable aleatoria  $X$  (suponemos  $C = \{b < X \leq a\}$ ) entonces la distribución anterior puede darse en términos de  $F_X(x)$ .

$$F_X(x|b < X \leq a) = \begin{cases} 1 & \text{si } x \geq a \\ F_{(a)} & \text{si } b \leq x < a \\ F_{(b)} & \text{si } x < b \end{cases} \quad \text{----- (5.28)}$$

La probabilidad total también puede expresarse en términos de la distribución:

$$F(x) = \sum_{i=1}^n F(x|A_i)P(A_i) \quad \text{----- (5.29)}$$

La probabilidad condicional  $P(AC)$  está indefinida si  $P(C) = 0$ . Si  $C$  está expresada como una variable aleatoria, a saber  $C = \{X = x\}$  entonces uno puede definir  $P(AC)$  como el límite siguiente, asumiendo que  $f(x) \neq 0$ .

$$P(A|X = x) = \lim_{\Delta_x \rightarrow 0} \frac{P(A|X < x \leq x + \Delta_x)}{f(x)} = \frac{f(x|A)P(A)}{f(x)} \quad \text{----- (5.30)}$$

De la ecuación anterior se deduce la *versión continua* del teorema de probabilidad total.

$$P(A) = \int_{-\infty}^{\infty} P(A|X = x)f(x)dx \quad \text{----- (5.31)}$$

y el teorema de Bayes.

$$f(x|A) = \frac{P(A|X = x)f(x)}{\int_{-\infty}^{\infty} P(A|X = x)f(x)dx} \quad \text{----- (5.32)}$$

Los momentos condicionales están definidos como en la sección 1.1 pero la función densidad se reemplaza por la densidad condicional. Se define la media condicional con un ejemplo.

**Definición 1.3.4** (Valor condicional esperado). *El valor condicional esperado de una variable aleatoria X, asumiendo que C está dado por:*

$$E\{X|C\} = \begin{cases} \int_{-\infty}^{\infty} xf(x|C)dx & \text{para el caso continuo.} \\ \sum_n x_n P(X = x_n|C) & \text{para el caso discreto.} \end{cases} \quad \text{----- (5.33)}$$

Ahora se tratarán dos variables aleatorias y se definirá su distribución condicional, densidad y valor esperado. Definimos la distribución condicional de una variable aleatoria en la definición 1.3.3. En lo siguiente se examinará esta definición en el caso donde la condición C está expresada en términos de otra variable aleatoria. Primero, asumimos que  $C = \{x_1 < X \leq x_2\}$ . En este caso  $P(C) = F_X(x_2) - F_X(x_1)$  y tenemos:

$$F_Y(y|x_1 < X \leq x_2) = \frac{P\{x_1 < X \leq x_2, Y \leq y\}}{P\{x_1 < X \leq x_2\}} = \frac{F_{XY}(x_2, y) - F_{XY}(x_1, y)}{F_Y(x_2) - F_Y(x_1)} \quad \text{----- (5.34)}$$

Diferenciando  $F_Y(y|x_1 < X \leq x_2)$ , la densidad es de la forma siguiente:

$$f_Y(y|x_1 < X \leq x_2) = \frac{\int_{x_1}^{x_2} f_{XY}(x, y)dx}{F_Y(x_2) - F_Y(x_1)} \quad \text{----- (5.35)}$$

A continuación, tratando un solo punto  $C = \{X = x\}$  y usando la ecuación (5.34) definimos la distribución condicional como el limite:

$$\begin{aligned}
 F_Y(y|X=x) &= \lim_{\Delta_x \rightarrow 0} F_Y(y|x < X \leq x + \Delta_x) \\
 &= \lim_{\Delta_x \rightarrow 0} \frac{F_{XY}(x + \Delta_x, y) - F_{XY}(x, y)}{F_X(x + \Delta_x) - F_X(x)} \quad \text{----- (5.36)} \\
 &= \frac{\partial F_{XY}(x, y) / \partial x}{dF_X(x) / dx}
 \end{aligned}$$

Finalmente, damos la distribución si  $C$  está especificado en términos de ambas variables aleatorias ( $C = \{X \leq a, Y \leq b\}$ ):

$$F_Y(y|X \leq a, Y \leq b) = \begin{cases} 1 & \text{si } y \geq b. \\ \frac{F_{XY}(a, y)}{F_{XY}(a, b)} & \text{si } y < b \end{cases} \quad \text{----- (5.37)}$$

También podemos definir las *distribuciones condicionales conjuntas*. Por ejemplo,  $C = \{a < X \leq b\}$ :

$$F_{XY}(x, y|a < X \leq b) = \begin{cases} \frac{F_{XY}(b, y) - F_{XY}(a, y)}{F_X(b) - F_X(a)} & \text{si } x > b \\ \frac{F_{XY}(x, y) - F_{XY}(a, y)}{F_X(b) - F_X(a)} & \text{si } a < x \leq b \\ 0 & \text{si } x \leq a \end{cases} \quad \text{----- (5.38)}$$

Un concepto importante es el *independencia condicional*.

**Definición 1.3.5** (Independencia Condicional). *Decimos que  $X_1$  es condicionalmente independiente de  $X_2$ , asumiendo  $X_3$ , si*

$$f(x_1, x_2, x_3) = f(x_1, x_3)f(x_2, x_3) \quad \text{----- (5.39)}$$

La independencia y la independencia condicional no implican otra cada una. Claramente, de la ecuación anterior no se sigue que  $f(x_1, x_2) = f(x_1)f(x_2)$  y de la independencia no se sigue la ecuación anterior.




Figura 5.0a – Función de densidad de una variable aleatoria normal.




Figura 5.0b – Función de densidad conjunta de dos variables aleatorias normales.

### 5.3 Antecedentes en los Campos Aleatorios de Markov.

Desde su comienzo en los años 60, la investigación en visión artificial ha ido evolucionando desde el diseño heurístico de algoritmos a la investigación sistemática de aproximaciones para resolver problemas de visión. En su búsqueda de soluciones, los investigadores se han dado cuenta de la importancia de la información contextual para la comprensión de las imágenes. Las restricciones de contexto son, en última instancia, necesarias en la interpretación de la información visual. Una escena se entiende en el contexto espacial y visual de los objetos que hay en ella; los objetos se reconocen en el contexto de las "características de objeto" en una representación de bajo nivel; y las características de objeto se extraen en el contexto de los píxeles de la imagen en el nivel más bajo de abstracción.

El uso de restricciones contextuales es imprescindible para un posible sistema de visión. En este proceso se han propuesto una gran cantidad de modelos de visión usando el contexto, y entre ellos está el modelo definido por los Campos Aleatorios de Markov.

La teoría de los Campos Aleatorios de Markov (CAM)<sup>2</sup> proporciona una manera conveniente y constante de modelar entidades dependientes del contexto tales como píxeles de la imagen y otras características espaciales correlacionadas. El uso práctico de los modelos de Campos Aleatorios de Markov se atribuye en gran parte a la equivalencia entre las distribuciones de probabilidad de los Campos Aleatorios de Markov y de Gibbs establecidas por [Hammersley y Clifford 1971] y posteriormente desarrolladas por [Besag 1974]. Esto nos permite modelar matemáticamente problemas de visión manejables para el análisis de imagen en el marco Bayesiano. Desde el punto de vista computacional, la característica local de los Campos Aleatorios de Markov conduce a algoritmos que se pueden implementar de una manera local o en paralelo. Además, la teoría de los Campos Aleatorios de Markov proporciona una base para computación multi-resolución.

Los modelos de Campos Aleatorios de Markov 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 mayoría de los problemas de visión pueden ser considerados como uno de etiquetado usando restricciones, debido al conocimiento a priori y a las observaciones. En este caso, la solución óptima es definida por el etiquetado MAP y se calcula minimizando la energía a posteriori.

---

<sup>2</sup>Las abreviaturas CAM o MRF serán utilizadas indistintamente para hacer referencia a los Campos Aleatorios de Markov.

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.

Los estudios basados en CAM han tenido éxito al modelar problemas de visión de bajo nivel, como son restauración de imágenes, segmentación, reconstrucción de superficies, análisis de texturas, flujo óptico, integración visual y detección de bordes. En un desarrollo inicial de un modelo CAM para la interpretación de imágenes, la solución óptima se define como el etiquetado MAP. Sin embargo, la probabilidad a posteriori se define usando reglas heurísticas en vez de las leyes de probabilidad, lo cual difiere de las promesas originales del modelo de visión 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 de visión como uno de etiquetado en el que la configuración de etiquetas representa una solución.
2. Después plantearlo como un problema de etiquetado bayesiano en el que la solución óptima se define como la configuración de etiquetas MAP.
3. Usar la distribución de Gibbs para caracterizar la distribución a priori de las configuraciones del etiquetado.
4. Definir la Función de Energía de la distribución de Gibbs.
5. Usar un algoritmo (por ejemplo, Simulated Annealing) para minimizar la Función de Energía de la distribución de Gibbs y obtener así la configuración de etiquetas MAP.

### 5.3.1 El problema del etiquetado en visión.

Muchos problemas de visión pueden ser considerados como problemas de etiquetado, de manera que la solución al problema es el conjunto de etiquetas asignado a los píxeles de la imagen. El etiquetado es una representación natural para el estudio de los Campos Aleatorios de Markov.

#### 5.3.1.1 Notación.

Un *Problema de Etiquetado* puede especificarse en términos de un *conjunto de estados* y un *conjunto de etiquetas*. Sea  $S$  un conjunto discreto con  $m$  estados.

$$S = \{1, 2, \dots, m\} \quad \text{----- (5.40)}$$

Un estado puede representar un punto o una región del espacio euclideo. El conjunto de estados puede ser clasificado en términos de su homogeneidad. Podemos notar por:

$$S = \{(i, j) / 1 \leq i, j \leq n\} \quad \text{----- (5.41)}$$

al conjunto de localizaciones de los píxeles de una imagen de 2D de tamaño  $n \times n$

Sea  $L$  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 compacto de  $\mathfrak{R}$ .

$$L_c = [x_l, x_h] \subset \mathfrak{R} \quad \text{----- (5.42)}$$

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

$$L_d = \{l_1, \dots, l_M\} = \{1, \dots, M\} \quad \text{----- (5.43)}$$

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. Por ejemplo, los elementos en el conjunto continuo de etiquetas  $\mathfrak{R}$  pueden ser ordenados en relación a "ser más pequeño que". 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.

### 5.3.1.2 El problema del etiquetado.

El problema del etiquetado consiste en asignar una etiqueta del conjunto de etiquetas  $L$  a cada estado de  $S$ . Por ejemplo, la detección de bordes en una imagen consiste en asignar una etiqueta  $f_i$  dentro del conjunto  $L = \{\text{borde}, \text{no borde}\}$  para cada estado de  $i \in S$ , donde  $S$  está formado por los píxeles de la imagen.

**Definición 1.** Llamaremos *etiquetado* a:

$$f = \{f_1, \dots, f_m\} \quad \text{----- (5.44)}$$

donde a cada estado de  $S$  se le ha asignado una de las etiquetas de  $L$ .

**Definición 2.** Llamaremos *mapping* a toda función:

$$f : S \rightarrow L \quad \text{----- (5.45)}$$

que a cada estado de  $S$  le asigna una única etiqueta  $f_i$  de  $L$ .

En terminología de Campos Aleatorios de Markov, llamaremos *configuración* al etiquetado. En visión artificial, 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 estados tienen el mismo conjunto de etiquetas  $L$ , el conjunto de todas las configuraciones posibles, es el producto cartesiano:

$$\mathfrak{S} = L \times L \times \dots \times L = L^m \quad \text{----- (5.46)}$$

donde  $m$  es el tamaño de  $S$ .

En restauración de imágenes, por ejemplo,  $L$  contiene los valores admisibles de cada pixel de  $S$  y  $\mathfrak{S}$  define todas las imágenes admisibles. Si  $L = \mathfrak{R}$ , entonces  $\mathfrak{S} = \mathfrak{R}^m$ . Si  $L$  es un conjunto discreto, entonces el tamaño de  $\mathfrak{S}$  es combinatorial. Para un problema con  $m$  estados y  $M$  etiquetas existen  $M^m$  configuraciones posibles en  $\mathfrak{S}$ .

En ciertas circunstancias, el conjunto de etiquetas puede no ser común a todos los estados (considérese, por ejemplo, un problema de emparejamiento basado en las características del objeto). En un caso extremo, cada estado  $i$  puede tener su propio conjunto de etiquetas posibles  $L_i$  y esto nos lleva al siguiente espacio de configuraciones:

$$\mathfrak{S} = L_1 \times L_2 \times \dots \times L_m \quad \text{----- (5.47)}$$

### 5.3.1.3 Clasificación del problema del etiquetado en visión.

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

- PE1: Estados homogéneos con conjunto de etiquetas continuo.
- PE2: Estados homogéneos con conjunto de etiquetas discreto.
- PE3: Estados no homogéneos con conjunto de etiquetas discreto.
- PE4: Estados 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 estados  $S$  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 pixel 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 pixel (más concretamente, entre cada par de píxeles vecinos) se le asigna una etiqueta entre  $\{\text{borde}, \text{no borde}\}$  si existen diferencias significativas entre las propiedades del par de píxeles vecinos. La restauración continua con discontinuidades es una combinación de PE1 y PE2.

El agrupamiento perceptual es un PE3. Los estados normalmente corresponden a características segmentadas inicialmente (puntos, líneas y regiones) que están ordenadas no homogéneamente. Las características fragmentarias se deben organizar en grupos perceptualmente con significado. Entre cada par de características se puede asignar una etiqueta dentro de  $\{\text{conectado}, \text{no conectado}\}$ , indicando si las características deben ser unidas.

El reconocimiento y emparejamiento de objetos basados en características es un PE3. Cada estado 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, afín o en perspectiva).

Para un problema de etiquetado discreto con  $m$  estados y  $M$  etiquetas existen  $M^m$  configuraciones posibles. Para un problema de etiquetado continuo, el número de configuraciones posibles es infinito. Sin embargo, entre todas las posibilidades, solamente algunas son óptimas en términos de algún criterio que mida el coste de las soluciones. Esto es precisamente lo que llamamos aproximación a la optimización del etiquetado en visión.

### 5.3.2 Sistema de vecinos y cliques.

Los estados de  $S$  están relacionados mediante lo que llamaremos un *sistema de vecinos*.

**Definición 3.** Llamaremos *sistema de vecinos* para el conjunto de estados  $S$  a

$$N = \{N_i / \forall i \in S\} \quad \text{----- (5.48)}$$

donde  $N_i$  es el conjunto de estados vecinos a  $i$  para los que:

1.  $i \in N_i$ ,
2.  $i \in N_j \Leftrightarrow j \in N_i$ ,

Para una rejilla regular  $S$ , el conjunto de vecinos de  $i$  está definido como el conjunto de estados próximos dentro de un radio  $r$ .



$$N_i = \{j \in S / [\text{dist}(\text{pixel}_j, \text{pixel}_i)]^2 \leq r, j \neq i\} \quad \text{----- (5.49)}$$

donde  $\text{dist}(A, B)$  denota la distancia euclídea entre A y B, y  $r$  es un número entero. Notar que los pixeles de la frontera o próximos a ella tienen pocos vecinos.




Figura 5.1 - Vecinos en una rejilla regular S.

En el sistema de vecinos de primer orden, llamado sistema de 4-vecinos, cada estado (interior) tiene cuatro vecinos, según lo mostrado en la figura 5.1(a), donde  $x$  denota al estado considerado y a sus vecinos. En el sistema de vecinos de segundo orden, también llamado sistema de 8-vecinos, hay ocho vecinos para cada estado (interior), según lo mostrado en la figura 5.1(b). Los números  $n = 1, \dots, 5$  mostrados en la figura 5.1(c) indican los estados vecinos exteriores en el sistema de vecinos de orden Q-ésimo.

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 estados cuyos elementos son los índices de los pixeles de una imagen 1D, entonces un estado interior  $i \in \{2, \dots, m-1\}$  tiene dos vecinos  $N_i = \{i-1, i+1\}$ ; y los estados de la frontera (los dos extremos) tienen un vecino cada uno,  $N_1 = \{2\}$  y  $N_m = \{m-1\}$ . El conjunto de estados de una rejilla regular rectangular  $S = \{(i, j) / 1 \leq i, j \leq n\}$ , corresponde a los pixeles de una imagen en dos dimensiones de tamaño  $n \times n$ . Cada estado interior, representado por  $(i, j)$ , tiene 4 vecinos  $N_{i,j} = \{(i-1, j), (i+1, j), (i, j-1), (i, j+1)\}$ , los estados de la frontera tienen tres y los estados de las esquinas tienen dos.

Para un conjunto irregular de estados  $S$ , el conjunto de vecinos de  $i, N_i$ , se define de la misma manera que (5.49) y corresponde a los estados próximos en un radio  $r$ .

$$N_i = \{j \in S / [\text{dist}(\text{característica}_j, \text{característica}_i)] \leq r, j \neq i\} \quad \text{----- (5.50)}$$

La función  $\text{dist}(A, B)$  necesita ser definida apropiadamente para puntos que no tienen características. Alternativamente, la vecindad se puede definir por la triangulación Delaunay (algunos algoritmos para construir la triangulación Delaunay en un espacio multidimensional pueden encontrarse en [Bowyer 1981; Watson 1981]), o su dual, los polígonos de Voronoi, en [Besag 1975].

En general, el conjunto de vecinos  $N_i$  para un conjunto irregular de estados  $S$  tiene dimensión y tamaño variables.

El par  $\{S, N\}$  es un grafo en el sentido usual, donde  $S$  contiene los nodos y  $N$  determina las relaciones entre los nodos de acuerdo con el sistema de vecinos definido.

**Definición 4.** Una *clique*  $c$  para  $\{S, N\}$  se define como un subconjunto de  $S$  tal que  $c$  consiste en un único estado  $c = \{i\}$  o un par de estados vecinos  $c = \{i, j\}$ , o tres estados vecinos  $c = \{i, j, k\}$  y así sucesivamente.

Denotamos el conjunto de cliques de un solo estado, el conjunto de cliques de dos estados, ..., por  $C_1, C_2, \dots$  respectivamente, donde

$$C_1 = \{i / i \in S\} \quad \text{----- (5.51)}$$

$$C_2 = \{\{i, j\} / j \in N_i, i \in S\} \quad \text{----- (5.52)}$$

$$C_3 = \{\{i, j, k\} / i, j, k \in S \text{ son vecinos dos a dos}\} \quad \text{----- (5.53)}$$

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

El tipo de clique para  $\{S, N\}$ , de una rejilla rectangular, viene determinado por su tamaño, dirección y orientación. La siguiente figura muestra diferentes tipos de cliques para sistemas de vecinos de primer y segundo orden. A medida de que aumenta el orden del sistema de vecinos, el número de cliques crece rápidamente y también el coste computacional asociado.




Figura 5.2 - Cliques en una rejilla regular  $S$ .

### 5.3.3 Campos Aleatorios de Markov.

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. Se usan en el problema del etiquetado en visión para establecer las distribuciones de probabilidad de las etiquetas.

**Definición 5.** Sea  $F = \{F_1, \dots, F_m\}$  una familia de variables aleatorias definidas en  $S$ , donde cada variable aleatoria  $F_i$  toma un valor  $f_i$  en  $L$ . Llamaremos *Campo Aleatorio* a la familia de variables aleatorias  $F$ . Usaremos la notación  $F_i = f_i$  para denotar que el suceso  $F_i$  toma el valor  $f_i$ .

**Definición 6.** Un suceso conjunto  $\{F_1 = f_1, \dots, F_m = f_m\}$ , abreviadamente  $F = f$ , es una *realización* de  $F$ . Llamaremos *configuración* del suceso conjunto  $F$  a  $f = \{f_1, \dots, f_m\}$ .

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

**Definición 7.** Una familia de variables aleatorias  $F$  se dice que es un *Campo Aleatorio de Markov* sobre  $S$  con respecto a  $N$ , si y solo si:

1.  $P(F = f) > 0 \quad \forall f \in \mathfrak{F}$ . ----- (5.54)

2.  $P(F_i = f_i / F_j = f_j, j \in d, j \neq i) = P(F_i = f_i / F_j = f_j, j \in N_i)$ , (propiedad Markoviana) ----- (5.55)

La condición (1) es para exigir que  $F$  sea un Campo Aleatorio. La condición (2) se llama característica local. Se dice que la probabilidad de un suceso local a  $i$  condicionado a todos los sucesos restantes es equivalente a aquella condicionada a los sucesos vecinos de  $i$ . Puede demostrarse que la probabilidad conjunta  $P(F = f)$  de cualquier Campo Aleatorio se determina únicamente por estas probabilidades condicionales locales. Cualquier  $F$  cumpliendo estas condiciones es un Campo Aleatorio de Markov con respecto a tal sistema de vecinos.

Un Campo Aleatorio de Markov puede tener otras características tales como homogeneidad e isotropía. Diremos que es homogéneo si  $P(f_i = f_j)$  se calcula sin importar la posición relativa del estado  $i$  en  $S$ . La isotropía se considerará posteriormente cuando definamos las funciones "clique potenciales".

Para ciertos problemas puede ser necesario definir más de un Campo Aleatorio de Markov, cada uno de ellos definido en uno de los conjuntos espaciales de estados con intersección no vacía.

El concepto de Campos Aleatorios de Markov es una generalización del de Procesos de Markov (PM) que han sido extensamente utilizados en análisis de secuencias. Los PM se definen normalmente en dominios de tiempo más que en dominios de espacio. Son una secuencia de variables aleatorias  $\dots, F_1, \dots, F_m, \dots$  definidas sobre un conjunto de índices de tiempo  $\{\dots, l, \dots, p, \dots\}$ . Un PM unilateral de orden  $n$ -ésimo satisface

$$P(f_i / \dots, f_{i-2}, f_{i-1}) = P(f_i / f_{i-1}, \dots, f_{i-n}) \quad \text{----- (5.56)}$$

Un PM bilateral no causal depende no solamente del pasado sino también del futuro. Un PM bilateral de orden  $Q$ -ésimo satisface

$$P(f_i / \dots, f_{i-2}, f_{i-1}, f_{i+1}, f_{i+2}, \dots) = P(f_i / f_{i+n}, \dots, f_{i+1}, f_{i-1}, \dots, f_{i-n}) \quad \text{----- (5.57)}$$

Se generaliza en un Campo Aleatorio de Markov cuando los índices del tiempo son considerados como índices espaciales. Hay dos aproximaciones para especificar un Campo Aleatorio de Markov, en términos de probabilidades condicionales  $P(f_i / f_N)$  y en términos de probabilidad conjunta  $P(f)$ . Besag (1974) discute la aproximación mediante la probabilidad conjunta en vista de las desventajas de la aproximación mediante la probabilidad condicional: en primer lugar, no hay método obvio disponible para deducir la probabilidad conjunta de las probabilidades condicionales asociadas. En segundo lugar, las probabilidades condicionales están sujetas a algunas condiciones de consistencia no obvias y altamente restrictivas. En tercer lugar, la especificación natural de equilibrio en un proceso estadístico es en términos de probabilidad conjunta en vez de en términos de distribución condicional de las variables.

Afortunadamente, un resultado teórico sobre la equivalencia entre los Campos Aleatorios de Markov y la distribución de probabilidad de Gibbs proporciona medios de especificar la probabilidad conjunta de un Campo Aleatorio de Markov matemáticamente manejables.

#### 5.3.4 Segmentación y reconstrucción de imágenes utilizando Campos Aleatorios de Markov.

Los Campos Aleatorios de Markov fragmentan una imagen en áreas de textura similar. La segmentación proporciona una base para la detección de líneas, clasificación de la imagen y reconocimiento de patrones. Otra aplicación de la segmentación de imágenes es la restauración de imágenes degradadas bajo alguna forma de ruido.

Si se considera que una imagen consiste de varios objetos distintos y que estos objetos completan una imagen objeto. La manera en que estos objetos interactúan entre sí (ocultando, sombreando, etc.), además de los elementos con textura de la superficie, se combinan para darnos la imagen visual, o la imagen de cómo esos objetos aparecen ante nosotros. Cuando esta imagen visual viaja a través de algún medio de la transmisión antes de que pueda ser observado realmente, se involucra ruido en esta etapa, lo que significa que la imagen final observada incluye alguna cantidad de ruido.

En general, se asume que la imagen observada  $G'$  es el resultado de algo de ruido agregado a la imagen visual  $G$ .

$$G' = (G * b) + e$$

donde  $b$  es el punto manchado (o función de punto spread) y  $e$  es ruido (para propósitos prácticos,  $e$  es normalmente asumido como ruido blanco Gaussiano). Esta expresión describe el proceso avanzado de cómo la imagen visual se observa. Para encontrar la imagen original, el proceso inverso tiene que ser encontrado.

El propósito de segmentar la imagen es obtener la imagen  $G_0$  objeto de la imagen observada dada  $G'$ . Para la restauración de la imagen, la imagen  $G'$  se usa junto con la imagen objeto  $G_0$  para derivar la imagen visual  $G$ .

Los Campos Aleatorios de Markov se utilizan para diversas operaciones sobre imágenes dependiendo de la forma de las funciones de energía:

- Eliminación de ruido.
- Filtros de diferentes tipos.
- Segmentación de texturas.
- Visión estereoscópica (recuperación de profundidad)
- Reconocimiento de objetos.

### 5.3.5 Distribución de Gibbs.

**Definición 8.** Diremos que un conjunto de variables aleatorias  $F$  es un Campo Aleatorio de Gibbs en  $S$  con respecto a  $N$  si y solo si sus configuraciones siguen una distribución de Gibbs. Una distribución de Gibbs tiene la siguiente función de densidad:

$$P(f) = \frac{1}{Z} e^{-\frac{1}{T} U(f)} \quad \text{----- (5.58)}$$

donde:

$U(f)$  = Función de energía.

$Z$  = Constante de normalización.

$T$  = Temperatura.

La función de energía  $U(f)$  viene definida por:

$$U(f) = \sum_c V_c(f) \quad \text{----- (5.59)}$$

suma de las funciones "clique potenciales",  $V_c(f)$ , para todas las cliques posibles  $C$ .

El valor de  $V_c(f)$  depende de la configuración local de la clique  $c$ . Obviamente, la distribución Gaussiana es un caso especial de la familia de distribuciones de Gibbs.

Diremos que un Campo Aleatorio de Gibbs es homogéneo si  $V_c(f)$  es independiente de la posición relativa de la clique  $c$  en  $F$ . Es considerablemente 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 en visión por conveniencia matemática y computacional. La isotropía es una propiedad de regiones independientes de la dirección.

$P(f)$  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. Con la temperatura cercana a cero, la distribución se concentra alrededor de los mínimos globales de la energía. Dada  $T$  y  $U(f)$ , podemos generar la "clase de patrones" muestreando el espacio de configuraciones  $\mathfrak{F}$  de acuerdo con  $P(f)$ .

Para los problemas de etiquetado discretos, una función *clique potencial*  $V_c(f)$  se puede especificar por un número de parámetros. Por ejemplo, sea  $f_c = \{f_i, f_j, f_k\}$  la configuración local en una clique triple  $c = \{i, j, k\}$ ,  $f_c$  toma un número finito de estados y, por lo tanto, toma un número finito de valores. Para los problemas de etiquetados continuos,  $f_c$  puede variar continuamente. En este caso,  $V_c(f)$  es una función continua (posiblemente a trozos) de  $f_c$ .

A veces, puede ser conveniente expresar la energía de una distribución de Gibbs como la suma de varios términos, cada uno correspondiente a cliques de distinto tamaño, es decir:

$$U(f) = \sum_{c \in C} V_c(f) = \sum_{\{i\} \in C_1} V_1(f_i) + \sum_{\{i,j\} \in C_2} V_2(f_i, f_j) + \dots \quad \text{----- (5.60)}$$

La función anterior implica una distribución homogénea de Gibbs porque  $V_1, V_2, \dots$ , son independientes de las localizaciones  $i, j, k$ . En 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 especialmente importante es cuando sólo se consideran las cliques de tamaño dos como máximo. En este caso, la energía puede también ser escrita como

$$U(f) = \sum_{i \in S} V_1(f_i) + \sum_{i \in S} \sum_{j \in N_i} V_2(f_i, f_j) \quad \text{----- (5.61)}$$

Considerando el segundo sumatorio de la ecuación anterior, y siendo  $\{i, j\}$  y  $\{j, i\}$  dos cliques distintas en  $C_2$  (ya que los estados de la clique están ordenados), la probabilidad condicional puede escribirse como:

$$P(f_i / f_{N_i}) = \frac{e^{-\left[ V_1(f_i) + \sum_{j \in N_i} V_2(f_i, f_j) \right]}}{\sum_{f_i \in \Omega_i} e^{-\left[ V_1(f_i) + \sum_{j \in N_i} V_2(f_i, f_j) \right]}} \quad \text{----- (5.62)}$$

### 5.3.6 Equivalencia Markov-Gibbs.

Un Campo Aleatorio de Markov se caracteriza por sus propiedades locales (propiedades Markovianas) mientras que un Campo Aleatorio de Gibbs se caracteriza por sus propiedades globales (la distribución de probabilidad de Gibbs). El teorema de Hammersley-Clifford [Hammersley y Clifford 1971] establece la equivalencia entre estos dos tipos de características.

**Teorema 1.**  $F$  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  $N$ .

Veamos primero que un Campo Aleatorio de Gibbs es un Campo Aleatorio de Markov.

Sea  $P(f)$  una distribución de Gibbs en  $S$  con respecto al sistema de vecinos  $N$ . Consideremos la probabilidad condicional

$$P(f_i / f_{N_i}) = \frac{P(f_i, f_{N_i})}{P(f_{N_i})} = \frac{P(f)}{\sum_{f' \in L} P(f')} \quad \text{----- (5.63)}$$

Donde  $f = \{f_1, \dots, f_{i-1}, f_i, f_{i+1}, \dots, f_m\}$  es cualquier configuración que contenga todos los estados de  $f_{N_i}$ , posiblemente, el  $i$ .

Sustituyendo  $P(f) = \frac{1}{Z} e^{-\left[\sum_c V_c(f)\right]}$ , lo cual también proporciona una fórmula para calcular la probabilidad condicional de las funciones potenciales, tenemos que:

$$P(f_i / f_{N_i}) = \frac{e^{-\sum_{c \in A} V_c(f)}}{\sum_{f' \in L} e^{-\sum_{c \in A} V_c(f')}} \quad \text{----- (5.64)}$$

Dividimos  $L$  en dos conjuntos  $A$  y  $B$ , de manera que  $A$  es el conjunto de cliques que contienen a  $i$  y  $B$  el conjunto de cliques que no contienen a  $i$ . Entonces podemos escribir:

$$P(f_i / f_{N_i}) = \frac{\left[ e^{-\sum_{c \in A} V_c(f)} \right] \left[ e^{-\sum_{c \in B} V_c(f)} \right]}{\sum_{f' \in L} \left[ e^{-\sum_{c \in A} V_c(f')} \right] \left[ e^{-\sum_{c \in B} V_c(f')} \right]} \quad \text{----- (5.65)}$$

Como  $V_c(f) = V_c(f')$  para cualquier clique  $c$  que no contenga a  $i$ ,  $e^{-\sum_{c \in B} V_c(f)}$  se simplifica en el numerador y en el denominador. Por lo tanto, esta probabilidad depende solamente de los potenciales de las cliques que contienen  $i$ .

$$P(f_i / f_{N_i}) = \frac{e^{-\sum_{c \in A} V_c(f)}}{\sum_{f' \in L} e^{-\sum_{c \in A} V_c(f')}} \quad \text{----- (5.66)}$$

Es decir, depende de la etiqueta en los vecinos de  $i$ . Esto prueba que un Campo Aleatorio de Gibbs es un Campo Aleatorio de Markov.

La prueba de que un Campo Aleatorio de Markov es un Campo Aleatorio de Gibbs es mucho más complicada. Un resultado sobre la representación única de Campos Aleatorios de Gibbs proporciona tal prueba.

La elección de las funciones clique potenciales para un Campo Aleatorio de Markov específico no es única; pueden existir muchas opciones equivalentes que especifiquen la misma distribución de Gibbs. Sin embargo, existe un potencial normalizado único, llamado *potencial canónico*, para cada Campo Aleatorio de Markov.

**Definición 9.** Sea  $L$  un conjunto de etiquetas numerables. Diremos que una función clique potencial  $V_c(f)$  está *normalizada* si,  $V_c(f) = 0 \forall i \in c$ , con  $f_i \in L$ .

Griffeath (1976) establece la relación matemática entre la distribución  $P(f)$  de un Campo Aleatorio de Markov y la representación canónica única de las funciones clique potenciales  $V_c(f)$  en la correspondiente distribución de Gibbs.

**Teorema 2.** Sea  $F$  un Campo Aleatorio en un conjunto finito  $S$  con características locales  $P(f_i / f_N)$ . Entonces  $F$  es un Campo Aleatorio de Gibbs con *función potencial canónica* definida por:

$$V_c(f) = \begin{cases} 0 & c = 0 \\ \sum_{b \subset c} (-1)^{|c-b|} \ln P(f^b) & c \neq 0 \end{cases} \quad \text{----- (5.67)}$$

donde  $|c-b|$  es el número de elemento del conjunto  $c-b$  y son:

$$f_i^b = \begin{cases} f_i & i \in b \\ b & \text{otro caso} \end{cases} \quad \text{----- (5.68)}$$

la configuración  $f$  para los estados de  $b$  y valor 0 para los estados fuera de  $b$ .

Para un conjunto no vacío  $c$ , la función clique potencial se puede obtener como:

$$V_c(f) = \sum_{b \subset c} (-1)^{|c-b|} \ln P(f_i^b / f_N^b) \quad \text{----- (5.69)}$$

donde  $i$  es cualquier elemento de  $b$ .

Esta función potencial canónica es única para el correspondiente Campo Aleatorio de Markov. Usando este resultado podemos calcular la función clique potencial  $V_c(f)$  si conocemos  $P(f)$ .

Sin embargo, en Campos Aleatorios de Markov que utilizan distribuciones de Gibbs,  $P(f)$  se define después de que se determine  $V_c(f)$  y por lo tanto, es difícil calcular el potencial canónico  $V_c(f)$  directamente a partir de  $P(f)$ . No obstante, hay una manera indirecta: usar una representación no canónica para calcular  $P(f)$  y después de usar el resultado de Griffeath para obtener la representación canónica única.



El valor práctico del teorema es que proporciona una manera simple de especificar la probabilidad conjunta. Se puede definir la probabilidad conjunta  $P(F = f)$  especificando las funciones clique potenciales  $V_c(f)$  y eligiendo las funciones potenciales apropiadas para el comportamiento deseado del sistema. De esta manera, se codifica el conocimiento a priori sobre las interacciones entre las etiquetas.

Cómo elegir las formas y los parámetros de las funciones potenciales para una codificación apropiada de restricciones es muy importante a la hora de modelar un Campo Aleatorio de Markov.

Las formas de las funciones potenciales determinan la forma de la distribución de Gibbs. La distribución de Gibbs está completamente definida cuando se han especificado todos los parámetros de las funciones potenciales.

Para calcular la probabilidad conjunta de un Campo Aleatorio de Markov, que tiene una distribución de Gibbs, es necesario dar un valor a  $Z$ ,  $T$  y  $U(f)$ . Dado que la suma es un número combinatorio de configuraciones, el coste computacional es muy elevado. El cálculo se puede hacer mediante el estimador MAP en modelos de visión basados en Campos Aleatorios de Markov cuando  $V_c(f)$  no contiene parámetros desconocidos.

Sin embargo, esto no es verdad cuando la estimación de los parámetros es también una parte del problema. En el último caso, la función de energía  $U(f) = U(f / \theta)$  es también función de los parámetros  $\theta$ . Para evitar la gran dificultad planteada, en la práctica se calcula una aproximación de la probabilidad conjunta.

#### 5.4 Estimación Bayesiana.

Primero, se construirá un estimador Bayesiano para el *campo de la etiqueta*. Usando los resultados de la sección 5.2 se puede definir tanto la probabilidad conjunta como la condicional en términos de las distribuciones *a priori* y *posteriori*.

$$P_{X,F}(\omega, f) = P_{F|X}(f|\omega)P_X(\omega)$$

$$P_{X,F}(\omega, f) = \frac{P_{X,F}(\omega, f)}{P_F(f)} = \frac{P_{F|X}(f|\omega)P_X(\omega)}{P_F(\omega)} \quad \text{----- (5.70)}$$

Dado que la realización del campo de observación es conocido,  $P(f)$  es constante y puede escribirse como:

$$P_{X,F}(\omega, f) \propto P_{F|X}(f|\omega)P_X(\omega) \quad \text{----- (5.71)}$$

El estimador es la función de decisión  $\delta$  siguiente:

$$\delta: \phi \rightarrow \Omega$$

$$f \rightarrow \delta(f) = \hat{\omega} \quad \text{----- (5.72)}$$

y el correspondiente riesgo de Bayes está dado por:

$$r(P_X, \delta) = E\{R(\omega, \delta(f))\} \quad \text{----- (5.73)}$$

donde  $R(\omega, \delta(f))$  es una función de costo. El estimador Bayesiano de riesgo mínimo es:

$$\hat{\omega} = \arg \min_{\omega' \in \Omega} \int_{\omega \in \Omega} R(\omega, \omega') P_{X|F}(\omega|f) d\omega \quad \text{----- (5.74)}$$

(2.14)

A continuación se explicarán los tres mejores estimadores Bayesianos conocidos.

### 5.4.1 Máximo A Posteriori (MAP).

El estimador MAP es el utilizado más frecuentemente en el procesamiento de imágenes. Su función de costo está definida por:

$$R(\omega, \omega') = 1 - \Delta_{\omega'}(\omega) \quad \text{----- (5.75)}$$

(2.15)

donde  $\Delta_{\omega'}(\omega)$  es la masa Dirac en  $\omega'$ .

Claramente, esta función tiene el mismo costo para todas las diferentes configuraciones de  $\omega'$ . De las ecuaciones (5.74) y (5.75), el estimador MAP del campo de la etiqueta está dado por:

$$\hat{\omega}^{MAP} = \arg \max_{\omega' \in \Omega} P_{X|F}(\omega'|f) \quad \text{----- (5.76)}$$

Este estimador da, para una observación dada  $f$ , los modos de la distribución a posteriori, que es el más probable etiquetado dada la observación  $f$ . La ecuación anterior es un problema de optimización combinatorial el cual requiere de algoritmos especiales como el de Recocido Simulado.

### 5.4.2 Modos Marginal a Posteriori (MPM).

Definimos la función de costo del estimador MPM como:

$$R(\omega, \omega') = \sum_{s \in S} (1 - \Delta_{\omega'_s}(s)) \quad \text{----- (5.77)}$$

Remarcamos que la función anterior se relaciona con el número de sitios  $s \in S$  tal que  $\omega_s \neq \omega'_s$ . La solución de la ecuación (5.74) está dada por:

$$\forall s \in S : \omega_s^{MPM} = \arg \max_{\omega_s \in \Omega_s} P_{X_s|F}(\omega_s|f) \quad \text{----- (5.78)}$$

El cual da la configuración que maximiza el marginal a posteriori de cada sitio  $P_{X_s|F}(\cdot|f)$ .

5.4.3 Campo Intermedio (MF).

La función de costo es la siguiente:

$$R(\omega, \omega') = \sum_{s \in S} (\omega_s - \omega'_s)^2 \quad \text{----- (5.79)}$$

De las ecuaciones (5.74) y (5.79) tenemos:

$$\forall s \in S : \hat{\omega}_s^{MF} = \int_{\omega \in \Omega} \omega_s P_{X|F}(\omega|f) d\omega \quad \text{----- (5.80)}$$

El valor condicional esperado de X está dado por  $F = f$  que es el valor intermedio de X.

5.5 Ejemplos de modelos Markovianos.

En este apartado vamos a introducir la definición de algunos modelos útiles de Campos Aleatorios de Markov para modelar características de la imagen tales como regiones y texturas. Estamos interesados en sus distribuciones de probabilidad condicionales y conjuntas, y en sus correspondientes funciones de energía. Dependiendo de cómo está definida la función de energía podemos agruparlos en: Auto-Modelos y Modelos Logísticos Multinivel.

5.5.1 Auto-Modelos.

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 estados. Entonces la función clique potencial queda definida por

$$U(f) = \sum_{i \in S} V_1(f_i) + \sum_{i \in S} \sum_{j \in S} V_2(f_i, f_j) \quad \text{----- (5.81)}$$

A la que llamamos energía de segundo orden porque se calcula para cada clique formada por dos estados. Podemos 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  $G_i(\bullet)$  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 es:

$$U(f) = \sum_{i \in C_1} f_i G_i(f_i) + \sum_{i,j \in C_2} \beta_{i,j} f_i f_j \quad \text{----- (5.82)}$$

**Definición 10.** El modelo anterior recibe el nombre de *auto-modelo*. Los auto-modelos se pueden clasificar más a fondo según las suposiciones hechas sobre las  $f_i$ .

**Definición 11.** Un *auto-modelo* se dice que es 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:

$$U(f) = \sum_{i \in C_1} \alpha_i f_i + \sum_{(i,j) \in C_2} \beta_{i,j} f_i f_j \quad \text{----- (5.83)}$$

donde  $\beta_{i,j}$  puede ser interpretado como la interacción entre los coeficientes.

Cuando el sistema de vecinos  $N$  es una rejilla (4 vecinos en una rejilla 2D, o 2 vecinos en una rejilla 1D), entonces el modelo *auto-logístico* se reduce al modelo de *Ising*. La probabilidad condicional para el modelo *auto-logístico* con  $L = \{0, 1\}$  es:

$$P(f_i / f_{N_i}) = \frac{e^{\alpha_i f_i + \sum_{j \in N_i} \beta_{i,j} f_i f_j}}{\sum_{f_i \in \{0,1\}} e^{\alpha_i f_i + \sum_{j \in N_i} \beta_{i,j} f_i f_j}} = \frac{e^{\alpha_i f_i + \sum_{j \in N_i} \beta_{i,j} f_i f_j}}{1 + e^{\alpha_i + \sum_{j \in N_i} \beta_{i,j} f_j}} \quad \text{----- (5.84)}$$

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

**Definición 12.** Diremos que un *auto-modelo* es un *auto-modelo binomial* si  $f_i$  toma valores en  $\{0, 1, \dots, M-1\}$  y cada  $f_i$  tiene una distribución condicional binomial con  $M$  pruebas y probabilidad de éxito  $q$ .

$$P(f_i / N_i) = \binom{M-1}{f_i} q^{f_i} (1-q)^{M-1-f_i} \quad \text{----- (5.85)}$$

donde:

$$q = \frac{e^{\alpha_i + \sum_{j \in N_i} \beta_{i,j} f_j}}{1 + e^{\alpha_i + \sum_{j \in N_i} \beta_{i,j} f_j}} \quad \text{----- (5.86)}$$

La correspondiente función de energía es de la forma:

$$U(f) = \sum_{i \in C_1} \ln \binom{M-1}{f_i} - \sum_{i \in C_1} \alpha_i f_i - \sum_{(i,j) \in C_2} \beta_{i,j} f_i f_j \quad \text{----- (5.87)}$$

que se reduce al modelo autologístico cuando  $M=1$ .

**Definición 13.** Diremos que un *auto-modelo* es un *auto-modelo-normal*, llamado Campo Aleatorio de Markov Gaussiano, si el conjunto de etiquetas  $L$  es  $\mathcal{R}$  y la distribución de probabilidad conjunta es una normal multivariante. Su función de probabilidad condicional es:

$$P(f_i / f_{N_i}) = \frac{1}{2\pi\sigma^2} e^{-\frac{1}{2\sigma^2} \left[ f_i - \mu_i - \sum_{j \in N_i} \beta_{i,j} (f_j - \mu_j) \right]^2} \quad \text{----- (5.88)}$$

que es una distribución normal con media condicional.

$$E(f_i / f_{N_i}) = \mu_i - \sum_{j \in N_i} \beta_{i,j} (f_j - \mu_j) \quad \text{----- (5.89)}$$

y varianza condicional

$$\text{var}(f_i / f_{N_i}) = \sigma^2 \quad \text{----- (5.90)}$$

La probabilidad conjunta es una distribución de Gibbs.

$$p(f) = \frac{\det(B)}{(2\pi\sigma^2)^m} e^{-\frac{1}{2\sigma^2} (f-\mu)^T B (f-\mu)} \quad \text{----- (5.91)}$$

Donde  $f$  se considera un vector,  $\mu$  es vector  $m \times 1$  de las medias condicionales, y  $B = [b_{i,j}]$  es la *matriz de interacción* de  $m \times m$  cuyos elementos de la diagonal son 1 y el resto de los elementos  $(i, j)$  es  $-\beta_{i,j}$ , es decir,  $b_{i,j} = \delta_{i,j} - \beta_{i,j}$  con  $\beta_{i,j} = 0$ . Por lo tanto, las funciones clique potenciales, de un solo estado y de dos estados, para el modelo auto-normal son:

$$\begin{aligned} V_1(f_i) &= (f_i - \mu_i)^2 / 2\sigma^2 \\ V_2(f_i, f_j) &= \beta_{i,j} (f_i - \mu_i)(f_j - \mu_j) / 2\sigma^2 \end{aligned} \quad \text{----- (5.92)}$$

respectivamente.

Un campo con ruido Gaussiano independiente es un caso especial de Campo Aleatorio de Markov cuya energía de Gibbs consiste únicamente en funciones clique potenciales de un solo estado. Como las funciones clique potenciales de todos los órdenes superiores son cero, no hay interacción del contexto en el ruido Gaussiano independiente.  $B$  está relacionado con la matriz de covarianza  $\Sigma$  ya que  $B = \Sigma^{-1}$ .

La condición necesaria y suficiente para que  $p(f) = \frac{\det(B)}{(2\pi\sigma^2)^m} e^{-\frac{1}{2\sigma^2} (f-\mu)^T B (f-\mu)}$  sea una verdadera función de probabilidad es que  $B$  sea simétrica y definida positiva.

**Definición 14.** Un modelo relacionado es el modelo *simultáneo de auto-regresión* (SAR). Este modelo, distinto del modelo *auto-normal* que está definido por  $m$  funciones de probabilidad condicional, viene determinado por un conjunto de  $m$  ecuaciones

$$f_i = \mu_i + \sum_{j \in N_i} \beta_{i,j} (f_j - \mu_j) + \varepsilon_i \quad \text{----- (5.93)}$$

Donde  $\varepsilon_i$  son Gaussianas independientes,  $\varepsilon_i \approx N(0, \sigma^2)$ . También genera la clase de todas las distribuciones normales multivariante con función de probabilidad conjunta

$$p(f) = \frac{\det(B)}{(2\pi\sigma^2)^m} e^{-\frac{1}{2\sigma^2}(f-\mu)^T B (f-\mu)} \quad \text{----- (5.94)}$$

donde  $B$  se define como se ha comentado previamente.

**5.5.2 Modelo Logístico Multinivel.**


El modelo *auto-logístico* se puede generalizar al modelo *logístico multinivel*. (MLL), también llamado *proceso de Strauss* y *modelo generalizado de Ising*. Hay  $M (>2)$  etiquetas discretas en el conjunto de etiquetas  $L = \{1, \dots, M\}$ . Un clique potencial depende del tipo  $c$  (tamaño, dirección y orientación posible) de la clique y de la configuración local  $f_c = \{f_i / i \in c\}$ . Para las cliques que contienen más de un estado ( $c > 1$ ), definimos las funciones clique potenciales MLL como:

$$V_c(f) = \begin{cases} \zeta_c & \text{si todos los estados de } c \text{ tienen la misma etiqueta} \\ -\zeta_c & \text{en otro caso} \end{cases} \quad \text{----- (5.95)}$$

Donde  $\zeta_c$  es el potencial para las cliques del tipo  $c$ ; para cliques de un solo estado, depende de la etiqueta asignada al estado:

$$V_c(f) = V_c(f_i) = \alpha_I \quad \text{si } f_i = I \in L_I \quad \text{----- (5.96)}$$

Donde  $\alpha_I$  es el potencial para la etiqueta  $I$ . La siguiente figura muestra los tipos de cliques y los parámetros asociados en sistemas de vecinos de segundo orden (8 vecinos).



**Figura 5.3 – Tipos de cliques y parámetros potenciales asociados en sistemas de vecinos de segundo orden (8 vecinos). Los estados son los puntos y las líneas muestran las relaciones entre vecinos.**

Asumiremos que un modelo MLL es de segundo orden, si y solo si  $\alpha$  (para cliques de un estado) y  $\beta$  (para cliques de dos estados) son parámetros distintos de cero. La función clique potencial para cliques de dos estados es:

$$V_2(f_i, f_j) = \begin{cases} \beta_c & \text{si los estados de la clique } \{i, j\} = c \in C_2 \\ -\beta_c & \text{en otro caso} \end{cases} \quad \text{----- (5.97)}$$

Donde  $\beta_c$  es el parámetro  $\beta$  para las cliques del tipo  $c$ , y  $C_2$  es el conjunto de cliques de dos estados. Para un sistema de 4 vecinos hay cuatro tipos de cliques de dos estados (figura 5.3) y cuatro tipos de  $\beta_c$ . Cuando el modelo es isotrópico los cuatro toman el mismo valor. Debido a su simplicidad el modelo en parejas MLL se ha utilizado extensamente para modelar regiones y texturas. Cuando el modelo MLL es isotrópico, la probabilidad condicional puede ser expresada como sigue:

$$P(f_i = I / f_{N_i}) = \frac{e^{-\alpha_i - \beta_{n_i}(I)}}{\sum_{I=1}^M e^{-\alpha_i - \beta_{n_i}(I)}} \quad \text{----- (5.98)}$$

donde  $n_i(I)$  es el número de estados en  $N_i$  que están etiquetados por  $I$ .

Cuando hay solamente dos etiquetas, 0 y 1, se reduce a

$$P(f_i / f_{N_i}) = \frac{e^{\alpha_i + \sum_{j \in N_i} \beta_{i,j} f_j}}{\sum_{f_i \in \{0,1\}} e^{\alpha_i + \sum_{j \in N_i} \beta_{i,j} f_j}} = \frac{e^{\alpha_i + \sum_{j \in N_i} \beta_{i,j} f_j}}{1 + e^{\alpha_i + \sum_{j \in N_i} \beta_{i,j} f_j}} \quad \text{----- (5.99)}$$

## 5.6 Métodos locales y globales de minimización.

### 5.6.1 Optimización Combinatoria.

En 1953 Metrópolis et al. propusieron un algoritmo para la simulación de la evolución de un sólido a equilibrio térmico.

En 1983 Kirkpatrick et al. se dan cuenta de la analogía entre minimizar la función de coste de un problema de optimización combinatoria y el lento enfriamiento de un sólido hasta que alcanza su estado de mínima energía. Sustituyendo coste por energía y ejecutando el algoritmo de Metrópolis a una sucesión decreciente de valores de temperatura, obtuvieron un algoritmo que llamaron Recocido Simulado (*Simulated Annealing*).

Hay dos formas de resolver un problema de optimización combinatoria:

- Usar un algoritmo de optimización (elevado coste temporal)
- Usar un algoritmo de aproximación (coste temporal razonable pero solución no óptima)

El *Recocido Simulado* es un algoritmo general de aproximación. Está basado en técnicas de aleatorización pero incorpora aspectos relacionados con algoritmos de mejora iterativa.

Un algoritmo de mejora iterativa presupone:

- Definición del espacio de configuraciones.
- Función de coste.
- Mecanismo de generación de transiciones de una configuración a otra a partir de pequeñas perturbaciones.

### 5.6.2 Función de energía y su optimización.

La mayoría de los problemas de visión artificial se formulan como criterios de optimización debido a las incertidumbres existentes, tales como ruido, solapamientos, ambigüedad en la interpretación visual, etc.

En estas condiciones no se pueden obtener soluciones exactas y hay que recurrir a aproximaciones de la solución óptima.

El problema de *optimización* basada en visión se puede resumir en tres pasos:

- Representación del problema.
- Definición de la función objetivo.
- Diseño y utilización de algoritmos de optimización.

El papel de la Función de Energía en problemas de minimización en visión es doble:

- Como medida cuantitativa de la calidad de la solución
- Como guía en la búsqueda de la solución mínima.

Dado que cada punto en una imagen puede tomar diferentes valores es importante usar métodos que ayuden a encontrar una energía mínima para obtener una probabilidad máxima de la(s) posible(s) solución(es); es decir, para encontrar el valor o valores más probables para cada punto en la imagen.

Hay dos aproximaciones básicas en la formulación de la Función de Energía:

- En la aproximación *paramétrica*, el tipo de distribución es conocido y parametrizado por algunos coeficientes.
- En la aproximación *no paramétrica*, no se hace ninguna suposición sobre las distribuciones.

Los dos aspectos más importantes de la función de energía son su *forma* y los *parámetros* implicados. La función de energía se puede expresar  $E(f/d, \theta)$ .

Puesto que los parámetros forman parte de la función de energía  $E(f/d, \theta)$  la solución mínima  $f^* = \arg \min_f E(f/d, \theta)$  no está definida completamente si no especificamos los parámetros. Hay que estimar de alguna forma estos parámetros.

Este es un campo de estudio muy importante en la Modelización de los Campos Aleatorios de Markov en visión.



## 5.6.3 Metrópolis.

En el algoritmo de Metrópolis (Chou & Brown, 1990; Li, 1995), dada una configuración inicial, en cada iteración a través de las posiciones de la imagen, el estado de cada posición es cambiado al estado que produce un decremento máximo de la energía, o es dejado sin cambio si no es posible alguna reducción de la energía. El proceso siempre para en un mínimo local cuando se efectúa un número preestablecido de iteraciones, el cual puede ser determinado de una manera experimental. Tal algoritmo es:

1. Dada una variable  $X$ , tomar su valor inicial  $vx$  y calcular su energía  $U(X)$  con ese valor.
2. Asignar al azar a  $X'$ , un valor  $nvx$  del conjunto de posibles valores que puede tomar una variable y calcular  $U(X')$ .
3.  $\Delta U = U(X') - U(X)$ .
4. Si  $(\Delta U < 0)$   $vx = nvx$   
 sino  
 con probabilidad  $P = e^{(-B \cdot \Delta U)}$  y  
 $umbral = RAND\_MAX * P$   
 Si  $(rand() < umbral)$   $vx = nvx$   
 sino dejar  $X$  con su valor inicial (con probabilidad  $P = 1 - e^{(-B \cdot \Delta U)}$ ).

$rand()$  es una función que genera un número al azar entre 0 y  $RAND\_MAX$ .  $RAND\_MAX$  es una constante que representa el número aleatorio más grande que puede generar  $rand()$ .

$B$  es un parámetro que al ir creciendo puede ayudar a que el algoritmo converja. En el recocido simulado con el algoritmo de Metrópolis se va decrementando la probabilidad de pasar a estados de mayor energía. Esto permite al algoritmo escapar de mínimos locales hacia un mínimo global.

5.6.4 Recocido Simulado (*Simulated Annealing*).

El Recocido Simulado (*Simulated Annealing*) presentado entre 1982 y 1985 por Cerny y Kirkpatrick *et al.* es un poderoso algoritmo estocástico para una optimización combinatoria. Este método simula un procedimiento físico aplicado en algunos sólidos como metales y cerámicas, el cual consiste en calentarlos a una temperatura muy elevada y después dejarlos enfriar lentamente, para darles el temple que necesitan, es decir, que obtengan una configuración de baja energía. Si el enfriamiento se efectúa demasiado rápido, el sólido puede llegar a estados meta-estables en lugar de llegar al estado de equilibrio, en el cual las partículas forman retículas perfectas y el sistema está en su más bajo nivel de energía, mientras en los meta-estables existen defectos en forma de estructuras de alta energía.

Para cada temperatura la simulación puede necesitar mucho tiempo para que el sistema pueda alcanzar un estado de equilibrio, esto es conocido como termalización. La secuencia de temperatura y el número de iteraciones utilizadas para termalizar el sistema a cada temperatura comprende una parte esencial del Recocido.

Este método es aplicado a una amplia gama de problemas de distintas áreas, ya que se enfoca en los métodos de búsqueda local para resolver el problema de mínimos locales, asegurándonos (respetando sus fundamentos) la convergencia hacia un óptimo global del problema.

El fundamento del Recocido Simulado es el algoritmo de Metrópolis, en el cual un sistema es inicializado con una configuración particular; a partir de ella se construye un nuevo esquema utilizando un desplazamiento aleatorio. Si la energía de este nuevo estado es más baja que el estado anterior, el cambio es aceptado incondicionalmente y el sistema le actualiza. Si la energía es mayor, la nueva configuración es aceptada probabilísticamente.

Este procedimiento permite al sistema moverse de forma consistente hacia los estados de mas baja energía, incluso "saltar" fuera del mínimo local debido a la aceptación probabilística de algunos movimientos ascendentes. Si la temperatura es incrementada logarítmicamente, el Recocido Simulado garantiza una solución óptima.

En trabajos de visión con MRF, el Recocido Simulado emplea un esquema de temperatura variable para minimizar la función de energía a *posteriori*  $U(\mathbf{Y} | \mathbf{X})$ , donde  $\mathbf{X}$  representa la imagen original e  $\mathbf{Y}$  representa la imagen segmentada. La optimización consiste en encontrar un elemento  $\Omega_0 = \omega \in \Omega$ , donde  $\omega$  es de energía mínima.

#### 5.6.4.1 Planteamiento para minimizar la función de energía.

1. Sea  $U^*$  la energía máxima en todas las configuraciones y  $U$ , la energía mínima, la diferencia entre las dos energías es:  $\Delta U = U^* - U$ .
2. Al emplear un muestreador de Gibbs con temperatura  $T_n$ , que varía después de cada barrido, la variación de la temperatura cumple:

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

$$T_n \geq \frac{N_s \Delta U}{\log n} \quad \text{para} \quad n \geq 2, \quad \text{donde} \quad N_s \quad \text{es el número de sitios en la imagen}$$

3. Para toda configuración inicial  $\Gamma$  de la imagen, y para toda configuración de una iteración cualquiera  $\omega$ , se tiene:

$$\lim_{n \rightarrow \infty} P(\mathbf{Y}^{(n)} = \omega \mid \mathbf{Y}^{(0)} = \Gamma) = P(\omega)$$

donde  $P(\omega)$  corresponde a la medida de probabilidad de Gibbs. Así existe una convergencia hacia una realización dada con una probabilidad que sigue la distribución de Gibbs global.

## 5.6.4.2 Algoritmo de Recocido Simulado.

## 1. Inicialización.

- Determinación aleatoria de la solución  $Y^{(0)}$  (la clase de cada pixel debe determinarse mediante un generador de números aleatorios, con distribución uniforme, en el rango de número de clases).
- Escoger una temperatura inicial  $T_0$  suficientemente elevada.

2. Iniciar una etiquetación  $f$ .

- Para todas las iteraciones: desde  $N_{it} = 0$  hasta  $N_{it} = n$ 
  - Barrer secuencialmente la imagen y en cada etapa ( $n$ ):
    - Escoger un sitio  $r = i^n$ , su valor es  $Y_r^n$  y su configuración de vecindad es  $V_r^n$ .
    - Efectuar el sorteo de una variable aleatoria (Clase "elección") con distribución uniforme:  $\varepsilon \in \Omega$ .

## 3. Criterio de Metrópolis.

- Calcular la variación de la energía local asociada al sitio  $i$ :

$$\Delta U = U(\varepsilon | V_r^n, X) - U(Y_r^n | V_r^n, X)$$

- Dos eventualidades pueden surgir:

$$\text{Si } \Delta U \leq 0, \quad Y_r^{n+1} = \varepsilon$$

$$\text{Si } \Delta U > 0, \quad Y_r^{n+1} = \varepsilon \quad \text{con probabilidad} \quad \prod (Y_r^{n+1} \rightarrow \varepsilon) = e^{-\frac{\Delta U}{T_n}}$$

## 4. Continuar con el punto (2) hasta que el equilibrio sea alcanzado.

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

## 5.6.4.3 Energía y ley de Temperatura.

La aplicación del Recocido Simulado en la optimización de la función de energía a *posteriori*  $U(Y | X)$ , asegura la convergencia hacia el mínimo global (punto C) y evita la convergencia a los mínimos locales (punto B). El cambio de la clase del pixel analizado a la clase propuesta es aceptado incondicionalmente solo cuando  $\Delta U < 0$  (punto A).




Figura 5.4 – Gráfica de la Función de Energía.

Dos esquemas surgen, dependiendo de la etapa donde se aplica el decremento en temperatura, estos son:

Recocido Homogéneo (Homogeneous Annealing)	Recocido No Homogéneo (Inhomogeneous Annealing)
1. Inicialización aleatoria.	1. Inicialización aleatoria.
2. Introducir una perturbación mínima.	2. Introducir una perturbación mínima.
3. Criterio de Metrópolis.	3. Criterio de Metrópolis.
4. Volver al punto (2) hasta alcanzar Un equilibrio.	5. Volver al punto (2) hasta barrer toda la imagen.
5. Decrementar temperatura.	5. Decrementar temperatura.

Tabla 5.1 - Tipos de Recocido en función del decremento de temperatura.

Es conocido que el Recocido Simulado converge con probabilidad unitaria hacia el óptimo global si la ley de temperatura  $T_k$  decrece menos rápidamente que  $\frac{C}{\ln(k)}$ , para una cierta constante C independiente de k. Debido a la lentitud en convergencia del esquema  $\frac{C}{\ln(k)}$ , en la práctica, la ley de temperatura se aproxima por una ley exponencial. A causa de esta aproximación, la convergencia hacia el óptimo global no está garantizada.

La temperatura inicial  $T_0$  debe ser escogida tal que todas las transiciones pueden ser aceptadas con una probabilidad diferente a cero. Es muy difícil determinar tal valor ya que se encuentra ligado a los valores máximos y mínimos de la función de energía. En la práctica se escoge un valor  $T_0$  relativamente bajo para asegurar una convergencia rápida. Así, por ejemplo, un valor de 2 resulta generalmente adecuado.

Las desventajas se pueden resumir en

- Terminan en un óptimo local
- El óptimo local obtenido depende de la configuración inicial
- En general, no se tiene una cota superior del coste temporal

Las soluciones obtenidas por el algoritmo Recocido Simulado no dependen de la configuración inicial.

El Recocido Simulado (*Simulated Annealing*) puede verse como un algoritmo que intenta transformar continuamente la configuración actual en una de sus vecinas con una cierta probabilidad.

Desde el punto de vista matemático, este tipo de conducta puede describirse a través de una cadena de Markov cuyos estados corresponden a las configuraciones globales del sistema en intervalos discretos de tiempo.

### 5.7 Modelo de Potts.

La finalidad del modelo de Potts es asociar a cada pixel una etiqueta de un conjunto finito. Denotemos por  $X$  la imagen de datos originales y por  $Y$  la imagen segmentada, el proceso de segmentación consiste en maximizar la probabilidad condicional  $P(X | Y)$ , que de la regla de Bayes (ecuación 5.26) se tiene:

$$P(Y | X) \approx P(X | Y) P(Y) \quad \text{----- (5.100)}$$

$P(Y)$  está referido como el modelo a *priori* mientras que  $P(X | Y)$  está referida como el término de manejo de datos. En estudios prácticos, el modelado probabilístico se basa en el análisis de energía de los cliques. Esto produce funciones de energía relacionadas a la llamada función potencial. El primer término probabilístico (el modelo a *priori*) está a menudo compuesto de un modelo de Potts. La función de energía asociada con este modelo es la siguiente:

$$U(Y) = - \sum_{\langle i, j \rangle} \beta \delta_{y_i, y_j} \quad \text{----- (5.101)}$$

Los cliques tienen dos elementos, definiendo interacciones estrechamente pares. El coeficiente  $\beta$  define la propiedad de homogeneidad de la solución, esto es, el mayor de estos términos, el más probable de los dos pixeles adyacentes que pueden tener la misma etiqueta.

Los términos de manejo de datos están definidos por las funciones de costeo dependiendo de la etiqueta  $l$  y denotada por  $f^l$ . Los parámetros inducidos son directamente extraídos de los datos. El potencial asociado, aplicado a los cliques de primer orden se define como.

$$U(X | Y) = \sum_{\langle i, j \rangle} \sum_l f^l(x^i) \delta_{y_i, l} = 1 \quad \text{----- (5.102)}$$

donde  $x_i$  e  $y_i$  son los datos y los valores de las etiquetas respectivamente en el sitio  $i$ .

El problema de segmentación consiste en minimizar la energía global:


$$U(X|Y) + U(Y) \quad \text{----- (5.103)}$$

En la estructura del MAP, el proceso de minimización está desarrollado por una técnica estocástica como el Recocido Simulado (convergiendo próximamente con un mínimo global). Remarcando la minimización puede incluso ser desarrollada por técnicas determinísticas como los Modos de Iteración Condicional (rápido, pero converge solo aproximándose al mínimo local).

---

# CAPÍTULO 6

## PRIMERA ETAPA: PRE – SEGMENTACIÓN BAYESIANA



*Imagen en colores falsos del continente Europeo. En ella se aprecia la distribución de las zonas de vegetación existentes todavía en dicho continente.*

### 6.1 Introducción.

El problema de la segmentación es fundamental en muchas áreas del análisis de datos e imágenes. El proceso implica la división de una larga secuencia de datos dentro de pequeños segmentos homogéneos, cuyos límites pueden ser interpretados como cambios en el sistema físico. Esta aproximación ha demostrado ser extremadamente útil para diferentes problemas prácticos dentro del procesamiento de señales y de imágenes.

En el marco de una estimación probabilista es importante disponer de la ley condicional de las observaciones (relacionada con la fuente de datos). Esto es, conocer  $P(X|Y)$ . La probabilidad  $P(X|Y)$  describe enteramente el proceso de adquisición de la imagen.

$P(X|Y)$  es obtenible mediante:

- a) Un modelo del sistema imagen y leyes de probabilidad.
- b) Cálculo numérico.

En este sentido, lo que interesa es maximizar la ley de la probabilidad de la función buscada (segmentación, restauración, etc.), condicionada a las medidas hechas (la imagen observada).

$$\text{Por Bayes: } P(Y|X) = \frac{P(X|Y)P(Y)}{P(X)}$$

El método MAP (*máximo a posteriori*) consiste en encontrar la configuración  $y$  que maximiza la distribución *a posteriori*  $P(Y|X)$ , o bien minimiza una función equivalente de energía:

$$y = \arg \max P(Y = y | X = x) = \arg \min U(y | x)$$

### 6.2 Proceso de Segmentación.

El proceso de segmentación propuesto consta de tres etapas desarrolladas en los capítulos 6, 7 y 8 (respectivamente) de esta tesis. La Figura 6.1 muestra el diagrama general de bloques de dicho proceso en cada una de sus etapas.




Figura 6.1 - Etapas del proceso de segmentación.



En la primera etapa se desarrolla una pre-segmentación Bayesiana. Para ello es necesario especificar inicialmente dos ventanas de entrenamiento que identifiquen típicamente a las clases: urbano y NO urbano (Figura 6.2). Estas dos clases constituyen el punto de partida del proceso de segmentación, por lo cual, su adecuada elección permitirá la obtención de mejores resultados en etapas posteriores. Después de la elección de las ventanas de entrenamiento se desarrolla el proceso de pre-segmentación bajo un esquema bayesiano.

Dado que inicialmente no se conoce la probabilidad *a priori*  $P(w_i)$ , en esta etapa se consideran como equiprobables a las probabilidades de ocurrencia de las clases  $P(w_i)$ . Esta primera etapa utiliza una Función Bayesiana de clasificación que permite la pre-clasificación de la imagen (Figura 6.5).




Figura 6.2 – Primera etapa. Especificación de clases y Pre-Segmentación Bayesiana.

En la segunda etapa se efectúa nuevamente una segmentación Bayesiana. En este caso, se utilizan ahora las probabilidades *a priori*  $P(w_i)$  actualizadas y obtenidas previamente en la etapa anterior (Figura 6.3). La Función Bayesiana de clasificación utilizada es la misma de la etapa anterior (Figura 6.5). El resultado de las dos etapas anteriores es una imagen segmentada en dos clases: urbana y NO urbana. La clase urbana se enmascara para no procesarla en la última etapa. La clase NO urbana entra a la última etapa de segmentación.




Figura 6.3 – Segunda etapa. Actualización de probabilidades y reclasificación Bayesiana.

En la última etapa es necesario especificar tres nuevas clases que definan típicamente: sombras, vegetación y otras (Figura 6.4). Para esta tercera etapa se utiliza un esquema de segmentación Markoviano y el modelo de Potts, solamente se utiliza la clase NO urbana obtenida en la etapa previa para el proceso de segmentación.

El resultado final de esta última etapa es una imagen segmentada en tres clases. A continuación se procede al desenmascaramiento del clases urbana. El resultado final de todo el proceso de segmentación es una imagen segmentada en cuatro clases: urbana, sombras, vegetación y otras.

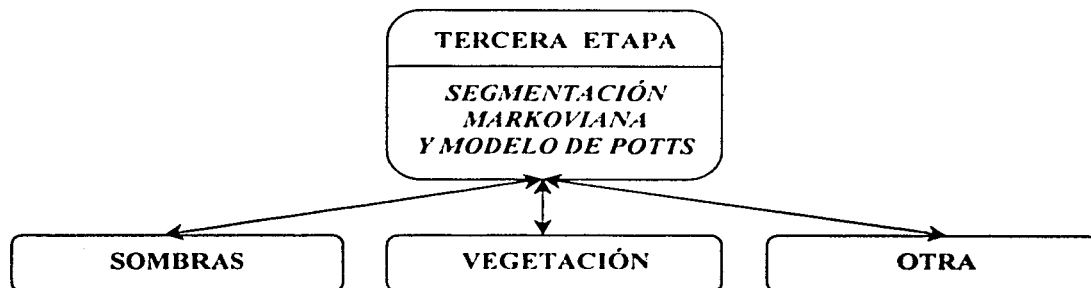


Figura 6.4 – Tercera etapa. Especificación de clases, segmentación Markoviana y modelo de Potts.

### 6.3 Pre-Segmentación Bayesiana.

Considerando la regla de Bayes

$$P(w_i | X) = \frac{P(X | w_i)P(w_i)}{P(X)} \quad \text{----- (6.1)}$$

Siendo  $X$  la imagen original y  $w_i$  las clases, con  $i = 0, 1$  (en esta etapa solo se tendrán dos tipos de clases: urbana y NO urbana).

Además, se tiene que:

$P(w_i | X)$  representa la probabilidad a posteriori.

$P(X | w_i)$  es la probabilidad conjunta de  $X$  dado  $w_i$ .

$P(w_i)$  es la probabilidad a priori de la clase  $w_i$ .

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

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

#### 6.3.1 Algoritmo de Pre-Clasificación.

##### PRIMERA PARTE

1. Sobre la imagen de prueba se definen 2 ventanas de entrenamiento que identifiquen a las clases: urbana y NO urbana dentro de dicha imagen. La adecuada elección de estas clases permitirá que en cada una de las etapas siguientes se obtengan mejores resultados.
2. Sobre cada ventana se calculan los parámetros estadísticos más importantes como son: la media, la desviación estándar y la varianza.

3. A continuación se aproximan las probabilidades conjuntas del numerador de la regla de Bayes mediante las funciones mostradas en la Figura 6.5. Ellas indican la probabilidad condicional de que un pixel dado pertenezca a la clase  $W_i$ , es decir, pertenezca a la clase urbana o NO urbana.

**SEGUNDA PARTE: PRE-CLASIFICACION**

4. Pre-clasificación de la imagen (representada por X) :

- Emplear la aproximación de la regla de Bayes :

$$P(W_i | X) \approx P(X | W_i)P(W_i) \quad \text{----- (6.2)}$$

- Considerar como equiprobables a las probabilidades de ocurrencia de las clases,  $P(W_i)$ .
- Analizar pixel por pixel la imagen X, clasificando de acuerdo a los valores máximos de probabilidad *a posteriori*:  $\arg \max \{ P(W | X) \}$ .




Figura 6.5 - Términos de probabilidad condicional  $P(X | W_i)$

6.3.2 Función Bayesiana de Clasificación.

La Función Bayesiana de Clasificación (FBC) permite la clasificación de cada pixel de la imagen original, esto es, decide la pertenencia de un pixel a una clase específica definida dentro de la segmentación de acuerdo al valor máximo de la probabilidad *a posteriori*:  $arg \max \{ P(W | X) \}$ . La FBC utilizada en la Pre-segmentación Bayesiana (primera etapa, capítulo 6) y en la Segmentación Bayesiana (segunda etapa, capítulo 7) se especifica gráficamente en la Figura 6.5. A continuación se describe el procedimiento de clasificación en términos de la probabilidad condicional  $P(X | w_i)$ .

El nivel de gris de cada pixel se proyecta sobre cada una de las funciones para determinar la probabilidad condicional de que el pixel pertenezca a la clase  $w_i$ . El número de funciones está determinado por el número de clases definidas previamente.

- Si el nivel de gris del pixel analizado ( $x$ ) está en el rango:  $0 \leq x < m_0$ , la probabilidad condicional para la clase  $w_0$  (clase inicial) es de 1. Para las demás clases la probabilidad será de 0.
- Si el nivel de gris del pixel analizado ( $x$ ) está en el rango:  $x \geq m_n$ , la probabilidad condicional para la clase  $w_n$  (última clase) es de 1. Para las demás clases la probabilidad será de 0.
- Si el nivel de gris del pixel analizado ( $x$ ) no está en alguno de los casos anteriores se realiza la diferencia entre las medias de las clases de la siguiente manera:  $S = m_i - m_a$ , donde  $m_i$  es la media de la clase siguiente y  $m_a$  es la media de la clase actual. El resultado de esta diferencia se divide entre 4, es decir,  $S/4$ .
- Si el nivel de gris del pixel analizado ( $x$ ) está en el rango:  $m_a \leq x < m_a + (S/4)$ , la probabilidad condicional para la clase  $w_a$  (clase actual) es de 1. Para las demás clases la probabilidad será de 0.
- Si el nivel de gris del pixel analizado ( $x$ ) está en el rango:  $m_a + (S/4) \leq x \leq m_a + (3/4)S$ , la probabilidad condicional para la clase  $w_a$  (clase actual) se determina a través de las siguientes funciones:

Pendiente negativa (clase actual)	Pendiente positiva (clase siguiente)
$y = -\frac{2}{S}x + \frac{2}{S}m_a + \frac{3}{2}$	$y = \frac{2}{S}x - \frac{2}{S}m_i - \frac{1}{2}$

donde:

- $y$  : Es la probabilidad condicional.
- $x$  : Es el pixel analizado.
- $m_a$  : Es la media de la clase analizada (actual).
- $S$  : Es la diferencia de las medias de clase, es decir,  $S = m_i - m_a$ .  
 $m_i$  es la media de la clase siguiente y  $m_a$  es la media de la clase actual.

- Ambas funciones tienen que ser calculadas para determinar si el pixel pertenece a la clase actual o a la clase siguiente. El pixel pertenecerá a la clase que tenga una probabilidad condicional mayor. Para las demás clases la probabilidad será de 0.
- Si el nivel de gris del pixel analizado ( $x$ ) está en el rango:  $m_a + (3/4)S < x < m_s$ , la probabilidad condicional para la clase  $w_s$  (clase siguiente) es de 1. Para las demás clases la probabilidad será de 0.
- La probabilidad condicional obtenida anteriormente se multiplica por las probabilidades de ocurrencia de clases  $P(w_i)$  (en la primera etapa las  $P(w_i)$  se consideran como equiprobables, en la segunda etapa las  $P(w_i)$  se actualizan con base al número de ocurrencia de clases obtenidas en la primera etapa). El pixel analizado pertenecerá a la clase cuya probabilidad *a posteriori* sea mayor.

### 6.4 Imágenes de Prueba y Áreas de estudio.

La imagen de prueba utilizada en el presente trabajo corresponde a una fotografía aérea de la zona de la Ciudad Deportiva de la Ciudad de México. Esta imagen tiene unas dimensiones de 4487 x 4731 píxeles, con 8 bits por píxel y 256 niveles de gris (Figura 6.6). Esta imagen fue seleccionada debido a que cuenta con las zonas típicas requeridas en este trabajo, tales como: áreas urbanas, NO urbanas, sombras, vegetación y otros.

Dentro de esta imagen se seleccionaron 3 diferentes áreas (Figura 6.7) que tuvieran las zonas antes mencionadas. Cada una de ellas tiene unas dimensiones de 600 x 600 píxeles, con 8 bits por píxel y 256 niveles de gris. En adelante, se hará referencia a ellas como: Área 1, Área 2 y Área 3 de estudio. La Figura 6.8 muestra el Histograma de la imagen original de prueba.



Figura 6.6 - Imagen original de prueba.



Figura 6.7 - Áreas seleccionadas para estudio y segmentación.




Figura 6.8 - Histograma de la imagen original de prueba.

6.4.1 Área de estudio #1.




Figura 6.9 - Área de estudio #1 Metro-Puebla.




Figura 6.10 - Mapa cartográfico del Área de estudio #1.




Figura 6.11 - Definición de clases urbana y NO urbana Área de estudio #1.

En la Figura 6.11 se aprecian las dos ventanas de entrenamiento escogidas para el proceso de pre-segmentación Bayesiana del área de estudio #1.

Estas están definidas como:

No. Clase	Descripción
1	NO urbana
2	Urbana

El área de estudio #1 comprende un recorte de 600x600 píxeles. Se aprecia la estación del metro puebla y parte de la Cd. Deportiva, el viaducto Río de la Piedad y la Av. 8




Figura 6.12 Histograma del Área de estudio #1.




Figura 6.13 Pre-segmentación del Área de estudio #1.

Clase Color	Descripción
1	NO urbana
2	Urbana

Área de estudio #1 – Pre-Segmentación – Resultados									
No. Clase	X1	Y1	X2	Y2	Tamaño Ventana	Media ( $\mu$ )	Varianza	Desv. Estándar	No. Ocurrencias
1	0	100	30	180	30x80	104.3458	240.6133	15.5117	224147
2	535	320	565	340	30x20	164.4050	2590.6230	50.8982	135853

Tabla 6.1 – Parámetros estadísticos de la Pre-segmentación del Área de estudio #1.

6.4.2 Área de estudio #2.




Figura 6.14 Área de estudio #2 Eje 3 sur (Añil) y Cd. Deportiva.




Figura 6.15 Mapa cartográfico del Área de estudio #2.



Figura 6.16 Definición de clases urbana y NO urbana Área de estudio #2.

En la Figura 6.16 se aprecian las dos ventanas de entrenamiento escogidas para el proceso de pre-segmentación Bayesiana del área de estudio #2.

Estas están definidas como:

No. Clase	Descripción
1	NO urbana
2	Urbana

El área de estudio #2 comprende un recorte de 600x600 píxeles. Se aprecia parte de la Cd. Deportiva, el Eje 3 Sur (añil) y una pequeña parte de la colonia Granjas México.







Figura 6.17 - Histograma del Área de estudio #2.



Color Clase	Descripción
1	NO urbana
2	Urbana

Figura 6.18 - Pre-segmentación del Área de estudio #2.

Área de estudio #2 - Pre-Segmentación - Resultados									
No. Clase	N1	Y1	N2	Y2	Tamaño Ventana	Media (μ)	Varianza	Desv. Estándar	No. Ocurrencias
1	490	15	570	60	80x45	78.9233	42.2202	6.4977	264703
2	130	60	180	110	50x50	199.8032	879.4802	29.6560	95297

Tabla 6.2 - Parámetros estadísticos de la Pre-segmentación del Área de estudio #2.

6.4.3 Área de estudio #3.




Figura 6.19 Área de estudio #3 Churubusco.




Figura 6.20 Mapa cartográfico del Área de estudio #3.




Figura 6.21 Definición de clases urbana y NO urbana Área de estudio #3.

En la Figura 6.21 se aprecian las dos ventanas de entrenamiento escogidas para el proceso de pre-segmentación Bayesiana del área de estudio #3.

Estas están definidas como:

No. Clase	Descripción
1	NO urbana
2	Urbana

El área de estudio #3 comprende un recorte de 600x600 píxeles. Se aprecia parte de la Av. Río Churubusco y de la colonia Jardín Balbuena.




Figura 6 22 - Histograma del Área de estudio #3.



Color Clase	Descripción
1	NO urbana
2	Urbana

Figura 6 23 - Pre-segmentación del Área de estudio #3.


Área de estudio #3 - Pre-Segmentación - Resultados									
No. Clase	X1	Y1	X2	Y2	Tamaño Ventana	Media ( $\mu$ )	Varianza	Desv. Estándar	No. Ocurrencias
1	380	480	480	580	100x100	93.8983	337.7758	18.3787	195182
2	405	290	460	340	55x50	201.2760	1156.4193	34.0062	164818

Tabla 6 3 - Parámetros estadísticos de la Pre-segmentación del Área de estudio #3.

---

# CAPÍTULO 7

## SEGUNDA ETAPA: SEGMENTACIÓN BAYESIANA



*Planisferio en colores falsos. Se aprecian los diferentes desiertos, lagos, mares y zonas de vegetación de todo el mundo.*

### 7.1 Segmentación Bayesiana.

Esta segunda etapa de segmentación Bayesiana es continuación de la etapa anterior (pre-segmentación Bayesiana). Esta etapa utiliza el mismo procedimiento de segmentación tratado en el capítulo anterior (capítulo 6) con la excepción de utilizar ahora las probabilidades de ocurrencia de clases  $P(W_i)$  actualizadas.

En la sección 7.3 de este capítulo se desarrolla un breve estudio comparativo de los resultados obtenidos entre el capítulo 6 (pre-segmentación Bayesiana) y el capítulo 7 (segmentación Bayesiana). En las correspondientes imágenes de cada etapa de segmentación se establecieron ventanas de zoom (acercamientos) para observar mejor los cambios en la asignación de píxeles al final de cada etapa de segmentación. También se presentan las tablas que muestran la variación de píxeles en cada etapa-

El desarrollo del algoritmo de segmentación Bayesiana se presenta en el capítulo 6 (sección 6.3.1 , primera y segunda parte) y en el capítulo 7 (sección 7.1.1 , tercera parte), el desarrollo y explicación de la Función Bayesiana de Clasificación utilizada en ambas etapas de segmentación se presenta en la sección (6.3.2).

#### 7.1.1 Algoritmo de Clasificación (continuación).

#### TERCERA PARTE: CLASIFICACION

5. El resultado previo de clasificación (capítulo 6) se utiliza para actualizar las probabilidades de ocurrencia de las clases,  $P(W_i)$ . Posteriormente, el proceso de clasificación (puntos 3 y 4) de la sección 6.3.1 del capítulo anterior se repite nuevamente.
6. Se comparan las imágenes: preclasificada y clasificada. Para tal efecto, se obtienen ventanas de 250x250 píxeles efectuando ampliaciones.

7.2 Segmentación Bayesiana de las Áreas de estudio.

7.2.1 Área de estudio #1.




Figura 7-1 - Segmentación del Área de estudio #1.

Clase	Descripción
1	NO urbana
2	Urbana

Área de estudio #1 - Segmentación - Resultados									
No. Clase	X1	Y1	X2	Y2	Tamaño Ventana	Media (μ)	Varianza	Desv. Estándar	No. Ocurrencias
1	0	100	30	180	30x80	104.3458	240.6133	15.5117	228812
2	535	320	565	340	30x20	164.4050	2590.6230	50.8982	131188

Tabla 7-1 - Parámetros estadísticos de la Segmentación del Área de estudio #1.

7.2.2 Área de estudio #2.




Figura 7-2 Segmentación del Área de estudio #2.

Color Clase	Descripción
1	NO urbana
2	Urbana

Área de estudio #2 – Segmentación – Resultados									
No. Clase	X1	Y1	X2	Y2	Tamaño Ventana	Media ( $\mu$ )	Varianza	Desv. Estándar	No. Ocurrencias
1	490	15	570	60	80x45	78.9233	42.2202	6.4977	277250
2	130	60	180	110	50x50	199.8032	879.4802	29.6560	82750

Tabla 7-2 Parámetros estadísticos de la Segmentación del Área de estudio #2.

7.2.3 Área de estudio #3.




Figura 7-3 -- Segmentación del Area de estudio #3.

Color Clase	Descripción
1	NO urbana
2	Urbana

Área de estudio #3 – Segmentación – Resultados									
No. Clase	X1	Y1	X2	Y2	Tamaño Ventana	Media ( $\mu$ )	Varianza	Desv. Estándar	No. Ocurrencias
1	380	480	480	580	100x100	93.8983	337.7758	18.3787	197931
2	405	290	460	340	55x50	201.2760	1156.4193	34.0062	162069

Tabla 7-3 - Parámetros estadísticos de la Segmentación del Area de estudio #3.



7.3 Estudio comparativo entre pre-segmentación y segmentación Bayesiana.

7.3.1 Área de estudio #1.




Figura 7.4 - Área de estudio #1 con la ventana de zoom seleccionada para comparación de resultados entre la primera y segunda etapa de segmentación.




Figura 7.5 - Resultado del Zoom del Área de estudio #1. Primera etapa - Pre-segmentación Bayesiana.




Figura 7.6 - Resultado del Zoom del Área de estudio #1. Segunda etapa - Segmentación Bayesiana

Clase Color	Descripción
1	NO urbana
2	Urbana

TESIS CON FALLA DE ORIGEN

Área de estudio #1 - Tabla comparativa de ocurrencia de clases			
No. Clase	No. Ocurrencias Pre-segmentación Bayesiana	No. Ocurrencias Segmentación Bayesiana	Diferencias entre ocurrencias de clase
1	224147	228812	4665
2	135853	131188	4665

Tabla 7.4 - Tabla comparativa de ocurrencias entre etapas de segmentación.

7.3.2 Área de estudio #2.




Figura 7-7 - Área de estudio #2 con la ventana de zoom seleccionada para comparación de resultados entre la primera y segunda etapa de segmentación.

Color Clase	Descripción
1	NO urbana
2	Urbana



Figura 7-8 - Resultado del Zoom del Área de estudio #2. Primera etapa - Pre-segmentación Bayesiana



Figura 7-9 - Resultado del Zoom del Área de estudio #2. Segunda etapa - Segmentación Bayesiana

Área de estudio #2 - Tabla comparativa de ocurrencia de clases			
No. Clase	No. Ocurrencias Pre-segmentación Bayesiana	No. Ocurrencias Segmentación Bayesiana	Diferencias entre ocurrencias de clase
1	264703	277250	12547
2	95297	82750	12547

Tabla 7-5 - Tabla comparativa de ocurrencias entre etapas de segmentación.

7.3.3 Área de estudio #3.




Figura 7.10 – Área de estudio #3 con la ventana de zoom seleccionada para comparación de resultados entre la primera y segunda etapa de segmentación.

Color Clase	Descripción
1	NO urbana
2	Urbana



Figura 7.11 – Resultado del Zoom del Área de estudio #3. Primera etapa – Pre-segmentación Bayesiana.



Figura 7.12 – Resultado del Zoom del Área de estudio #3. Segunda etapa – Segmentación Bayesiana.

Área de estudio #3 – Tabla comparativa de ocurrencia de clases			
No. Clase	No. Ocurrencias Pre-segmentación Bayesiana	No. Ocurrencias Segmentación Bayesiana	Diferencias entre ocurrencias de clase
1	195182	197931	2749
2	164818	162069	2749

Tabla 7.6 – Tabla comparativa de ocurrencias entre etapas de segmentación.

---

# CAPÍTULO 8

## TERCERA ETAPA: SEGMENTACIÓN MARKOVIANA Y MODELO DE POTTS



*Imagen satelital de Gran Bretaña. En ella se aprecia parte del día y de la noche sobre el planeta.*

### 8.1 Introducción.

Los *Campos Aleatorios de Markov* son un método genérico que se basa en conceptos de teorías de probabilidad y el cual ha sido aplicado en diferentes aspectos de visión computacional. Permiten, en una forma muy compacta y elegante, combinar el "conocimiento" previo (del mundo en general o de un tipo de imágenes) con los datos obtenidos de la imagen para el procesamiento de imágenes. Han sido aplicados principalmente en aspectos de nivel bajo, como eliminación de ruido, detección de orillas, filtrado, segmentación de texturas, etc.

Los campos de Markov surgen del problema de modelar materiales ferromagnéticos en lo que se conoce como el Modelo Ising. Se considera que se tiene una serie de dipolos en una línea que pueden estar orientados hacia "arriba" (+) o hacia "abajo" (-). El estado de cada dipolo se ve influenciado por los dipolos cercanos, de forma que lo podemos modelar con una probabilidad para cada estado que depende de los estado de los puntos vecinos. La línea puede tener diferentes configuraciones dependiendo del estado de cada punto. Un campo de Markov asigna probabilidad a cada configuración en el espacio de posibles configuraciones. Para esto se considera que la probabilidad del estado de un punto es independiente de los demás dados sus 2 vecinos.

Dadas las probabilidades condicionales de cada estado dados los vecinos, el problema central en este tipo de modelos es encontrar la probabilidad de cada una las posibles configuraciones, y en particular cual es la configuración más probable. Es decir, lo que requerimos es calcular la probabilidad conjunta dadas las probabilidades condicionales locales.

Un *campo aleatorio* es una colección de variables aleatorias indexadas por sitios (malla regular). Un *Campo Aleatorio de Markov* (CAM) es un campo aleatorio con la propiedad de "localidad",  $P(X|L) = P(X|vec(X))$ .

Se pueden tener diferentes "vecindades" (primer orden, segundo orden, etc.). En visión, las variables aleatorias las podemos asociar con píxeles directamente, o a otros entes (regiones, objetos, etc.) de mayor nivel. Entonces, podemos usar los CAM para obtener la probabilidad (o el valor más probable) de un pixel (región, ...) dada cierta información (observaciones). Para esto aplicamos el teorema de Bayes y obtenemos la probabilidad conjunta de todo el campo (imagen).

Aprovechando la propiedad de localidad de los CAM, podemos expresar la probabilidad conjunta como el producto de las probabilidades de las vecindades (cliques). Bajo este enfoque, la solución a un problema particular en visión corresponde en encontrar la configuración del CAM de mayor probabilidad o de "energía" mínima.

Los campos de Markov se pueden utilizar para realizar diversas operaciones sobre imágenes dependiendo de las formas de las funciones de energía. Algunos ejemplos de aplicaciones son los siguientes:

- Eliminación de ruido.
- Filtros de diferente tipo.
- Segmentación de texturas.
- Reconocimiento de objetos.
- Visión estereoscópica (recuperación de profundidad).
- Integración de niveles de visión.

## 8.2 El Recocido Simulado (*Simulated Annealing*).

Los campos de Markov, además de ser un conjunto de metodologías para el análisis y la representación de imágenes, están también ligados a un método específico de optimización: el *recocido simulado*. Este algoritmo permite resolver el problema de estimación en el sentido del MAP (*Máximo A Posteriori*). Muy importante además, el recocido simulado nos asegura (respetando sus fundamentos) la convergencia hacia un óptimo global del problema.

En la práctica se emplea un algoritmo de Metrópolis, con un esquema de temperatura variable, a fin de minimizar la función de energía *a posteriori*  $U(Y|X)$ . El objetivo del problema de optimización consiste en encontrar un elemento de  $\Omega_0$  donde:

$$\Omega_0 = \{\omega \in \Omega, \text{ donde } \omega \text{ es de energía mínima}\}$$

### 8.2.1 Planteamiento:

Si  $U^*$  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 deberá seguir el esquema:


$$\begin{aligned} T_n &\rightarrow 0 \text{ cuando } n \rightarrow \infty \\ T_n &\geq \frac{N \Delta U}{\log(n)} \text{ para } n \geq 2 \end{aligned}$$

donde  $N$  es el número de *sites* en la imagen

Para toda configuración inicial  $\eta$  (de la imagen) y para toda configuración de una iteración cualquiera  $\omega$ , se tiene:

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

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



## 8.3 Segmentación Markoviana.

Considerando la regla de Bayes

$$P(w_i|X) = \frac{P(X|w_i)P(w_i)}{P(X)} \quad \text{----- (8.1)}$$

Siendo  $X$  la imagen original y  $w_i$  las clases, con  $i = 0,1,2$  (en esta etapa solo se consideran 3 clases: sombras, vegetación y "otras").

Además, se tiene que:

$P(w_i|X)$  representa la probabilidad a posteriori.

$P(X|w_i)$  es la probabilidad conjunta de  $X$  dado  $w_i$ .

$P(w_i)$  es la probabilidad a priori de la clase  $w_i$ .

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

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

## 8.3.1 Proceso de segmentación.

4. Sobre la imagen de prueba se definen 3 ventanas de entrenamiento que identifiquen típicamente a las clases: sombras, vegetación y "otras", dentro de dicha imagen. La adecuada elección de estas clases permitirá que en esta última etapa se obtengan mejores resultados durante la clasificación de los píxeles (segmentación). Esta última segmentación solo se realizará sobre los píxeles que hayan sido etiquetados como clase NO urbana durante la etapa anterior (segmentación Bayesiana). Los píxeles restantes son enmascarados para no procesarlos en esta última etapa.
5. Sobre cada ventana, definida previamente, se calculan los parámetros estadísticos más importantes como son: la media, la desviación estándar y la varianza.
6. A continuación, se aproximan las probabilidades conjuntas del numerador de la regla de Bayes mediante las funciones de energía mostradas en la Figura 8.1. Ellas indican la *probabilidad condicional* de que un píxel dado pertenezca a la clase  $w_i$ , es decir, pertenezca a la clase: sombras, vegetación u "otras". El modelo de Potts se emplea para el cálculo de la energía *a priori* de clase
4. Clasificación de la imagen (representada por  $X$ ):
  - Emplear la aproximación de la regla de Bayes:

$$P(w_i|X) \approx P(X|w_i)P(w_i) \quad \text{----- (8.2)}$$

para calcular la energía *a posteriori*:

$$U(W, X) \approx U(X, W) + U(W) \quad \text{----- (8.3)}$$

- Analizar pixel por pixel la imagen X, clasificando al aplicar el algoritmo de *Recocido Simulado* (*Simulated Annealing*) desarrollado en la sección 8.3.3 .




Figura 8.1 - Términos de energía  $U(X, W)$

### 8.3.2 Función de Energía.

La Función de Energía permite la clasificación de cada pixel de la imagen original, esto es, decide la pertenencia de un pixel a una clase específica definida dentro de la segmentación. La Función de Energía utilizada para la segmentación Markoviana se especifica gráficamente en la Figura 8.1. A continuación se describe el procedimiento de clasificación en términos de energía  $U(X, W)$ .



El nivel de gris de cada pixel se proyecta sobre la función a la que pertenezca el pixel analizado, es decir, la clase a la que pertenezca el pixel. Esto permite determinar la energía condicional del pixel que pertenece a la clase  $w_i$ . El número de funciones está determinado por el número de clases definidas previamente.

- Si el nivel de gris del pixel analizado ( $x$ ) está en el rango:  $0 \leq x < m_0$ , la energía condicional para la clase  $w_0$  (clase inicial) es de 0. Para las demás clases la energía será de 1.
- Si el nivel de gris del pixel analizado ( $x$ ) está en el rango:  $x \geq m_n$ , la energía condicional para la clase  $w_n$  (última clase) es de 0. Para las demás clases la energía será de 1.
- Si el nivel de gris del pixel analizado ( $x$ ) no está en alguno de los casos anteriores se realiza la diferencia entre las medias de las clases de la siguiente manera:  $S = m_s - m_a$ , donde  $m_s$  es la media de la clase siguiente y  $m_a$  es la media de la clase actual. El resultado de esta diferencia se divide entre 4, es decir,  $S/4$ .
- Si el nivel de gris del pixel analizado ( $x$ ) está en el rango:  $m_a \leq x < m_a+(S/4)$ , la energía condicional para la clase  $w_a$  (clase actual) es de 0. Para las demás clases la energía será de 1.
- Si el nivel de gris del pixel analizado ( $x$ ) está en el rango:  $m_a+(S/4) \leq x \leq m_a+(3/4)S$  y pertenece a la clase inicial  $w_0$ , la energía condicional para la clase  $w_0$  (clase inicial) se determina a través de la función (A) y la diferencia de medias  $S = m_{sig} - m_{act}$ . Si el pixel pertenece a la última clase  $w_n$  se utilizará la función (B), para ello se utilizará la diferencia de medias de la clase actual menos la clase anterior, es decir:  $S = m_{act} - m_{ant}$ .

Para cualquier otra clase, si el pixel analizado ( $x$ ) está en el rango  $m_{ant}+(S/4) \leq x \leq m_{ant}+(3/4)S$  se utiliza la función (B) y la diferencia de medias  $S = m_{act} - m_{ant}$ . Si el pixel analizado ( $x$ ) está en el rango  $m_{act}+(S/4) \leq x \leq m_{act}+(3/4)S$  se utiliza la función (A) y la diferencia de medias  $S = m_{sig} - m_{act}$ .

Pendiente positiva (clase actual) ( A )	Pendiente negativa (clase siguiente) ( B )
$y = \frac{2}{S} x - \frac{2}{S} m_a - \frac{1}{2}$	$y = -\frac{2}{S} x + \frac{2}{S} m_s + \frac{3}{2}$

donde:

- $y$  : Es la energía condicional.
- $x$  : Es el pixel analizado.
- $m_a$  : Es la media de la clase analizada.
- $S$  : Es la diferencia de las medias de clase. Dependiendo del caso,  $S = m_{sig} - m_{act}$  ó  $S = m_{act} - m_{ant}$   
 $m_{ant}$  es la media de la clase anterior a la actual.  
 $m_{act}$  es la media de la clase actual.  
 $m_{sig}$  es la media de la clase siguiente a la actual.

La energía condicional obtenida anteriormente se suma con la probabilidad de la clase "actual" o "elección" (según sea el caso) que se obtuvo previamente usando el modelo de Potts. Esto permite calcular la variación de la energía local asociada al site  $r$  (pixel analizado).

Los métodos Bayesianos asociados a la modelización markoviana proporcionan una función de energía *no convexa* que debe ser minimizada. La aplicación del recocido simulado en la optimización de la función de energía *a posteriori* asegura la convergencia hacia el mínimo global y evita la convergencia a los mínimos locales.

8.3.3 Algoritmo de Recocido Simulado (*Simulated Annealing*).

Sea  $X$  la imagen original (en niveles de gris) e  $Y$  la imagen segmentada (por ejemplo, en cuatro clases), la simulación toma como datos iniciales a  $X$  y a la imagen de clases originada en la inicialización,  $Y^{(0)}$ . La Figura 8.2 muestra la esquematización del algoritmo de simulación, para el caso de  $n$  iteraciones:




Figura 8.2 – Simulación del algoritmo de Recocido Simulado.


Para el caso de la energía  $U(Y)$  se considera al modelo de Potts, el cual se aplica en vecindades en 8-conexidad.

## 1. Inicialización.

- Determinación aleatoria de la solución  $Y^{(0)}$  (la clase de cada píxel debe determinarse mediante un generador de números aleatorios, con distribución uniforme, en el rango del número de clases).
- Escoger una temperatura inicial  $T^{(0)}$  suficientemente elevada ( $T^{(0)} = 2.5$ ). El número de iteraciones  $N_{iter} = 50$  y el parámetro  $\beta_i = 0.35$

2. do  $N_{iter}=1, N_{iter}=n$ 

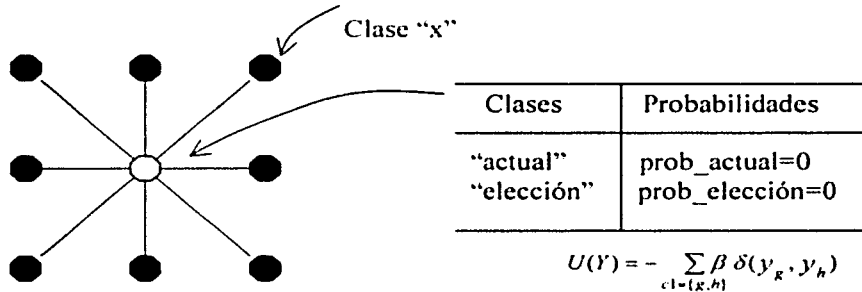
2.1 Barrer secuencialmente la imagen (por líneas y columnas).



En cada etapa (n),

- Escoger un site:  $r=s^{(n)}$ , su valor es  $Y_r^{(n)}$  y su configuración de vecindad es  $V_r^{(n)}$ .
- Efectuar el sorteo de una variable aleatoria (clase "elección") con distribución uniforme:  $\xi \in \Omega$ .

2.2 Criterio de Metrópolis y Modelo de Potts.



Análisis en 8-conexidad:

- Si "actual" = "x":  $prob\_actual = prob\_actual - \beta[actual]$
- Si "elección" = "x":  $prob\_elección = prob\_elección - \beta[elección]$

2.3 Calcular la variación de la energía local asociada al site r (pixel analizado):

- $prob\_actual = prob\_actual + potencial[actual][i][j]$
- $prob\_elección = prob\_elección + potencial[elección][i][j]$

donde  $potencial [][i][j]$  representa la energía condicional  $U(X|Y)$  e  $[i][j]$  son las coordenadas del pixel analizado.

- Si  $prob\_elección \leq prob\_actual$ :  $Y[i][j] = "elección"$

En caso contrario:

- $p = \exp - [ (prob\_elección - prob\_actual)/T^{(n)} ]$
- sorteo de una variable aleatoria  $\xi_2$  uniformemente distribuida en el rango  $[0, 1]$
- si  $\xi_2 < p$ . entonces  $Y[i][j] = "elección"$

3. Regresar al punto 2.1 hasta terminar un barrido.

4. Decrementar la temperatura:

$$T(n) = T(n-1) * 0.95$$

5. Regresar al punto 2 hasta terminar el número de iteraciones fijadas.

8.4 Segmentación Markoviana de las Áreas de estudio.

8.4.1 Área de estudio #1.



Figura 8.3 - Definición de clases - sombras, vegetación y otras. Área de estudio #1.




Figura 8.4 - Imagen aleatoria para la segmentación markoviana del Área de estudio #1.




Figura 8.5 - Segmentación markoviana final en 4 clases - urbana, sombras, vegetación y otras



Figura 8.6 - Segmentación markoviana final en colores falsos.

Área de estudio #1 - Segmentación - MRF										
Color / Clase	No. Clase	X1	Y1	X2	Y2	Tamaño Ventana	Media ( $\mu$ )	Varianza	Desv. Estándar	No. Ocurrencias
Sombras	1	325	300	345	320	20x20	60.3950	17.1368	4.1397	45978
Vegetación	2	50	70	80	110	30x40	59.8558	26.8051	5.1774	34044
Otras	3	265	540	285	590	20x50	72.6710	23.7113	4.8694	148790
Urbana	4	535	320	565	340	30x20	164.4050	2590.6230	50.8982	131188

Tabla 8.1 - Parámetros estadísticos de la Segmentación del Área de estudio #1.

8.4.2 Área de estudio #2.




Figura 8.7 - Definición de clases: sombras, vegetación y otras. Área de estudio #2.




Figura 8.8 - Imagen aleatoria para la segmentación markoviana del Área de estudio #2.



Figura 8.9 - Segmentación markoviana final en 4 clases: urbana, sombras, vegetación y otras



Figura 8.10 - Segmentación markoviana final en colores falsos.

Área de estudio #2 - Segmentación - MRF										
Color / Clase	No. Clase	X1	Y1	X2	Y2	Tamaño Ventana	Media ( $\mu$ )	Varianza	Desv. Estándar	No. Ocurrencias
Sombras	1	190	278	215	333	25x55	66.4727	29.3948	5.4217	50016
Vegetación	2	330	475	360	510	30x35	62.4857	31.0674	5.5738	135025
Otras	3	185	200	205	225	20x25	100.4240	217.8302	14.7591	92209
Urbana	4	130	60	180	110	50x50	199.8032	879.4802	29.6560	82750

Tabla 8.2 - Parámetros estadísticos de la Segmentación del Área de estudio #2.

8.4.3 Área de estudio #3.




Figura 8.11 - Definición de clases - sombras, vegetación y otras. Área de estudio #3.




Figura 8.12 - Imagen aleatoria para la segmentación markoviana del Área de estudio #3.




Figura 8.13 - Segmentación markoviana final en 4 clases - urbana, sombras, vegetación y otras



Figura 8.14 - Segmentación markoviana final en colores falsos


Área de estudio #3 - Segmentación - MRF										
Color / Clase	No. Clase	X1	Y1	X2	Y2	Tamaño Ventana	Media ( $\mu$ )	Varianza	Desv. Estándar	No. Ocurrencias
Sombras	1	295	255	310	265	15x10	65.9333	16.1834	4.0229	28043
Vegetación	2	220	130	240	150	20x20	72.4825	63.4037	7.9626	136913
Otras	3	185	185	235	235	50x50	136.7092	153.3769	12.3845	32975
Urbana	4	405	290	460	340	55x50	201.2760	1156.4193	34.0062	162069

Tabla 8.3 - Parámetros estadísticos de la Segmentación del Área de estudio #3.

---

# CAPÍTULO 9

## RESULTADOS



### 9.1 Especificaciones de plataforma, software y parámetros utilizados.

Todo el proceso de segmentación fue realizado en una plataforma con las siguientes características:

- Procesador AMD athlon a 1 GHz.
- 256 Mbytes de RAM.
- Disco Duro de 40 Gbytes.
- Tarjeta de video S3 Graphics ProSavage con 32 Mbytes de VRAM.
- Monitor SVGA con una resolución de 1024x768 pixeles.
- Sistema operativo Windows 98 SE (segunda edición).
- El lenguaje de programación utilizado fue el Borland C++ 3.1 y las librerías gráficas: TVISION 1.0 (incluida en el lenguaje Borland C++) y SVGACC.LIB versión 2.6
- Para el retoque de las imágenes segmentadas se utilizó el siguiente software: Adobe Photoshop 6.0 y CorelDRAW 10.

Los valores de inicialización utilizados en la segmentación Markoviana y en el modelo de Potts, durante la aplicación del algoritmo de Recocido Simulado, son los siguientes:

Parámetros de Segmentación Markoviana	
Número de iteraciones ( $N_{iter}$ )	50
Temperatura inicial $T^{(0)}$	2.5
$\beta_i$	0.35

La asignación del número de clase y la etiqueta correspondiente a cada una se presentan a continuación:

Definición de Clases	
No. Clase	Clase
1	Sombras
2	Vegetación
3	Otras
4	Urbana

### 9.2 Segmentaciones comparativas de las Áreas de estudio

(Markoviana, Bayesiana y Funciones Discriminantes)

Con fines de comparación y análisis, cada una de las áreas de estudio fue segmentada por diferentes métodos de segmentación. Cada una de las imágenes obtenidas se presentan en colores falsos con el fin de poder identificar cada clase segmentada. También se presenta una tabla que resume el número de ocurrencias de clase por método de segmentación así como el respectivo color asignado dentro de la imagen segmentada.

En cada área de estudio se presenta un zoom (acercamiento) por método de segmentación con el fin de obtener un mejor detalle de cada una de las imágenes segmentadas. Estos acercamientos tiene una dimensión de 250x250 pixeles. Cada área de estudio tiene unas dimensiones de 600x600 pixeles a 8 bits.



9.2.1 Área de estudio #1.




Figura 9.1 - Área de estudio #1 Metro-Puebla. Imagen original en 256 niveles de gris.



Figura 9.2 - Segmentación Markoviana final del Área de estudio #1 (en 3 etapas). Colores falsos.



Figura 9.3 - Segmentación Bayesiana del Área de estudio #1. Colores falsos.




Figura 9.4 - Segmentación por Funciones Discr. Óptimas del Área de estudio #1. Colores falsos.

Área de estudio #1 - Resultados - No. de Ocurrencias							
Clase / Color	No. Clase	Segmentación Markoviana		Segmentación Bayesiana		Segmentación Func. Discr.	
Sombras	1	45978	12.77%	35083	9.74%	41485	11.52%
Vegetación	2	34044	9.45%	22532	6.25%	59290	16.46%
Otras	3	148790	41.33%	145323	40.36%	112857	31.27%
Urbana	4	131188	36.45%	157062	43.65%	145903	40.55%

Tabla 9.1 - Número de ocurrencias por método de Segmentación del Área de estudio #1.



Figura 9.5 - Zoom del Area de estudio #1.




Figura 9.6 - Zoom de la segmentación por MRF.




Figura 9.7 - Zoom de la segmentación BAYESIANA.



Figura 9.8 - Zoom de la segmentación por FDO.

El proceso de segmentación Markoviano (en 3 etapas) permite la mejor detección de contornos y agrupación de píxeles. Esto permite que la imagen segmentada sea más homogénea al existir una mejor definición de las fronteras entre las diferentes clases. El método Bayesiano presenta algunos problemas en lo referente a la agrupación de píxeles de la misma clase y por tanto presenta algunos problemas de homogeneidad y detección de contornos. El método de segmentación por Funciones Discriminantes Óptimas presenta una buena agrupación de píxeles de la misma clase a comparación del método anterior. Sin embargo, muestra algunos errores de clasificación, pero una buena detección de contornos. Los tres métodos de segmentación anteriores presentaron algunos errores de clasificación de píxeles, como la clasificación de píxeles de la clase "Urbana". El método Markoviano y el de FDO presentaron una mejor definición de fronteras y contornos y, por lo tanto, una mejor homogeneidad en la segmentación.

9.2.2 Área de estudio #2.



Figura 9.9 Área de estudio #2 Eje 3 sur (Añil) y Cd. Deportiva. Imagen original, 256 niveles de gris.



Figura 9.10 Segmentación Markoviana final del Área de estudio #2 (en 3 etapas). Colores falsos.



Figura 9.11 Segmentación Bayesiana del Área de estudio #2. Colores falsos.




Figura 9.12 Segmentación por Funciones Discr. Óptimas del Área de estudio #2. Colores falsos.

Área de estudio #2 – Resultados – No. de Ocurrencias							
Clase / Color	No. Clase	Segmentación Markoviana		Segmentación Bayesiana		Segmentación Func. Discr.	
Sombras	1	50016	13.89%	41085	11.41%	23700	6.58%
Vegetación	2	135025	37.50%	104556	29.04%	141610	39.33%
Otras	3	92209	25.61%	112470	30.79%	110132	30.59%
Urbana	4	82750	23%	81889	22.76%	84548	23.5%

Tabla 9.2 – Número de ocurrencias por método de Segmentación del Área de estudio #2.



Figura 9.13 - Zoom del Área de estudio #2.



Figura 9.14 - Zoom de la segmentación por MRF.



Figura 9.15 - Zoom de la segmentación BAYESIANA.



Figura 9.16 - Zoom de la segmentación por FDO.

En este caso, los tres métodos de segmentación realizaron una buena clasificación de la clase "urbana" aunque presentaron algunos errores de clasificación entre las clases restantes. El método Markoviano (en 3 etapas) presentó un mejor agrupamiento de píxeles y, por lo tanto, una mayor homogeneidad en la segmentación. Los métodos restantes presentaron, en este caso, una buena uniformidad en la agrupación de píxeles aunque inferior al método Markoviano. La detección de contornos en los tres casos fue buena aunque superior en el método de segmentación por MRF. La segmentación de la clase "vegetación" fue muy aceptable en los tres casos, sin embargo, en todos ellos se presentaron errores de clasificación al confundirlas con zonas pertenecientes a la clase "sombras" y a la clase "otras". La clase "otras" también tuvo algunos problemas de clasificación al llegar a clasificarse como "urbanas" o "vegetación". La segmentación de la clase "sombras" fue buena en los tres métodos.

9.2.3 Área de estudio #3.




Figura 9.17 Área de estudio #3 Churubusco. Imagen original en 256 niveles de gris.



Figura 9.18 Segmentación Markoviana final del Área de estudio #3 (en 3 etapas). Colores falsos.




Figura 9.19 Segmentación Bayesiana del Área de estudio #3. Colores falsos




Figura 9.20 Segmentación por Funciones Discr. Óptimas del Área de estudio #3. Colores falsos.

Área de estudio #3 - Resultados - No. de Ocurrencias							
Clase / Color	No. Clase	Segmentación Markoviana		Segmentación Bayesiana		Segmentación Func. Discr.	
Sombras	1	28043	7.78%	17244	4.79%	21791	6.05%
Vegetación	2	136913	38.03%	107505	29.86%	102958	28.59%
Otras	3	2076	0.58%	6574	1.83%	9963	2.76%
Urbana	4	162069	45.04%	138727	38.54%	135636	37.69%

Tabla 9.3 - Número de ocurrencias por método de Segmentación del Área de estudio #3.




Figura 9 21- Zoom del Area de estudio #3.




Figura 9 22 Zoom de la segmentación por MRF.



Figura 9 23 Zoom de la segmentación BAYESIANA.




Figura 9 24 Zoom de la segmentación por FDO.

En esta área de estudio #3, el método de segmentación Markoviano obtuvo buenos resultados en la segmentación de cada una de las clases. Como se muestra en las imágenes respectivas, la detección de contornos y la agrupación de píxeles, en este método, fue mejor que en los métodos restantes. El método de segmentación Bayesiano registró una mayor dispersión en el agrupamiento de píxeles, principalmente entre las clases "vegetación" y "sombras". Los tres métodos de segmentación propuestos mostraron algunos problemas referentes a la clasificación errónea de píxeles, principalmente el método Bayesiano y el FDO al clasificar zonas de clase "urbana" como clase "otras". La segmentación de la clase "otras" en el método Markoviano fue mejor que en los métodos restantes ya que se obtuvo una mejor clasificación al tener una menor dispersión de los píxeles de esta clase, así como una adecuada identificación de contornos y unas regiones más homogéneas.

En las tablas 9.1 , 9.2 y 9.3 se resume el número de ocurrencias por área de estudio y por método de segmentación. Junto a cada ocurrencia, y para fines de comparación y estudio, se expresa el porcentaje de dicha ocurrencia en relación al tamaño de la imagen segmentada y al porcentaje de las restantes clases segmentadas.

En adelante, por fines prácticos, se hará referencia al método de segmentación Markoviano por método A, al método de segmentación Bayesiano por método B y al método de segmentación por Funciones Discriminantes Óptimas como método C.

En la tabla 9.1 del área de estudio #1 se muestra que para el método A el mayor número de píxeles fue asignado a la clase "otras" mientras que para el método B y C el mayor número de píxeles fue asignado a la clase "urbana". Para el método A y B la menor asignación de píxeles son para la clase "vegetación" mientras que para el método C la menor asignación fue para la clase "sombras".


En la tabla 9.2 del área de estudio #2 el menor porcentaje de asignación (píxeles asignados) fue para la clase "sombras" en los tres métodos de segmentación (A, B y C). La mayor asignación de píxeles fue para la clase "vegetación" en los métodos A y C, y para la clase "otras" en el método B.

En la tabla 9.3 del área de estudio #3 la mayor ocurrencia de píxeles fue para la clase "urbana" en los tres métodos de segmentación probados (A, B y C). La menor ocurrencia fue para la clase "sombras" también en los tres métodos de segmentación.

---

# CAPÍTULO 10

## CONCLUSIONES





El principal objetivo del procesamiento digital de imágenes es permitir manipular y analizar los datos de imágenes producidas por sensores remotos, de tal forma que sea revelada "información" que no pueda ser reconocida inmediatamente en la forma original.

Aunque la mayoría de los sensores toman datos usando los principios básicos de teledetección, el formato y la calidad de los datos varían enormemente. Estas variaciones dependerán de los diversos tipos de resoluciones de los sensores (radiométrica, espacial, espectral y temporal). Mejorando una o varias de esas resoluciones, un científico incrementará la capacidad de obtener datos de percepción remota de un objetivo con mayor precisión, realismo y utilidad.

Actualmente existen una gran variedad de técnicas para la segmentación de imágenes, algunas de propósito general y otras de propósito específico. El algoritmo de segmentación que se presenta en este trabajo permite resolver problemas de estimación en el sentido del MAP (*máximo a posteriori*).

Los métodos bayesianos asociados a la modelización markoviana proporcionan una función de energía *no convexa* que debe ser minimizada. La aplicación del recocido simulado en la optimización de la función de energía *a posteriori* nos asegura (respetando sus fundamentos) la convergencia hacia un **óptimo global** (mínimo global) del problema evitando la convergencia a los mínimos locales. Además, el *recocido simulado*, está ligado estrechamente con los Campos Aleatorios de Markov (CAM). Los campos de Markov son un conjunto de metodologías para el análisis y la representación de imágenes.

La teoría de los CAM (ó MRF) permiten describir con facilidad: los objetos de escena (es decir, el proceso de etiquetamiento de regiones) y el proceso de formación de las imágenes (a través de la estadística de datos). Por el contrario, la principal desventaja de la segmentación markoviana radica en la pérdida de resolución espacial.

Los algoritmos de segmentación generalmente están basados en dos criterios importantes a considerar: uno es la homogeneidad de la región y otro es la discontinuidad entre regiones disjuntas adyacentes. Generalmente, la imagen segmentada resultante depende de los valores umbrales predeterminados y el algoritmo falla a menudo al juntar regiones que deben estar separadas o al separar regiones que no necesitaban ser separadas, porque la información sobre la uniformidad de una región y la discontinuidad entre regiones diferentes no está bien incorporada a los algoritmos. De ahí la importancia de una adecuada integración de la información a los algoritmos a utilizar.

Como el modelo MRF tiene una potente capacidad para integrar varias informaciones visuales, ha sido aplicado a problemas tales como: restauración y segmentación de imágenes. Debido al gran número de píxeles en los que el MRF debe ser definido, requiere mucho tiempo de computación (costo computacional en la relación tiempo / resultados) para conseguir etiquetas óptimas, lo que hace difícil aplicar el modelo MRF.

El papel de una función de energía en visión basada en minimización es doble: como la medida cuantitativa de la calidad global de la solución y como una guía para la búsqueda de una solución óptima. Dado que cada punto en una imagen puede tomar diferentes valores es importante usar métodos que ayuden a encontrar una energía mínima para obtener una probabilidad máxima de la(s) posible(s) solución(es); es decir, para encontrar el valor o valores más probables para cada punto en la imagen.

La teoría de los Campos Aleatorios de Markov (CAM) proporciona una manera conveniente y constante de modelar entidades dependientes del contexto tales como píxeles de la imagen y otras características espaciales correlacionadas.

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 mayoría de los problemas pueden ser considerados como problemas de etiquetado, usando restricciones, debido al conocimiento *a priori* y a las observaciones. En este caso, la solución óptima es definida por el etiquetado MAP y se calcula minimizando la energía *a posteriori*.

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 uso del modelo CAM.

El esquema de segmentación propuesto en este trabajo de tesis obtuvo mejores resultados que el resto de los métodos de segmentación utilizados para comparación. Esto es, el esquema utilizado: pre-segmentación Bayesiana - segmentación Bayesiana - segmentación Markoviana, obtuvo resultados más robustos que el método Bayesiano y el de Funciones Discriminantes Óptimas por si mismos.

Las principales características de los resultados obtenidos en el esquema de segmentación propuesto fueron:

- La agrupación de píxeles (proceso de etiquetación) fue mejor que el resto de los métodos utilizados. Esto permitió que se obtuvieran regiones más homogéneas de segmentación.
- Se obtuvo una mejor detección de contornos (fronteras) lo que permitió una mejor definición de los límites de las regiones segmentadas.
- La segmentación de la clase "sombras" fue buena en todos los casos aunque presentó algunas confusiones con la clase "vegetación".
- La segmentación de la clase "urbana" y la clase "NO urbana", en la primera y segunda etapa de segmentación, puede considerarse buena aunque si se presentaron algunos errores de clasificación entre ambas clases. Esto debido a las características del algoritmo y de la imagen.
- También se presentaron algunas confusiones entre la clase "otras" y la clase "urbana". Esto es debido a que en la primera y segunda etapa de segmentación algunas áreas más oscuras dentro de la clase "urbana" fueron clasificadas como "NO urbanas". Posteriormente, en la última etapa estas fueron clasificadas como "otras" siendo que pertenecían realmente a la clase "urbana".

La utilización adecuada de esquemas combinados de segmentación permite la obtención de resultados más robustos. Esto es, la segmentación por un solo método no necesariamente obtiene los mejores resultados (esto debido a la características propias del algoritmo de segmentación y a las características mismas de la imagen a segmentar).

El esquema de segmentación presentado en este trabajo de tesis hace uso de varios algoritmos de segmentación (Bayesiano, Markoviano, Recocido Simulado; y para fines de comparación, el método de Funciones Discriminantes Óptimas).

En términos generales, el método Bayesiano fue el que presentó una mayor deficiencia en lo que se refiere a la agrupación de píxeles, el método de Funciones Discriminantes Óptimas presentó problemas referentes a errores de clasificación entre las distintas clases. Por último, el método propuesto en tres etapas fue el que obtuvo resultados más robustos aunque también presentó algunos errores de clasificación.

El presente trabajo, así como los resultados obtenidos en este, proyectan realizar una aportación en estudios cartográficos y de crecimiento de zonas urbanas. Esto con el fin de tener una información más actualizada y precisa que permita una mejor planificación de las zonas urbanas actuales y futuras.

---

# APÉNDICE

Sistemas de Procesamiento Digital de Imágenes.

Selected Commercial and Public Digital Image Processing Systems and their Functions  
(X = moderate to significant capability; O = moderate capability; no symbol = little or no capability)

Systems	Operating System	Preprocessing	Display & Enhancement	Information Extraction	Lineage	Image/Map Cartography	GIS	IP/GIS
<b>Commercial Systems</b>								
Adobe Photoshop	DOS/Mac/UNIX	O	X					
CAD Overlay GIS	Dos	O	O					
CORE HardCore	Dos/UNIX	O	O	O				
Core ImageNet	Dos/Unix		O	O				
Decision Images	Dos	X	X	X		X	X	X
EarthView	Dos	X	X	X				
EIDETIC	Dos	O	O	O				
ESRI Arc-Info GRID	UNIX	O	O	O		X	X	X
Dragon	Dos	X	X	X				
ERDAS Imagine	Dos/UNIX	X	X	X	X	X	X	X
ER-Mapper	UNIX	X	X	X		X	X	X
GAIA	Macintosh	O	O	O				
GENASYS	Dos/UNIX	X	X	X		X	X	X
Genlsis	Dos	O	O	O				
Global Lab Image	Dos		X	O				
GRASS	UNIX	X	X	X	X	X	X	X
IDRISI	Dos	X	X	X		X	X	X
Intergraph	UNIX	X	X	X	X	X	X	X
PCI	Dos/UNIX	X	X	X		X	X	X
R-WEL	Dos	X	X	X		X	X	X
MacSadie	Macintosh	X	X	X				
Microlmages	Dos/UNIX	X	X	X	X	X	X	X
MOCHA Jandel	Dos/Windows	X	X	X				
Orthoview	UNIX	X	X					
SPANS GIS/MAP	Dos/Mac	O	O	O		X	O	O
VISILOG	Dos/UNIX	X	X	X				

## APÉNDICE

Public Systems								
C-Coast	Dos		X	X				
Cosmic VICAR-IBIS	UNIX	X	X	X		X	X	X
NOAA	UNIX	O	O					
EPPL7	Dos	O	O	O		O	X	O
MultiSpec	Macintosh	X	X	X				
NASA ELAS	UNIX	X	X	X	X	X	X	X
NIH-Image	UNIX		O					

### Sources:

- Adobe Systems Inc., 1585 Charleston, Road, Mountain View, CA 94039
- CAD Overlay GIS, Autodesk Image Systems Technology, Rensselaer Technology Park, Troy, NY 12180.
- C-Coast, JA20 Building 1000, Stennis Space Center, MS 29519
- CORE, Box 50845, Pasadena, CA 91115
- Cosmic, Univ. of Georgia, Athens, GA 30602
- Decision Images, Inc., 196 Tamarack Circle, Skillman, NJ 08558
- Dragon, Goldin-Rudahl Systems, Six Univ. Drive Suite 213, Amherst, MA 01002
- EarthView, Atlantis Scientific Systems Group, 1827 Woodward Drive, Ottawa, Canada K2C 0P9
- EPPL7, Land Management Information Center, 300 Centennial Building, 638 Cedar St., St. Paul, MN 55155
- ERDAS, 2801 Buford Hwy., NE, Suite 300, Atlanta, GA 30329
- ER Mapper, 4370 La Jolla Village Dr., San Diego, CA 92122
- ESRI, 380 New York St., Redlands, CA 92373
- GAIA, 235 W. 56th St., 20N, NY, NY, 10019
- Global Lab, Data Translation, 100 Locke Drive, Marlboro, MA 01752-1192
- IDRISI, Graduate School of Geography, Clark Univ. 950 Main, Worcester, MA 01610
- Intergraph, Huntsville, AL, 35894
- MicroImages, 201 N. 8th St., Lincoln, NB 68508.
- MOCHA Jandel Scientific, 2591 Kerner Blvd., San Rafael, CA 94901
- MultiSpec, Dr. David Landgrebe, Purdue Research Foundation, W. Lafayette, IN 47907
- NASA, Stennis Space Center, SSC, MS
- NIH-Image, National Institute of Health, Washington, D.C.
- OrthoView, Hammon-Jensen-Wallen, 8407 Edgewater Dr., Oakland, CA 94621
- PCI, 50 W. Wilmot, Richmond Hill, Ontario Canada L4B 1M5
- R-WEL Inc., Box 6206, Athens, GA 30604
- Terra-Mar Inc., 1927 Landings Drive, Mountain View, CA 94043
- VISILOG, NOESIS Vision Inc., 6800 Cote de Liesse, Suite 200, St. Laurent, Quebec, H4T 2A7

LISTA DE SATELITES DE PERCEPCIÓN REMOTA

Satélite (fecha de lanzamiento, país y operación)	Elementos de la órbita	Sensor observador			
		Nombre del Sensor	Espectro / frecuencia	IFOV	Cubrimiento
Landsat - 1 (1972) " - 2 (1975) (USA) Retirados	Sincronizada con el sol Altura: 915 km. Inclinación 99 ° Recurrencia: 18 días	MSS (Sistema barreador Multiespectral)	0.5 - 0.6 μ m 0.6 - 0.7 0.7 - 0.8 0.9 - 1.1	80 m	185 km.
		RBV (Cámara Vidicon de haz de retorno)	0.475 - 0.575 μ m 0.580 - 0.680 0.690 - 0.830	80 m	
Landsat - 3 (1978) (USA) Retirado	Sincronizada con el sol Altura: 915 km. Inclinación: 99 ° Recurrencia: 18 días	MSS (Sistema barreador Multiespectral)	0.5 - 0.6 μ m 0.6 - 0.7 0.7 - 0.8 0.9 - 1.1	80 m	185 km.
		RBV	0.505 - 0.750 μ m	38 m	
Landsat - 4 (1982) Modo Standby " - 5 (1984) (USA) Operando	Sincronizada con el sol Altura: 705 km. Inclinación: 98 ° Recurrencia: 17 días	TM (Mapeador Temático)	0.45 - 0.52 μ m 0.52 - 0.60 0.63 - 0.69 0.75 - 0.90 1.55 - 1.75 2.08 - 2.35	30 m	185 km.
			10.40 - 12.50 μ m	120m	
		MSS (Sistema barreador Multiespectral)	0.5 - 0.6 μ m 0.6 - 0.7 0.7 - 0.8 0.9 - 1.1	80m	
Landsat - 6 (1993) Falló el lanzamiento " - 7 (1999) (USA) Operando	Sincronizada con el sol Altura: 705 km. Inclinación: 98 ° Recurrencia: 17 días	ETM + (Mapeador Temático mejorado plus)	0.50 - 0.90 μ m	13m x 15m	185 km.
			0.45 - 0.52 μ m 0.52 - 0.60 0.63 - 0.69 0.75 - 0.90 1.50 - 1.75 2.08 - 2.35	30 m	
			10.40 - 12.50 μ m	60 m	
SPOT -1 (1986) " - 2 (1990) Operando " - 3 (1993) (Francia) Se perdió	Sincronizada con el sol Altura: 832 km. Inclinación: 99 ° Recurrencia: 26 días	HRV (Alta Resolución visible)	0.50 - 0.59 μ m 0.61 - 0.68 0.79 - 0.89	20 m	1) 60 km. x 2
			0.51 - 0.73 μ m	10 m	
SPOT -4 (1996) (Francia) Operando	Sincronizada con el sol Altura: 822 km. Inclinación: 99 ° Recurrencia: 26 días	HRVIR (Alta Resolución visible e Infrarrojo Medio)	0.50 - 0.59 μ m 0.61 - 0.68 0.79 - 0.89 1.55 - 1.75	20 m	2) 60 km. x 2
		Panromático	0.61 - 0.68 μ m	10 m	

Satélite (fecha de lanzamiento, país y operación)	Elementos de la órbita	Sensor observador			
		Nombre del Sensor	Espectro / frecuencia	IFOV	Cobrimiento
		VMI (Instrumento de monitoreo de vegetación)	0.43-0.4 $\mu$ m 0.50-0.59 0.61-0.68 0.79-0.89 1.58-1.75	1 Km	2000 Km.
ERS - 1 (1991) " - 2 (1994) (ESA- Agencia Espacial Europea) Operando	Sincronizada con el sol Altura: 785 km. Inclinación : 99 ° Recurrencia: 3 días 35 días 176 días	AMI (INSTRUMENTACION DE MICROONDAS ACTIVAS)			
		Modo SAR	5.3 GHz.	30 m	100 km.
		Modo Onda		5 km. x 5 km	-
		Modo Viento		50 km.	500 km.
		RA (Radar altímetro)	13.8 GHz.	-	-
		ATSR / M (Radiómetro barredor a lo largo de la trayectoria/ Resonancia de microondas)		1 km.	500 km
		Radiómetro IR Termal	1.6 $\mu$ m 3.7 11 12		
Resonancia de microondas	23.8 GHz. 36.5 GHz.	22 km.	-		
JERS - 1 (1992) (Japón) No opera	Sincronizada con el sol Altura: 568 km. Inclinación: 98° Recurrencia: 44 días	O P S (Sensor Óptico) V N I R (Radiómetro visible e IR cercano)	0.52 - 0.60 $\mu$ m 0.63 - 0.69 0.76 - 0.86	18m x 24m	75 km.
		S W I R (Radiómetro de longitud de onda corta del infrarrojo)	1.60 - 1.71 $\mu$ m 2.01 - 2.12 2.13 - 2.25 2.27 - 2.40		
		S A R (Radar de Apertura Sintética)	1.275GHz Polarización HH	18m x 18m (3 Look)	
IRS - 1A (1988) " - 1B (1991) " - 1C (1993). Operando " - 1D (1997). Operando (India)	Altura: 904 km. Inclinación 99° Recurrencia: 22 días	L I S S - I (Sistema de barrido Lineal de Imágenes)	0.45 - 0.52 $\mu$ m 0.52 - 0.60 0.63 - 0.69 0.76 - 0.90	73m.	146 Km.
		L I S S - II	0.45 - 0.52 $\mu$ m 0.52 - 0.60 0.63 - 0.69 0.76 - 0.90	36.5m	73 Km. X 2



Satélite (fecha de lanzamiento, país y operación)	Elementos de la órbita	Sensor observador			
		Nombre del Sensor	Espectro / frecuencia	IFOV	Cobrimiento
		L I S S - III	0.52-0.59 $\mu$ m 0.62-0.68 0.77-0.86 1.55-1.70	23.5 m. (visible) 70.5 m. (RIR)	141 X 141 Km
		PAN (pancromáticos)	0.5 - 0.75 $\mu$ m	5.8 m	70 x 70 km
		WIFS (wide field sensor)	0.62 - 0.68 $\mu$ m 0.77 - 0.86	188 m	810 x 810 Km.
SEASAT - 1 (1978) (USA) No está operando	Sincronizada con el sol Altura: 790 km. Inclinación: 108° Recurrencia: 105 - 165 días	S M M R (Barredor multicanal de Radiómetro de microondas)	6.6 GHz. 10.69 18.0 21.0 27.0	121 x 79Km <sup>2</sup> 74 x 49 44 x 29 39 x 25 21 x 14	660 Km
		A L T Altimetro	13.5 GHz	1.6 - 12 km	2.4 - 12 Km
		S A S Escatorómetro de microondas	14.595 GHz.	50 x 50 Km <sup>2</sup>	1500 Km
		S A R Radar de Apertura Sintética	1.2748 Ghz.	25 x 25 Km <sup>2</sup> (4 look)	100 Km.
		V I R R Radiómetro Visible e Infrarrojo	0.5 - 0.7 $\mu$ m	2 Km.	2.280 Km.
			10.5 - 12.5 $\mu$ m	4 Km.	
RADARSAT (1994) (Canadá) Operando	No sincronizada con el sol Altura: 793 - 821 km. Inclinación: 99° Recurrencia: 24 días	S A R Radar de Apertura Sintética <i>Angulo de incidencia:</i> 20 - 49 °	5.3 GHz	25m x 28m (4 look)	100 Km.
		Modo Amplio <i>Angulo de incidencia:</i> 20 - 31°		30 - 48m x 28 m (4 look)	165 Km.
		Modo Amplio 2 <i>Angulo de incidencia:</i> 31 - 39 °		25 - 32 m x 28 m (4 look)	150 Km.
		Modo de Resolución fina <i>Angulo de incidencia:</i> 37 - 48 °		9 - 11 m x 9m (1 look)	45 Km.
		Modo ScanSAR (N) <i>Angulo de incidencia:</i> 20 - 40 °		50m x 50m (2 - 4 look)	305 Km.

Satélite (fecha de lanzamiento, país y operación)	Elementos de la órbita	Sensor observador					
		Nombre del Sensor	Espectro / frecuencia	IPOV	Cobrimiento		
		Modo ScanSAR (W) Angulo de incidencia: 20 - 49 °		100 m x 100m (4 - 8 look)	510 Km.		
		Modo Extendido (H) Angulo de incidencia: 50 - 60 °		19 - 22 m x 28m (4 look)		75 Km.	
		Modo Extendido (H) Angulo de incidencia: 10 - 23 °		28 - 63 m x 28m (4 look)		170 Km.	
<b>TIROS - N / NOAA Series</b> TIROS - N (1978) NOAA - 6 (1979) " - 7 (1981) " - 8 (1983) " - 9 (1984) " - 10 (1986) " - 11 (1988) No operan " - 12 (1993) Operando por requerimiento " - I (1993) No opera " - J (1995) Operando USA	Sincronizada con el sol Altura: 833 km. o Órbita: 870 Km. Inclinación: 99°	AVHRR (Radiómetro avanzado de alta resolución)	0.58 - 0.68µm <sup>4)</sup> 0.725 - 1.10 <sup>3)</sup> 3.55 - 3.93 10.30 - 11.30 11.50 - 12.50 <sup>6)</sup>	1.1 Km.	2.700 Km.		
		TOVS - SSU (Unidad ultrasónica de la estratósfera)	15 µ m 15 15	147 Km.	736 Km.		
		TOVS - HIRS/2 (Alta resolución en resonancia y radiación de Infrarrojo)	14.96. 4.71 µm 14.49. 14.22 13.97. 13.64 13.35. 11.11 9.71. 8.16 7.33. 6.72 4.57. 4.52 4.46. 4.40 4.24. 4.00 3.76. 0.69	20 Km.	2.200 Km.		
		TOVS - MSU (Unidad de resonancia de Microonda)	50.31 GHz 53.73 54.96 57.95	110 Km.	2.347 Km.		
		SBUV / 2 <sup>7)</sup> Experimento de backscatter solar de rayos ultra violeta	0.2520 -0.339µm 12 Bandas	169.3 Km.	-		
		ERB <sup>8)</sup> Experimento de balance de radiación de la tierra)	0.2 - 50.0 µm 8 Bandas	67.5 Km.	-		
		NOAA - siguiente serie NOAA -K (1998) Operando	Sincronizada con el sol Altura: 833 km. o Órbita: 870 Km. Inclinación 99°	AVHRR / 3 (AVHRR) Modelo 3	0.58 - 0.68 µm	0.5 Km.	2.700 Km.

Satélite (fecha de lanzamiento, país y operación)	Elementos de la órbita	Sensor observador			
		Nombre del Sensor	Espectro / frecuencia	IFOV	Cubrimiento
			0.82 - 0.87 1.57 - 1.78 <sup>m</sup> 3.55 - 3.93 <sup>m</sup> 10.30 - 11.30 11.50 - 12.40	1.0 Km.	
		TOVS - HIRS / 2	14.96, 4.71 $\mu$ m 14.49, 14.22 13.97, 13.64 13.35, 11.11 9.71, 8.16 7.33, 6.72 4.57, 4.52 4.46, 4.40 4.24, 4.00 3.76, 0.69	20 Km.	2.200 Km.
		ASMU - A (Resonancia de microondas avanzado A)	23.0 - 90.0 GHz 15 Bandas	40 Km.	2.240 Km.
		AMSU - B	90.0 - 183.0 GHz 5 Bandas	15 Km.	
		SBUV / 2 (Experimento de barredor solar de rayos ultra violeta)	0.2520 - 0.3398 $\mu$ m 12 Bandas	169.3 km	-
		ADEOS (1996) No opera (Japón)	Sincronizada con el sol Altura: 797 km. Inclinación: 99° Recurrencia: 41 días	OCTS (Barredor de temperatura y color del Océano)	0.402 - 0.422 $\mu$ m 0.433 - 0.453 0.480 - 0.500 0.510 - 0.530 0.555 - 0.575 0.655 - 0.675 0.745 - 0.785 0.845 - 0.885 3.55 - 3.85 8.25 - 8.75 10.5 - 11.5 11.5 - 12.5
AVNIR (Radiómetro avanzado del visible E IR cercano)	0.40 - 0.50 $\mu$ m 0.52 - 0.62 0.62 - 0.72 0.82 - 0.92			16 m	80 Km. <sup>10)</sup>
	0.52 - 0.72 $\mu$ m			8 m	
NSCAT (Escatérómetro de la NASA)	13.995 GHz			25 Km.	1.200 Km.
TOMS (Espectrómetro de Mapeo del Ozono total)	304.0 - 312.5 $\mu$ m 325.0 - 317..5 332.6 - 360.0			42 Km.	2.795 Km.

Satélite (fecha de lanzamiento, país y operación)	Elementos de la órbita	Sensor observador			
		Nombre del Sensor	Espectro / frecuencia	IPOV	Cubrimiento
		<b>IMG</b> (Monitor Interferométrico para gases de efecto de invernadero)	3 - 15 $\mu\text{m}$	8 Km.	20 Km.
		<b>POLDER</b> (Polarización y direccionalidad de la reflectancia de la tierra)	0.433 - 0.453 $\mu\text{m}$ <sup>11)</sup> 0.480 - 0.500 0.510 - 0.530 0.555 - 0.575 0.660 - 0.680 <sup>11)</sup> 0.760 - 0.770 0.860 - 0.900 <sup>11)</sup> 0.945 - 0.955	5 Km.	1.440 Km. X 1.920 Km.
		<b>ILAS</b> (Resonancia atmosférica mejorado)	0.753 - 0.784 $\mu\text{m}$ 6.0 - 6.8 7.3 - 11.8		
<b>IKONOS (septiembre de 1999)</b> (USA)  Operando	Sincronizada con el sol Altura: 681 km. Inclinación: 98.1° Recurrencia: 2.9 días con 1 m. de resolución y 1.5 días con 1.5 m de resolución	<b>Panorámico</b>          <b>Multiespectral</b>	00.45 - 0.90 $\mu\text{m}$   #1: Azul: 0.45 - 0.52 #2: Verde: 0.52 - 0.60 #3: Roja: 0.63 - 0.69 #4: IRC: 0.76 - 0.90 (igual que Landsat 4&5 TM Bandas #1-4)	1 m.          4 m.	13 Km. en el nadir

- 1) Visión del Angulo en el Nadir:  $\pm 27^\circ$ , por  $0.6^\circ$  de inclinación
- 2) 4 pixeles de 1Km de información están agrupados en un pixel 4Km.
- 3) V Polarización.
- 4) 0.58 - 0.90  $\mu\text{m}$ , Instalado en TIROS - N.
- 5) Adicionado a AVHRR / 2.
- 6) 10.5 - 11.5  $\mu\text{m}$  como en el NOAA - 8
- 7) Instalado en NOAA - 9. II. 1
- 8) Instalado en NOAA - 9. 10
- 9) Canal 1.57 - 1.78  $\mu\text{m}$  y canal 3.55 - 3.93  $\mu\text{m}$  dividido por el tiempo observado
- 10) Angulo apuntado:  $\pm 40^\circ$ .
- 11) 3 Diferentes direcciones de polarización.

### **TVFDO - Sistema para el Procesamiento Digital de Imágenes.**

Para el desarrollo del presente trabajo de tesis se efectuó la programación del sistema TVFDO. Este sistema fue programado en lenguaje Borland C y C++ versión 3.1. También se utilizaron las librerías gráficas: TVISION (para la interfase gráfica GUI) y SVGACC26 (para el manejo gráfico en alta resolución del sistema), las cuales se enlazaron con el código fuente en tiempo de compilación.

Este sistema se caracteriza por ser totalmente abierto y con capacidad de configuración. Dado que el compilador del lenguaje de programación utilizado opera solamente en modo real, este sistema esta limitado a una cantidad de memoria RAM máxima de 1 Mbyte (la compilación se realiza en el modelo de memoria Large). Para poder utilizar una memoria mayor es necesario disponer de un compilador que opere en modo protegido (las librerías correspondientes también deberán operar en dicho modo), esto permite la posibilidad de trabajar con imágenes más grandes y ampliar las posibilidades propias del sistema TVFDO.

Entre los requerimientos del sistema están:

- Una computadora PC compatible.
- Al menos un Mbyte de memoria RAM (dependiendo del S.O. utilizado será la cantidad de memoria RAM adicional requerida).
- Un ratón compatible.
- Un monitor SVGA con una resolución de 1024x768 pixeles.
- Una tarjeta de video VESA SVGA compatible. Algunas de las tarjetas soportadas son las siguientes:
  - 1 Acumos AVGA2/3 SuperVGA
  - 2 ATI Technologies 18/28/38/68800 SuperVGA
  - 3 Ahead V5000 Ver. A SuperVGA
  - 4 Ahead V5000 Ver. B SuperVGA
  - 5 Chips and Technologies 82C45x SuperVGA
  - 6 Cirrus Logic CL-GD 5xx, 6xx, 28xx, 54xx, 62xx SuperVGA
  - 7 Everex Micro Enhancer Ev236/6xx SuperVGA
  - 8 Genoa 61/62/63/64 6600 SuperVGA
  - 9 NCR 77C21/22 22E 22E+ SuperVGA
  - 10 Oak Technologies OTL-037C 067/077/087 SuperVGA
  - 11 Paradise/Western Digital PVGA1A, WD90C00/1x/2x/3x SuperVGA
  - 12 Realtek RT3106 SuperVGA
  - 13 Trident 8800CS, 8900B C/CL CX, 90x0 SuperVGA
  - 14 Tseng Labs ET3000-AX/BX/BP SuperVGA
  - 15 Tseng Labs ET4000/W32/W32I SuperVGA
  - 16 VESA compatible SuperVGA
  - 17 Video 7 HT-208/16 SuperVGA
  - 18 Avance Logic AL2101 SuperVGA
  - 19 MXIC MX68000 10 SuperVGA
  - 20 Primus P2000 SuperVGA
- Un teclado compatible PC.
- Un disco duro con capacidad suficiente para el almacenamiento de resultados.
- El sistema operativo puede ser MSDOS 6.22, Windows 95 ó Windows 98. Cada S.O. requiere de diferentes cantidades mínimas de memoria RAM para funcionar


- Este sistema se desarrollo bajo Windows 98 SE, 256 Mbytes de memoria RAM, disco duro de 40 Gigabytes, tarjeta de video S3 a una resolución de 800x600 pixeles, monitor SVGA, ratón y teclado compatibles.

**Características generales del sistema TVFDO:**

- Longitud máxima de imagen: 600x600 pixeles.
- Número máximo de colores soportados: 256 colores.
- Número máximo de niveles de gris soportados: 256 niveles de gris.
- Formatos gráficos soportados: PCX (en modo nativo) y RAW (previa especificación de la longitud de la imagen).
- Interfaz gráfica incorporada y configurable, con menús desplegables.
- Editor de textos incorporado.
- Soporte integral para mouse.
- Número máximo de clases definibles para segmentación: 20 clases.
- Rango posible de definición de las ventanas de entrenamiento: 1x1 hasta 100x100 pixeles.
- Capacidad de visualización del histograma de la imagen a segmentar.
- Capacidad de visualización del histograma de las medias de clase definidas.
- Capacidad de visualización del histograma por ocurrencias de clases.
- Capacidad de visualización en colores falsos.
- Tipos de segmentación soportados: MRF y Bayesiano, MRF, Bayesiano, Mahalanobis y Funciones Discriminantes Óptimas.
- Presentación de información estadística con la siguiente información: número de clase, coordenadas de la ventana de entrenamiento, tamaño de la ventana, media, varianza, desviación estándar, número de ocurrencias y color asignado a la clase segmentada.

**Descripción del sistema TVFDO.**

Para comenzar el sistema se deberá teclear desde MSDOS el nombre del programa TVFDO.EXE, ó bien, desde Windows se deberá hacer doble click sobre el archivo TVFDO (en este caso se deberá ejecutar el programa en modo de pantalla completa). Al iniciar el sistema TVFDO se presenta una pantalla de créditos que muestra la información relacionada con el objetivo del sistema y los derechos de autoría. Para cerrar la ventana de inicio se deberá pulsar la tecla ENTER ó ESC, ó también se puede hacer click sobre el botón ACEPTAR. La siguiente figura muestra dicha pantalla de inicio.



El sistema cuenta con menús desplegables para las diferentes acciones del programa. A continuación se describen las opciones más importantes de cada menú.

## ARCHIVO.

*Nuevo* : Limpia las variables del sistema para reinicialización.

*Abrir Imagen* : Permite especificar el nombre de la imagen que se desea abrir para edición, pueden ser imágenes en formato PCX ó RAW (previa especificación de su tamaño) con una longitud máxima de 600x600 pixeles.

*Tamaño Imagen* : Permite especificar el tamaño de la imagen para el formato RAW.

*Parámetros* : Define los valores de los parámetros  $N_1$  ,  $T_1$  y  $B_1$  para la segmentación MRF.

*Ver texto* : Inicia el editor de textos incorporado.


*Cerrar* : Cierra el archivo de texto abierto actualmente.

*Guardar y Guardar como* : Almacena el archivo de texto que se está editando actualmente.

*Cambiar directorio* : Cambia la ubicación actual del directorio.

*DOS shell* : Inicia el intérprete de comandos sin salir del programa.

*Salir* : Finaliza el sistema TVFDO.



## IMAGEN.

*Seg. MRF & Bayes* : Efectúa la segmentación por ambos métodos. Esta opción está diseñada específicamente para los propósitos del presente trabajo de tesis.

*Segmentar MRF* : Realiza la segmentación utilizando los Campos Aleatorios de Markov.

*Seg. Func. Bayesianas* : La segmentación se efectúa utilizando las Funciones Bayesianas.

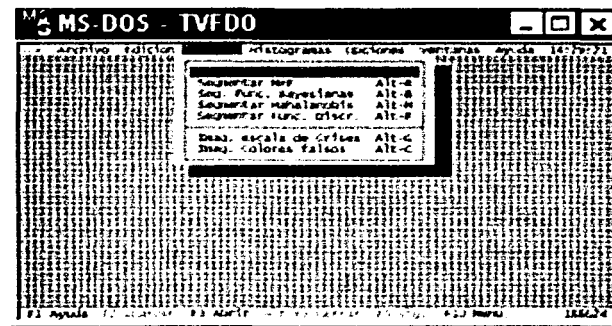
*Segmentar Mahalanobis* : Utiliza el método segmentación denominado Mahalanobis.

*Segmentar Func. Discr.* : Segmenta la imagen utilizando el método de Funciones Discriminantes Óptimas.

*Imag. niveles de gris* : Visualiza cualquier imagen (que haya sido segmentada o no) en niveles de gris.


*Imag. Colores falsos* : Visualiza cualquier imagen (que haya sido segmentada o no) en colores falsos.

Para activar cualquier opción también pueden utilizarse las teclas abreviadas: Alt-S, Alt-R, Alt-B, Alt-M, Alt-F, Alt-G y Alt-C respectivamente. Para el método de segmentación a través de MRF es necesario especificar los parámetros:  $N_1$ ,  $T_1$  y  $B_1$ . Si no se cambian los valores de dichos parámetros se utilizarán los valores por defecto para los mismos, esto es:  $N_1=50$ ,  $T_1=2.5$  y  $B_1=0.35$ . La figura siguiente muestra las opciones del menú Imagen.



**HISTOGRAMA.**


- Imagen original* : Muestra el histograma de la imagen especificada originalmente para segmentación. Se requiere haber especificado previamente las ventanas de entrenamiento. No se necesita la segmentación previa de la imagen.
- Medias de clases* : Visualiza el histograma de las medias de las clases definidas previamente. No se necesita la segmentación previa de la imagen.
- Ocurrencias de clases* : Despliega el histograma de las ocurrencias de las clases segmentadas. Se requiere segmentar primeramente la imagen a través de un método.
- Estadísticas* : Muestra una tabla con información sintetizada referente a las ventanas de entrenamiento definidas, esto es: su posición, su tamaño, su media, su varianza, su desviación estándar, número de ocurrencias y color asignado a la clase segmentada.



**EDITOR DE TEXTOS.**

El editor de textos incorporado permite la edición de cualquier archivo de texto en formato ASCII. Incluye una amplia variedad de funciones de edición clásicas como: borrar, insertar, copiar, pegar, guardar, guardar como, etc. El tamaño del archivo de texto que se puede editar depende de la memoria disponible bajo MSDOS (ya que es una aplicación msdos) y del espacio de almacenamiento disponible en disco. El programa abre archivos con extensión TXT de manera predeterminada (el formato ASCII es el único soportado). Para cerrar la ventana del editor de textos bastará con seleccionar la opción cerrar del menú Archivo o hacer click en la parte superior izquierda de la ventana de edición, sobre el recuadro de control.





**ESTADÍSTICAS.**

La figura siguiente muestra un ejemplo de la salida de información a través de la opción Estadísticas del menú Histogramas. Esta salida muestra una tabla con la información más relevante del proceso de segmentación previo para cada una de las clases definidas. Para salir de esta pantalla bastará con presionar cualquier tecla.

Clase	Objetos	Objetos	Objetos	Objetos	Objetos	Objetos
1	121 14	145 22	11 2048	4 1280	12 640	12 640
2	121 14	145 22	11 2048	4 1280	12 640	12 640
3	121 14	145 22	11 2048	4 1280	12 640	12 640
4	121 14	145 22	11 2048	4 1280	12 640	12 640

Presione cualquier tecla para continuar

**PANTALLA DE DEFINICIÓN DE CLASES.**

A esta pantalla se accede a través de la opción Abrir del menú Archivo. Una vez especificada la opción se solicitará la ubicación y el nombre del archivo de la imagen a segmentar. De manera predeterminada se mostrarán todos los archivos con extensión PCX, si se desea mostrar todos los archivos con extensión RAW bastará con especificar dicha extensión en el recuadro correspondiente (previamente se deberá especificar la longitud de la imagen para este tipo de archivos, esto se realiza a través de la opción Tamaño imagen del menú Archivo).

Una vez que se especificó el nombre del archivo deseado, se mostrará la imagen con el fin de definir las ventanas de entrenamiento. Estas ventanas pueden tener una longitud de 1x1 hasta 100x100 pixeles. Para definir una ventana se deberá posicionar el cursor sobre el punto donde se desea definir la esquina superior izquierda de la ventana y presionar una vez el botón izquierdo del mouse, posteriormente se posicionará el cursor en el punto donde se desea definir la esquina inferior derecha de la ventana de entrenamiento, presionando nuevamente el botón izquierdo del mouse con lo cual queda definida la ventana. Cada ventana se visualizará en la pantalla con su correspondiente número en la parte superior.

Este proceso se repetirá tantas veces como ventanas de entrenamiento se requieran. Para finalizar el proceso de definición de ventanas se deberá pulsar una vez el botón derecho del mouse. A continuación el sistema preguntará si se desea guardar la imagen con las ventanas definidas anteriormente. Bastará con presionar la tecla S para indicar un si (la imagen se guardará con el nombre IMADEF.PCX) ó la tecla N para indicar un NO. Posteriormente, podrá especificarse algún método de segmentación deseado, esto se hace a través del menú Imagen.

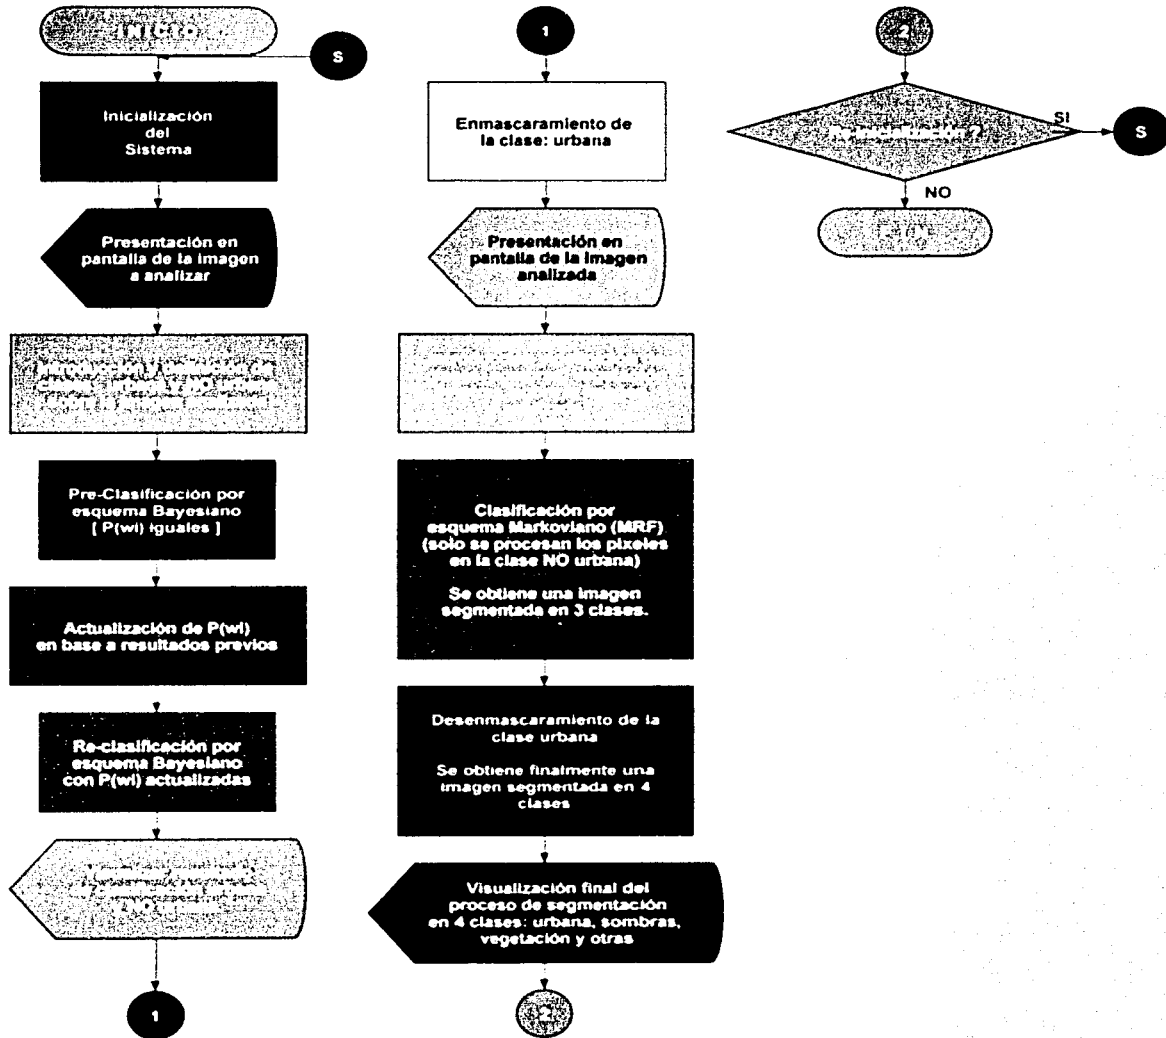


Como puede observarse en la figura anterior, la información disponible en la pantalla de definición de clases es variada. Primeramente, se dispone de las coordenadas de posición X e Y del cursor en relación a la imagen. En el momento de definir una ventana de entrenamiento, el tamaño de dicha ventana se muestra en relación a X e Y. El nivel de gris actual indicado por la posición del cursor también se muestra en esta pantalla. También se especifica el número de la ventana de entrenamiento (ó clase) que se ha definido, así como su media y desviación estándar respectiva. El número máximo de ventanas de entrenamiento que se pueden definir es de 20 ventanas. Por último, se especifica el tamaño de la imagen que se está editando (el tamaño máximo permitido actualmente es de 600x600 pixeles). En cada método de segmentación se dispone de la opción de guardar la imagen segmentada con un nombre predeterminado. A continuación se describen los nombres utilizados.

SEGMRF.PCX para el método por MRF.      SEGMAH.PCX para el método de Mahalanobis.  
 SEGBAYES.PCX para el método Bayesiano.      SEGMEN1.PCX y SEGMEN2.PCX para las Func. Discr.  
 HISTORIG.PCX para el histograma original.      HISTMED.PCX para el histograma de medias de clase.  
 HISTOCUR.PCX para el histograma de ocurrencias de clase.



Diagrama General de Flujo del Proceso de Segmentación Bayesiano-Markoviano.



---

# BIBLIOGRAFÍA

BIBLIOGRAFÍA

"Fundamentos de Teledetección Espacial".

Chuvieco, Emilio.

3ª. Edición.

Ediciones RIALP S.A.

Madrid, 1996.

ISBN 84-321-3127-X.

"Reconocimiento de Formas y Visión Artificial".

Gómez-Allende, Maravall Darío.

Ediciones: Addison-Wesley Iberoamericana, Ra-ma.

E.U.A, 1994.

ISBN 0-201-64183-6.

"Introduction to Statistical Pattern Recognition".

Fukunaga, Keinosuke.

2ª. Edición.

Ediciones Academic Press.

E.U.A, 1990.

ISBN 0-12-269851-7.

"El Lenguaje de Programación C".

W. Kernighan, Brian , M. Ritchie Dennis.

2ª Edición.

Ed. Prentice - Hall Hispanoamericana, S.A.

México, 1991.

ISBN 0-13-110362-8.

"Lenguaje C. Programación Avanzada".

Schildt, Herbert.

1ª Edición.

Ed. McGraw-Hill.

México, 1988.

ISBN 968-422-211-4.

"Programación en TURBO C".

Schildt, Herbert.

2ª Edición.

Ed. McGraw-Hill.

México, 1991.

ISBN 84-7615-491-7.

**Direcciones Electrónicas****Teledetección.**

- [www.efnavarra.es/territorial2000/COMUNICA/TELEDETECCIÓN.pdf](http://www.efnavarra.es/territorial2000/COMUNICA/TELEDETECCIÓN.pdf)
- <http://cursos.puc.cl/catalogo/programas/geo1124.pdf>
- <http://redgeomatica.rediris.es/teledeteccion/listatdt3.html>
- [www.uco.es/docinv/invest/ayudas/apoyo\\_invest/scit/teledeteccion/teledeteccion.htm](http://www.uco.es/docinv/invest/ayudas/apoyo_invest/scit/teledeteccion/teledeteccion.htm)
- [www.uco.es/~infoscit/teledeteccion.htm](http://www.uco.es/~infoscit/teledeteccion.htm)
- [asd-www.larc.nasa.gov/SCOOJ/Spanish/definition-sp.html](http://asd-www.larc.nasa.gov/SCOOJ/Spanish/definition-sp.html)
- [www.ija.csic.es/tele/rsweb/sensor.htm](http://www.ija.csic.es/tele/rsweb/sensor.htm)
- [www.ija.csic.es/tele/rsweb/indice1.htm](http://www.ija.csic.es/tele/rsweb/indice1.htm)
- [www.cma.junta-andalucia.es/documentos\\_tecnicos/inedita/introduccion2.pdf](http://www.cma.junta-andalucia.es/documentos_tecnicos/inedita/introduccion2.pdf)
- [www.stenet.com/corecap/FRAME5/rem-sensing\\_main.htm](http://www.stenet.com/corecap/FRAME5/rem-sensing_main.htm)
- [www.aero.org/publications/brochure/Remote-Sensing.pdf](http://www.aero.org/publications/brochure/Remote-Sensing.pdf)
- [www.esag.uct.ac.za/Tutorials-FAQs/remote-sensing/pdf/pdf.html](http://www.esag.uct.ac.za/Tutorials-FAQs/remote-sensing/pdf/pdf.html)

**Ikonos.**

- [www.spaceimagingeurope.com/products\\_layout.htm](http://www.spaceimagingeurope.com/products_layout.htm)
- [www.aeroterra.com/HTM/ikonos.htm](http://www.aeroterra.com/HTM/ikonos.htm)
- [www.eurimage.com/products/ikonos.html](http://www.eurimage.com/products/ikonos.html)
- [www.birdseyeimages.com/](http://www.birdseyeimages.com/)
- [www.spaceimaging.com/level2/level2gallery.htm](http://www.spaceimaging.com/level2/level2gallery.htm)
- [www.spaceimaging.com/aboutus/satellite](http://www.spaceimaging.com/aboutus/satellite)
- [www.space.com/scienceastronomy/planetearth/ikonos\\_990921.html](http://www.space.com/scienceastronomy/planetearth/ikonos_990921.html)
- [www.ikonos.com.br/](http://www.ikonos.com.br/)
- [www.spatialnews.com/features/ikonosdem](http://www.spatialnews.com/features/ikonosdem)
- [www.flatoday.com/space/explore/stories](http://www.flatoday.com/space/explore/stories)

**LandSat.**

- [www.aeroterra.com/HTM/landsat7E/TM.htm](http://www.aeroterra.com/HTM/landsat7E/TM.htm)
- [www.gsfc.nasa.gov/IAS/handbook/htmls/chapter2/chapter2.html](http://www.gsfc.nasa.gov/IAS/handbook/htmls/chapter2/chapter2.html)
- [www.gsfc.nasa.gov/IAS/handbook/handbook/htmls/chapter1/chapter1.html](http://www.gsfc.nasa.gov/IAS/handbook/handbook/htmls/chapter1/chapter1.html)
- [www.gsfc.nasa.gov/IAS/handbook/handbook/htmls/chapter6/chapter6.html](http://www.gsfc.nasa.gov/IAS/handbook/handbook/htmls/chapter6/chapter6.html)
- [www.cers.nrcan.gc.ca/cers/tekrd/satsens/sats/landsate.html](http://www.cers.nrcan.gc.ca/cers/tekrd/satsens/sats/landsate.html)
- [edewww.cr.usgs.gov/glis/hyper/guide/landsat.html](http://edewww.cr.usgs.gov/glis/hyper/guide/landsat.html)
- [daac.gsfc.nasa.gov/CAMPAIGN\\_DOCS/LAND\\_BIO/](http://daac.gsfc.nasa.gov/CAMPAIGN_DOCS/LAND_BIO/)
- [www.cct.nrcan.gc.ca/cers/tekrd/satsens/sats/landsatf.html](http://www.cct.nrcan.gc.ca/cers/tekrd/satsens/sats/landsatf.html)
- [joy.gsfc.nasa.gov/missions/landsat.html](http://joy.gsfc.nasa.gov/missions/landsat.html)
- [www.gallaudet.edu/~msellsw0/satellites/landsat.brk.html](http://www.gallaudet.edu/~msellsw0/satellites/landsat.brk.html)
- [fdd.gsfc.nasa.gov/mission/landsat7.html](http://fdd.gsfc.nasa.gov/mission/landsat7.html)

**Spot 5.**

- [www.spotimage.fr/home/system/introsat/orbit/welcome.htm](http://www.spotimage.fr/home/system/introsat/orbit/welcome.htm)
- [www.ccrs.nrcan.gc.ca/ccrs/tekrd/satsens/sats/spot.html](http://www.ccrs.nrcan.gc.ca/ccrs/tekrd/satsens/sats/spot.html)
- [www.spotimage.fr/satellite-imagery.htm](http://www.spotimage.fr/satellite-imagery.htm)
- [www.csrnr.neu.edu.tw/english.ver/service/resource/spot/spot.html](http://www.csrnr.neu.edu.tw/english.ver/service/resource/spot/spot.html)
- [www.dgi.inpe.br/html/spot.htm](http://www.dgi.inpe.br/html/spot.htm)
- [spot4.cnes.fr/spot4\\_gb/index.htm](http://spot4.cnes.fr/spot4_gb/index.htm)
- [www.aurensa.es/aurensa/ingles/index\\_ing.htm](http://www.aurensa.es/aurensa/ingles/index_ing.htm)
- [www.spotimage.fr/home/system/future/spot5/welcome.htm](http://www.spotimage.fr/home/system/future/spot5/welcome.htm)
- [www.spot.com/home/system/future/spot5/spot5.htm](http://www.spot.com/home/system/future/spot5/spot5.htm)
- <http://spot5.cnes.fr/>

**Métodos Bayesianos.**

- [http://bayes.wustl.edu/etj/articles/general\\_background.pdf](http://bayes.wustl.edu/etj/articles/general_background.pdf)
- [www.aisa.uvigo.es/fvazquez/cursos/tti.pdf](http://www.aisa.uvigo.es/fvazquez/cursos/tti.pdf)
- [www.etsimo.uniovi.es/~feli/pdf/TIGE\\_150a.pdf](http://www.etsimo.uniovi.es/~feli/pdf/TIGE_150a.pdf)
- [www.ejournal.unam.mx/compuysistemas/vol04-01/CYS04101.pdf](http://www.ejournal.unam.mx/compuysistemas/vol04-01/CYS04101.pdf)
- [www.dcs.warwick.ac.uk/pub/reports/rr/316.html](http://www.dcs.warwick.ac.uk/pub/reports/rr/316.html)
- [www.rma.ac.be/dire/DEMOS/MRF.html](http://www.rma.ac.be/dire/DEMOS/MRF.html)
- [www.ece.ucdavis.edu/~ispj/3D\\_seg\\_demo/gibbs-markov.html](http://www.ece.ucdavis.edu/~ispj/3D_seg_demo/gibbs-markov.html)
- [scorpions.ifqsc.sc.usp.br/IFSC/II/grupos/instrum/visao/courses/markov/mark1.htm](http://scorpions.ifqsc.sc.usp.br/IFSC/II/grupos/instrum/visao/courses/markov/mark1.htm)
- [ftp.sophia.inria.fr/pastis/theses/theseKato](http://ftp.sophia.inria.fr/pastis/theses/theseKato)
- <http://sepdl.stanford.edu/SOL/courses/prof.d.CAMD/downloads/BAYEShandout.pdf>
- <http://smi-web.stanford.edu/courses/archives/mis211/>
- [http://www.rci.rutgers.edu/~dhjones/STATISTICS\\_FOR MANAGERS/topic%2012-bayes%20theorem.pdf](http://www.rci.rutgers.edu/~dhjones/STATISTICS_FOR MANAGERS/topic%2012-bayes%20theorem.pdf)

**MRF.**

- <http://revc.uab.es/revista/04/0401-tut.pdf>
- <http://w3.mor.itesm.mx/~esucar/Clases-incer/clase06.hmm.ps>
- <http://w3.mor.itesm.mx/~esucar/Clases-incer/clase07-cam.ps>
- <http://w3.mor.itesm.mx/~esucar/Clases-incer/clase13-mdp.ps>
- [www.stat.yale.edu/~pollard/251.spring99/MRF.pdf](http://www.stat.yale.edu/~pollard/251.spring99/MRF.pdf)
- [www.nyu.edu/phd\\_students/ishikawa/MRF.pdf](http://www.nyu.edu/phd_students/ishikawa/MRF.pdf)
- [www.cs.umn.edu/~shekhar\\_research/mrf.pdf](http://www.cs.umn.edu/~shekhar_research/mrf.pdf)
- <http://eivind.imm.dtu.dk/teaching/BiomedImg/MRF.pdf>
- [www.imm.dtu.dk/courses/025031/lectures/2\\_mrf.pdf](http://www.imm.dtu.dk/courses/025031/lectures/2_mrf.pdf)

**Mapas de la Ciudad de México**

- [www.guiaroji.com.mx](http://www.guiaroji.com.mx)
- [www.inegi.gob.mx](http://www.inegi.gob.mx)