



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

FACULTAD DE INGENIERÍA

*“ESQUEMA DE RELAJACIÓN
DETERMINISTA MULTIESCALA”*

T E S I S

QUE PARA OBTENER EL TÍTULO DE:

INGENIERO EN TELECOMUNICACIONES

P R E S E N T A:

CYNTHIA LISSETH VELAZCO VELASCO



DIRECTOR DE TESIS:

DR. MIGUEL MOCTEZUMA FLORES

MEXICO, DF

ABRIL 2007



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

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

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



ÍNDICE



INTRODUCCIÓN	4
1 OBJETIVO	5
1.1 DEFINICIÓN DEL PROBLEMA	5
1.2 ESQUEMA DE ANÁLISIS	7
1.3 RESULTADOS Y APORTACIÓN DE LA TESIS	9
2 FUNDAMENTOS DE PROBABILIDAD	10
2.1 AXIOMAS DE PROBABILIDAD	11
2.1.1 AXIOMAS DE KOLMOGOROV	11
2.1.2 PROPIEDADES QUE SE DEDUCEN DE LOS AXIOMAS	12
2.2 VARIABLES ALEATORIAS	13
2.2.1 TIPOS DE DISTRIBUCIONES DE PROBABILIDAD	13
2.2.2 VARIABLES ALEATORIAS DISCRETAS	14
2.3 DISTRIBUCIÓN GAUSSIANA	17
2.4 TEOREMA DEL LÍMITE CENTRAL	21
3 SEGMENTACIÓN ÓPTIMA	23
3.1 TEOREMA DE BAYES	25
3.2 FUNCIONES DISCRIMINANTES	28
3.2.1 FUNCIÓN DE PÉRDIDA	28
3.2.2 DECISIÓN DE MÁXIMA PROBABILIDAD	31
4 RELAJACIÓN DETERMINISTA	33
4.1 ICM- ITERATED CONDITIONAL MODES	33
4.2 APLICACIÓN DE ICM	34
CYNTHIA VELAZCO VELASCO	2



ÍNDICE

5	RESULTADOS	36
5.1	IMÁGENES DE PRUEBA	40
5.1.1	REPRESENTACION PIRAMIDAL	40
5.1.2	REPRESENTACION NO PIRAMIDAL	74
5.2	COMPARACIÓN DE FUNCIONALIDAD	84
5.2.1	RESULTADOS OBTENIDOS.....	84
6	CONCLUSIONES	86
7	G L O S A R I O.....	88
8	BIBLIOGRAFÍA.....	90



INTRODUCCIÓN

Una de las primeras aplicaciones del procesamiento digital data de los años 20`s, cuando las imágenes digitales eran transmitidas por cables submarinos tendidos entre Nueva York y Londres. Las imágenes eran codificadas al principio de la transmisión y decodificadas al final de la transmisión; lo cual tuvo consecuencias en la calidad de las imágenes transmitidas; estas llegaban incompletas o muy borrosas.

Con la construcción de la tercera generación de computadoras digitales a mediados de los 60, el procesamiento de imágenes tuvo un gran empuje, ya que para el procesamiento digital se requiere alta velocidad y gran capacidad de memoria, las anteriores son suficientes razones para que se hayan desarrollado técnicas de computo de alto desempeño; tal como el procesamiento paralelo.

Básicamente, existen dos niveles de procesamiento digital de imágenes:

Procesamiento de bajo nivel, el cual es aquel que usa una gran cantidad de píxeles.

Procesamiento de alto nivel, el cual usa pocos píxeles.

El presente trabajo expondrá técnicas de segmentación de imágenes mediante el uso de modelos probabilísticos que se usan en el procesamiento de imágenes digitales de bajo nivel.



1 OBJETIVO

Investigar sobre técnicas de segmentación. Con fundamentos probabilísticos así como definir un esquema para:

- a) La segmentación de imágenes de percepción remota
- b) Definir un esquema determinista de regularización de resultados.

1.1 DEFINICIÓN DEL PROBLEMA

La fotografía aérea de alta resolución permite realizar análisis detallados de estructuras urbanas y de elementos temáticos. En desventaja, nuevos retos deben ser afrontados y nuevas técnicas deben ser planteadas a fin de resolver problemas de la alta definición como lo son la aparición de sombras. La información parcial proporcionada por las imágenes pancromáticas no permite una discriminación inmediatamente precisa sobre las escenas urbanas. Las áreas verdes por lo general comparten un similar rango en niveles de gris sobre otros elementos de las escenas. Las tecnologías contemporáneas de Procesamiento digital de imágenes y de Percepción remota se sitúan como fuentes de datos útiles a los sistemas de información ambiental.

Es en este contexto que en el presente tema de tesis, se pretende el estudio de técnicas bayesianas para la segmentación de imágenes de percepción remota. En datos de alta resolución, un problema a resolver consiste en la definición de un modelo rápido de procesamiento.

En base a un esquema definido en tres niveles de resolución espacial, se plantea en ésta tesis:

La definición de un esquema máximo a posteriori, que aplique criterios bayesianos en la segmentación en una representación en baja resolución.

- b) La proyección de los resultados en una resolución intermedia.
- c) La regularización mediante un esquema de relajación



CAPITULO 1



d) la aplicación de la relajación hasta el nivel de resolución original.

En el esquema propuesto, el algoritmo deberá tener un buen desempeño y un rápido procesamiento en imágenes de gran tamaño. El nivel de baja resolución, por su tamaño deberá de requerir de un bajo tiempo de procesamiento, además del efectos paso bajas que deberá eliminar parte del ruido de la imagen original.

En ambos casos el fundamento teórico reside en la teoría de Bayes y en la maximización de probabilidades a posteriori. Un estudio deberá emprenderse a fin de definir un esquema multiescala de relajación. Inicialmente, a partir de la imagen original se construirá una representación multiresolución piramidal.

Las etapas de procesamiento serán:

- a) Al nivel de más baja resolución se le aplicará un esquema bayesiano óptimo de segmentación.
- b) Al resultado se le aplicará un esquema de relación ICM.
- c) El resultado de la relajación se proyectará al siguiente nivel de resolución.
- d) Se procederá a una relajación.
- e) Se repetirán los pasos de proyección-relajación hasta el nivel de resolución alta.



1.2 ESQUEMA DE ANÁLISIS

Parte 1 → ESQUEMA BAYESIANO ÓPTIMO DE SEGMENTACIÓN

En la presente tesis, se pretende aplicar un proceso de segmentación a una imagen definida en 256 niveles de gris. Bajo un fundamento bayesiano, el proceso involucra el empleo de funciones equiprobables y la obtención de medias y de probabilidades a priori.

Considere la regla de Bayes $P(w_i|X) = \frac{P(X|w_i)P(w_i)}{P(X)}$, siendo X la imagen original y W_i las clases,

$P(w_i|X)$ 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

con $i = 0, 1, 2, \dots, 4$



Parte 2 → ALGORITMO DETERMINÍSTICO ICM

Se aplica el algoritmo determinístico ICM a la imagen resultante de la aplicación del esquema bayesiano. Se muestra el esquema análisis completo en el siguiente diagrama.

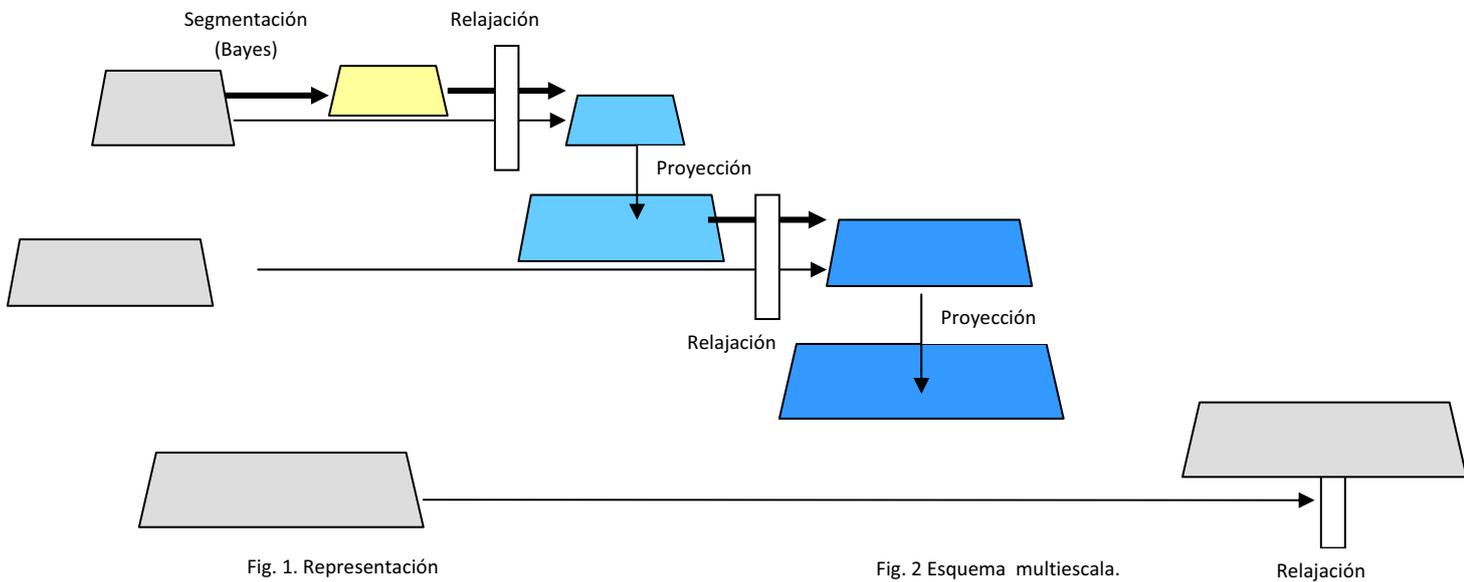


Fig. 1. Representación multiescala. El nivel inferior corresponde a la imagen original.

Fig. 2 Esquema multiescala. De relajación-proyección.

Relajación



1.3 RESULTADOS Y APORTACIÓN DE LA TESIS

Realizar investigaciones sobre representaciones piramidales.

Realizar investigaciones sobre métodos de segmentación por estimaciones máximo posteriori.

Definir un esquema de segmentación por Bayes

Definir un criterio para comparar la funcionalidad de los resultados

Realizar investigaciones sobre aplicaciones en la segmentación de regiones urbanas.

Colaborar en la integración de un paquete de procesamiento de imágenes.



2 FUNDAMENTOS DE PROBABILIDAD

La teoría de probabilidad es la teoría matemática que modela los fenómenos aleatorios. Estos deben contraponerse a los fenómenos determinísticos, en los cuales el resultado de un experimento, realizado bajo condiciones determinadas, produce un resultado único o previsible. Un fenómeno aleatorio es aquel que, a pesar de realizarse el experimento bajo las mismas condiciones determinadas, tiene como resultados posibles un conjunto de alternativas, ejemplos: lanzar un dado o una moneda.

Los procesos reales que se modelan como procesos aleatorios pueden no serlo realmente; cómo tirar una moneda o un dado no son procesos aleatorios en sentido estricto, ya que no se reproducen exactamente las mismas condiciones iniciales que lo determinan sino sólo unas pocas. Los procesos reales que se modelan mediante distribuciones de probabilidad corresponden a modelos complejos donde no se conocen todos los parámetros que intervienen o no son reproducibles sus condiciones iniciales (teoría del caos). Para simplificar, generalmente a este tipo de problemas también se le considera aleatorio aunque estrictamente hablando no lo sea.

En 1933, el matemático soviético Andrei Kolmogorov propuso un sistema de axiomas para la teoría de la probabilidad, basado en la teoría de conjuntos y en la teoría de la medida, desarrollada pocos años antes por Lebesgue, Borel y Frechet entre otros.

Esta aproximación axiomática que generaliza el marco clásico de la probabilidad, la cual obedece a la regla de cálculo de casos favorables sobre casos posibles, permitió la modelación matemática de sofisticados fenómenos aleatorios. Actualmente, estos fenómenos encuentran aplicación en las más variadas ramas del conocimiento, como puede ser la física (donde corresponde mencionar el desarrollo de las difusiones y el movimiento Browniano), o las finanzas (donde destaca el modelo de Black y Scholes para la valuación de acciones).



2.1 AXIOMAS DE PROBABILIDAD

Los axiomas de probabilidad son las condiciones mínimas que deben verificarse para que una función que definimos sobre unos sucesos determine consistentemente valores de probabilidad sobre dichos sucesos.

La probabilidad P de un suceso E , denotada por $P(E)$, se define con respecto a un "universo" o espacio muestral Ω , conjunto de todos los posibles sucesos elementales, tal que P verifique los Axiomas de Kolmogorov. En este sentido, el suceso E es, en términos matemáticos, un subconjunto de Ω .

2.1.1 AXIOMAS DE KOLMOGOROV

Dado un conjunto de sucesos elementales, Ω , sobre el que se ha definida una σ de subconjuntos de Ω y una función P que asigna valores reales a los miembros de σ , a los que denominamos "sucesos", diremos que P es una probabilidad sobre (Ω, σ) si se cumplen los siguientes tres axiomas:

➤ Primer axioma

La probabilidad de un suceso A es un número real mayor o igual que 0.

$$0 \leq P(A)$$

La probabilidad de un suceso es un número positivo o nulo.

➤ Segundo axioma

La probabilidad del total, Ω , es igual a 1.

$$P(\Omega) = 1$$

Ω representa todas las posibles alternativas y se denomina suceso seguro.



➤ Tercer axioma

Si A_1, A_2, \dots son sucesos mutuamente excluyentes (incompatibles dos a dos, disjuntos o de intersección vacía dos a dos),

Entonces:

$$P(A_1 \cup A_2 \cup \dots) = \sum P(A_i).$$

Según este axioma se puede calcular la probabilidad de un suceso compuesto de varias alternativas mutuamente excluyentes sumando las probabilidades de sus componentes.

2.1.2 PROPIEDADES QUE SE DEDUCEN DE LOS AXIOMAS

De los axiomas anteriores se deducen otras propiedades de la probabilidad:

1. $P(\emptyset) = 0$ donde el conjunto vacío (\emptyset) representa en probabilidad el suceso imposible

2. Para cualquier suceso $P(A) \leq 1$

3. $P(A^c) = 1 - P(A)$

4. Si $A \subseteq B$ entonces $P(A) \leq P(B)$

5. $P(A \cup B) = P(A) + P(B) - P(A \cap B)$

En términos más formales, una probabilidad es una medida sobre una σ -álgebra de subconjuntos del espacio muestral, siendo los subconjuntos miembros de la σ -álgebra los sucesos y definida de tal manera que la medida del total sea 1.



Tal medida, gracias a su definición matemática, verifica igualmente los tres axiomas de Kolmogorov. A la terna formada por el espacio muestral, la σ -álgebra y la función de probabilidad se la denomina Espacio probabilístico, esto es, un "espacio de sucesos" (el espacio muestral) en el que se han definido los posibles sucesos a considerar (la σ -álgebra) y la probabilidad de cada suceso (la función de probabilidad).

2.2 VARIABLES ALEATORIAS

Las distribuciones de probabilidad están relacionadas con las distribuciones de frecuencias. Una distribución de frecuencias teórica es una distribución de probabilidades que describe la forma en que se espera que varíen los resultados. Debido a que estas distribuciones tratan sobre expectativas de que algo suceda, resultan ser modelos útiles para hacer inferencias y para tomar decisiones en condiciones de incertidumbre.

Las distribuciones de probabilidad pueden basarse en consideraciones teóricas o en una estimación subjetiva de la posibilidad. Se pueden basar también en la experiencia.

2.2.1 TIPOS DE DISTRIBUCIONES DE PROBABILIDAD

Las distribuciones de probabilidad se clasifican como continuas y discretas. En la distribución de probabilidad discreta está permitido tomar sólo un número limitado de valores.

En una distribución de probabilidad continua, la variable que se está considerando puede tomar cualquier valor dentro de un intervalo dado. Las distribuciones continuas son una forma conveniente de presentar distribuciones discretas que tienen muchos resultados posibles, todos muy cercanos entre sí.



2.2.2 VARIABLES ALEATORIAS DISCRETAS

Una variable es aleatoria si toma diferentes valores como resultado de un experimento aleatorio. Puede ser discreta o continua. Si puede tomar sólo un número limitado de valores, entonces es una variable aleatoria discreta. Si toma cualquier valor dentro de un intervalo dado, entonces se trata de una variable aleatoria continua.

Una variable aleatoria es un valor o una magnitud que cambia de una presentación a otra, sin seguir una secuencia predecible. Los valores de una variable aleatoria son los valores numéricos correspondientes a cada posible resultado de un experimento aleatorio.

Variables aleatorias discretas: Es aquella variable que toma un número finito o infinito de valores numerables. Variable aleatoria que puede tomar sólo un número limitado de valores. Ejemplo

$$X : E \rightarrow \mathcal{N}$$

Su **función de probabilidad** f , se define de modo que $f(x_i)$ es la probabilidad de que X tome ese valor:

$$f : \mathcal{N} \rightarrow [0, 1]$$
$$x_i \mapsto f(x_i) = \mathcal{P}[X = x_i] = \mathcal{P}[\{e, \text{t.q. } X(e) = x_i\}]$$



Variables aleatorias continuas: Es aquella variable que toma un valor infinito de valores no numerables. Variable aleatoria que puede tomar cualquier valor Dentro de un intervalo dado de valores. Ejemplo $X : E \rightarrow R$.

- Función de distribución, F , se define de modo que si $x_i \in R$, $F(x_i)$ es igual a la probabilidad de que X tome un valor menor o igual a x_i :

$$F : R \rightarrow [0,1]$$
$$x \mapsto F(x) = P[X \leq x] = \int_{-\infty}^x f(t) dt$$

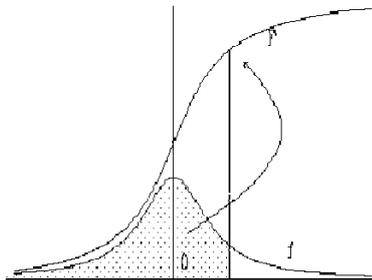


Figura 2.1: Función de distribución F



- **Función de densidad**, se define como una función $f: \mathbb{R} \rightarrow \mathbb{R}$ integrable, que verifica las dos propiedades siguientes:

$$\begin{cases} f(x) \geq 0 \\ \int_{-\infty}^{+\infty} f(x) dx = 1 \end{cases}$$

Y que además verifica que dado $a < b$, se tiene que

$$P\{a \leq X \leq b\} = \int_a^b f(x) dx$$

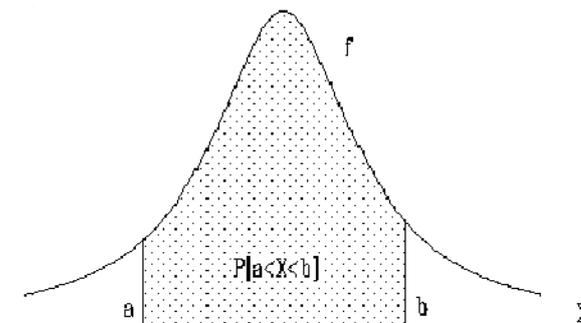


Figura 2.2: Función de densidad f.



2.3 DISTRIBUCIÓN GAUSSIANA

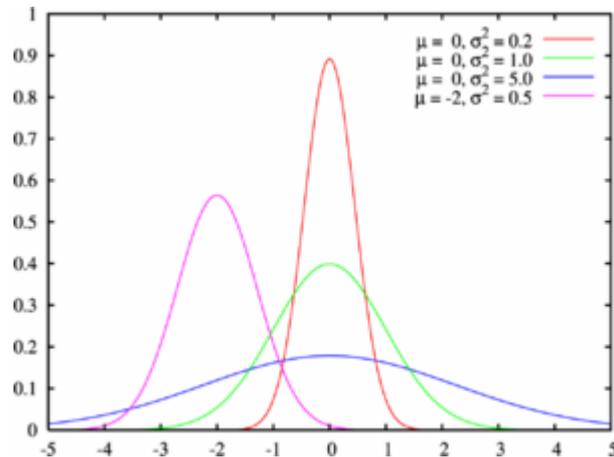


Figura 2.3

Las cuatro distribuciones del gráfico son normales, con distintos valores de la media y la desviación típica. La verde es la "normal estándar", de media cero y desviación típica uno.

La **distribución normal**, también llamada **distribución de Gauss** o **distribución gaussiana**, debe su nombre al matemático alemán Carl Friedrich Gauss.

Es la distribución de probabilidad que con más frecuencia aparece en estadística y teoría de probabilidades. Esto se debe a dos razones fundamentalmente:

- Su función de densidad es simétrica y con forma de campana, lo que favorece su aplicación como modelo a gran número de variables estadísticas.
- Es, además, límite de otras distribuciones y aparece relacionada con multitud de resultados ligados a la teoría de las probabilidades gracias a sus propiedades matemáticas.



CAPITULO 2



Muchas variables aleatorias continuas presentan una función de densidad cuya gráfica tiene forma de campana.

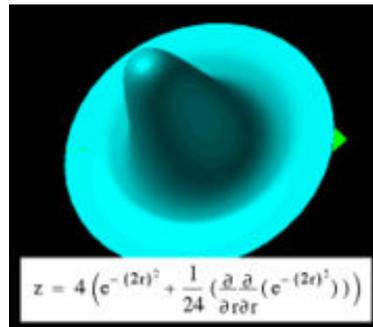


Figura 2.4 Forma tridimensional

Se dice que una variable aleatoria X sigue una **distribución normal** de parámetros μ y σ^2 , lo que representamos del modo $X \sim N(\mu, \sigma^2)$, su función de densidad esta dada por:

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}, \quad \forall x \in \mathbb{R}$$

Donde μ (M) es la media y σ (sigma) es la desviación estándar (σ^2 es la varianza).



La forma de la función de densidad es la llamada campana de Gauss.

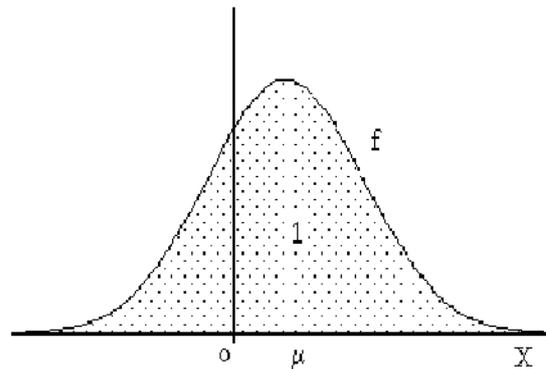


Figura 2.5: Campana de Gauss o función de densidad de una v.a. de distribución normal.

La forma de la campana de Gauss depende de los parámetros μ y σ :

μ Indica la posición de la campana (parámetro de centralización)

(O equivalentemente, σ) será el parámetro de dispersión. Cuanto menor sea, mayor cantidad de masa de probabilidad habrá concentrada alrededor de la media (gráfico de f muy apuntado cerca de μ) y cuanto mayor sea "más aplastado" será.

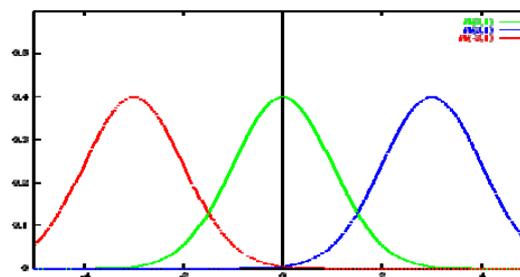


Figura 2.6: Distribuciones gaussianas con diferentes medias e igual dispersión

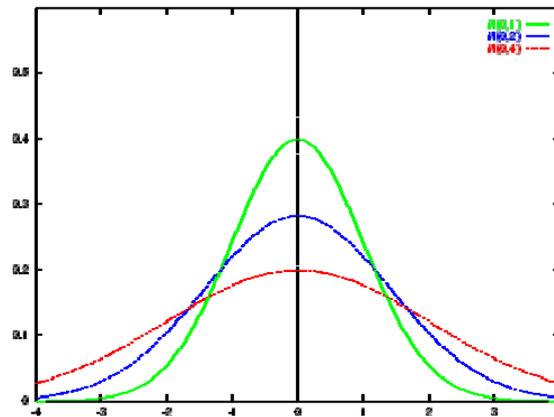


Figura 2.7: Distribuciones gaussianas con igual media pero varianza diferente.

La importancia de la distribución normal se debe principalmente a que hay muchas variables asociadas a fenómenos naturales que siguen el modelo de la normal.

Cuando se realizan series de medidas experimentales, algunas de ellas son mayores que la media y otras menores. Si se representa en el eje horizontal las medidas obtenidas y en el vertical el número de veces que se obtiene cada valor, se obtiene lo que se llama un histograma de frecuencias.

Si se elimina el error sistemático, el conjunto de datos obtenido se distribuye de forma simétrica alrededor de la media, dando una curva en forma de campana.

Muchas variables se distribuyen de esta forma, variables tanto de tipo morfológico (p.e. la altura de las personas en una población) como fisiológicas, sociológicas, etc.

Constituye otra forma de expresar lo establecido en el Teorema central del límite: variables independientes que no siguen necesariamente una distribución normal sí lo hacen para tamaños suficientemente grandes de la muestra.



2.4 TEOREMA DEL LÍMITE CENTRAL

El Teorema del Límite Central o Teorema Central del Límite indica que, bajo condiciones muy generales, la distribución de la suma de variables aleatorias tiende a una distribución gaussiana cuando la cantidad de variables es muy grande.

Teorema: Sea X_1, X_2, \dots, X_n una muestra aleatoria de una distribución con media μ y varianza σ^2 . Entonces, si n es suficientemente grande, X tiene aproximadamente una distribución normal con $\mu_X = \mu$ y $\sigma_X^2 = \sigma^2/n$. También se cumple que T_0 tiene aproximadamente una distribución normal con $\mu_{T_0} = n\mu$ y $\sigma_{T_0}^2 = n\sigma^2$. Cuanto más grande sea el valor de n , mejor será la aproximación.

El Teorema del Límite Central garantiza una distribución normal cuando n es suficientemente grande.

Existen diferentes versiones del teorema, en función de las condiciones utilizadas para asegurar la convergencia. Una de las más simples establece que es suficiente que las variables que se suman sean independientes, idénticamente distribuidas, con valor esperado y varianza finitas.

La aproximación entre las dos distribuciones es, en general, mayor en el centro de las mismas que en sus extremos o colas, motivo por el que se prefiere el nombre "Teorema del Límite Central" ("central" califica al límite, más que al teorema).

Este teorema, perteneciente a la Teoría de la Probabilidad, encuentra aplicación en muchos campos relacionados, como la Inferencia estadística o la Teoría de renovación.

Teorema del límite central. Si X_1, X_2, \dots, X_n son variables aleatorias (discretas o continuas) independientes, con idéntico modelo de probabilidad, de valor medio μ y varianza σ^2 , entonces la distribución de la variable



$$Z = \frac{(X_1 + X_2 + \dots + X_n) - n\mu}{\sigma\sqrt{n}} = \frac{(\sum_{i=1}^n X_i) - n\mu}{\sigma\sqrt{n}}$$

Se aproxima a la de una variable normal tipificada $N(0,1)$, mejorándose la calidad de la aproximación a medida que n aumenta.

Este resultado prueba que el estadístico o estimador media muestral.

$$\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n} = \sum_{i=1}^n \frac{X_i}{n}$$

se distribuye aproximadamente como una variable

$$N\left(\mu, \frac{\sigma}{\sqrt{n}}\right)$$

o, de manera equivalente, que $\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$

se distribuye aproximadamente como una variable $N(0,1)$

Con carácter general, o al menos en los modelos de probabilidad clásicos, se admite una aproximación aceptable al modelo normal siempre que n sea mayor o igual que 30, a pesar de que esta cifra es insuficiente en determinados casos y excesiva en otros; por lo que debemos ser cautelosos en su aplicación. En el enlace modelos de probabilidad, se establece una relación de algunos modelos, con aproximaciones particulares, que en la mayoría de los casos derivan del teorema del límite central.



3 SEGMENTACIÓN ÓPTIMA

La segmentación es el proceso de dividir una imagen en regiones o segmentos manipulables. Se utiliza en el análisis de imágenes para separar de la imagen, propiedades o regiones de una textura seleccionada previamente.

La segmentación se basa en alguna de las dos siguientes propiedades de la imagen:

- Similitud: En esta propiedad se segmenta la imagen en regiones que tienen niveles de gris dentro de un rango predeterminado utilizando técnicas tales como fijación de umbrales y el crecimiento de regiones.
- Discontinuidad: En esta propiedad se utiliza para segmentar la imagen en regiones de discontinuidad donde existe un cambio abrupto en los valores de los niveles de gris. Lo anterior se utiliza para detectar las fronteras o bordes en la imagen y es conocida como: detección de bordes.

Para clasificar las diferentes regiones obtenidas en el proceso de segmentación, se divide el conjunto de píxeles que componen la imagen en clases típicas previamente definidas o por definir, según sea el método clasificatorio que se decida utilizar.

Durante la clasificación se requiere la adopción de unos métodos que incorporen reglas de decisión, las cuales se pueden agrupar en dos grandes rubros: los supervisados y los no supervisados. La diferencia entre estos métodos es que, en el caso de los primeros, se requiere de un conocimiento previo muy preciso de las clases a clasificar, mientras que en los no supervisados, la segmentación de las clases espectrales se obtiene con base a un procedimiento estadístico, lo cual genera clases estadísticas, las que posteriormente, deberán ser asignadas a clases o categorías de información de acuerdo con antecedentes de terreno.



CAPITULO 3



Para realizar la clasificación de imágenes se utilizan funciones discriminantes, la cuales brindan grandes ventajas debido a que:

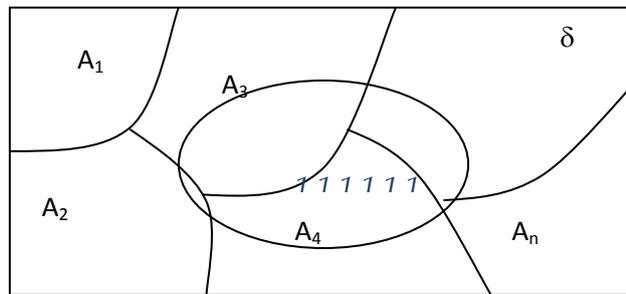
- Existe una cantidad considerable de conocimientos en áreas como comunicación estadística, teoría de detección, teoría de decisión, etc. Y estos conocimientos son directamente aplicables al reconocimiento de patrones.
- La formulación estadística es particularmente aplicable par el problema de reconocimiento de patrones, ya que muchos procesos de reconocimiento de patrones son modelados estadísticamente.



3.1 TEOREMA DE BAYES

Sea δ un espacio muestral que está formado por los eventos $A_1, A_2, A_3, \dots, A_n$ mutuamente excluyentes, luego,

$$\delta = A_1 \cup A_2 \cup A_3 \cup \dots \cup A_n$$



Luego si ocurre un evento B definido en δ , observamos que;

$$B = \delta \cap B = (A_1 \cup A_2 \cup A_3 \cup \dots \cup A_n) \cap B = (A_1 \cap B) \cup (A_2 \cap B) \cup (A_3 \cap B) \cup \dots \cup (A_n \cap B)$$

Donde cada uno de los eventos $A_i \cap B$ son eventos mutuamente excluyentes, por lo que:

$$P(B) = p(A_1 \cap B) + p(A_2 \cap B) + p(A_3 \cap B) + \dots + p(A_n \cap B)$$

Y como la $p(A_i \cap B) = p(A_i)p(B|A_i)$, o sea que la probabilidad de que ocurra el evento A_i y el evento B es igual al teorema de la multiplicación para probabilidad condicional, luego;

$$p(B) = p(A_1)p(B|A_1) + p(A_2)p(B|A_2) + p(A_3)p(B|A_3) + p(A_n)p(B|A_n)$$

Si deseamos calcular la probabilidad de que ocurra un evento A_i dado que B ya ocurrió, entonces;

$$P(A_i|B) = \frac{p(A_i \cap B)}{p(B)} = \frac{p(A_i)p(B|A_i)}{p(A_1)p(B|A_1) + p(A_2)p(B|A_2) + \dots + p(A_n)p(B|A_n)}$$



Simplificando:

$$p(A_i | B) = \frac{p(A_i)p(B|A_i)}{p(B)}$$

A la ecuación anterior se le conoce como el Teorema de Bayes.

$$p(A_i | B) = \frac{p(A_i)p(B|A_i)}{p(B)}$$

Donde:

$P(A_i)$ son las probabilidades a priori.

$P(B | A_i)$ es la probabilidad de B en la hipótesis A_i .

$P(A_i | B)$ son las probabilidades a posteriori.

El primer término de la ecuación anterior aporta la solución al problema de clasificación. Dado un vector B, la clasificación será la siguiente:

$$X \in \alpha_j \text{ Si } P(\alpha_j | x) > P(\alpha_i | x)$$

Si ahora nos basamos en el segundo miembro de la ecuación del teorema de Bayes (eliminando el factor de escala $p(B)$), tendremos una forma alternativa de clasificar un vector B.

$$X \in \alpha_j \text{ Si } P(\alpha_j | x)P(\alpha_j) > P(\alpha_i | x)P(\alpha_i)$$

Se añadió el calificativo de a posteriori al clasificador estadístico basado en el primer miembro del Teorema de Bayes y, análogamente, el calificativo de a priori al segundo miembro de dicho teorema. La justificación es inmediata, ya que en el primer caso se trata de calcular o estimar la probabilidad a posteriori de que B pertenezca a la clase A_i , mientras que en el segundo caso se



CAPITULO 3



trata de la probabilidad a priori de que cumpliéndose a hipótesis de pertenencia a la clase A_i el objeto sea B .

La estimación de las probabilidades del clasificador estadístico a posteriori solo se puede realizar mediante un proceso de aprendizaje

$$p(B|A_1) \quad p(B|A_2) \quad \dots \quad p(B|A_N)$$

A partir de un conjunto de muestras o realizaciones físicas de las clases.



3.2 FUNCIONES DISCRIMINANTES

El uso de funciones discriminantes estadísticas para la clasificación es ventajoso por dos razones. Que a continuación se exponen.

1. El conocimiento que a lo largo del tiempo se ha adquirido en áreas como teoría de la decisión y comunicaciones es aplicable directamente al reconocimiento de patrones.
2. La formulación estadística es particularmente ajustable para el problema del reconocimiento de patrones, ya que este tratamiento es de naturaleza estadística. En este problema es deseable el uso de toda la información a priori disponible.

3.2.1 FUNCIÓN DE PÉRDIDA

La función discriminante de Bayes sirve para clasificar imágenes. Para definir esta función primero se definirá la pérdida condicional promedio o el riesgo condicional promedio.

Antes de establecer la función de pérdida, los siguientes puntos deben ser tomados en cuenta:

1. $P(\omega_1)$ es conocida o puede ser estimada.
2. $P(x|\omega_1)$ es conocida o puede ser estimada por medio del entrenamiento del sistema.
3. $P(\omega_1|x)$ no es conocida

Entonces la función queda como:

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



Donde L_{ik} es una función de pérdida, costo o multa por decir si x pertenece a ω_j , cuando en realidad pertenece a ω_i .

Si sustituimos la siguiente ecuación $\rightarrow P(A_i | B) = \frac{P(A_i)P(B|A_i)}{P(B)}$

En la función de pérdida, entonces tenemos:

$$\eta_k(x) = \frac{1}{P(x)} \sum_{i=1}^M L_{ik} P(\omega_i | x) P(\omega_i)$$

Como $p(x)$ en la ecuación anterior es común a toda $\eta_j(x), j = 1, \dots, M$ podemos eliminarla de la pérdida condicional promedio y solo buscar el mínimo.

El trabajo del clasificador es entonces, encontrar la decisión óptima que minimice el riesgo o pérdida promedio. Entonces la regla de decisión consistirá de los siguientes pasos:

1. Calcular $\eta_k(x)$ para $x \in \omega_1 \forall i=1,2,\dots,M$
2. Decidir si $x \in \omega_k$, siempre y cuando $\eta_k(x) < \eta_j(x)$, tal que i es diferente de k .

La matriz de pérdida se puede representar de la siguiente forma:

$$L = \begin{pmatrix} 0 & \dots & 1 \\ \vdots & \searrow & \vdots \\ 1 & \dots & 0 \end{pmatrix}$$

Donde $L_{ii} = 0, i = 1, \dots, M$ sin que ocurra clasificación incorrecta, mientras

$L_{ik} = 1$, representa el error de clasificar $x \in \omega_i, i = 1, \dots, M, i \neq k$. Esta es una función simétrica de pérdida:

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



Donde $\delta(k - i)$ es la función delta de Kronecker donde:

$$\delta(k - i) = \begin{cases} 1, & k = i \\ 0, & \text{otro caso} \end{cases}$$

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

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

La matriz de perdida se convierte en una función matricial negativa:

$$\begin{bmatrix} -h_1 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & -h_M \end{bmatrix}$$

El significado de esta función matricial de perdida negativa es que la perdida negativa es asignada a la decisión correcta y sin perdida de decisión incorrecta. En otras palabras, la perdida asignada a una decisión es mayor para una decisión errónea que para una correcta.

Entonces la función discriminante estadística correspondiente basándonos en lo anterior es:

$$d_k(x) = -\eta_k(x)$$

El signo negativo de $\eta_k(x)$ se escoge para hacer que $d_k(x)$ represente la clase mas parecida. Entre menor sea al valor de $\eta_k(x)$, mas acertado el que $x \in \omega_1$, esta es la que se conoce como la Función Discriminante de Bayes.

$$\text{Función Discriminante de Bayes} \rightarrow d_k(x) = -\eta_k(x)$$



3.2.2 DECISIÓN DE MÁXIMA PROBABILIDAD

Para el caso de dos clases ($M=2$), la pérdida condicional promedio de que $x \in \omega_1$, se plantea de la siguiente manera:

$$r_1 = L_{11}P(x|\omega_1)P(\omega_1) + L_{21}P(x|\omega_2)P(\omega_2)$$

$$r_2 = L_{12}P(x|\omega_2)P(\omega_1) + L_{22}P(x|\omega_2)P(\omega_2)$$

Se dice que $x \in \omega_1$

$$L_{11}P(x|\omega_1)P(\omega_1) + L_{21}P(x|\omega_2)P(\omega_2) < L_{12}P(x|\omega_2)P(\omega_1) + L_{22}P(x|\omega_2)P(\omega_2)$$

Si se simplifica lo anterior, tendríamos:

$$\text{La regla de máxima verosimilitud} \rightarrow \frac{p(x|\omega_1)}{p(x|\omega_2)} > \frac{(L_{22}-L_{21})p(\omega_1)}{(L_{11}-L_{12})p(\omega_2)}$$

Si se generaliza para varios casos:

$$L_{ki} = \frac{p(x|\omega_k)}{p(x|\omega_i)} > \frac{p(x|\omega_j)}{p(x|\omega_k)}$$

De donde el criterio de asignación es el siguiente:

$$x \in \omega_k \text{ Si } L_{ki} > 1$$

Entonces:

$$P(x|\omega_k)P(\omega_k) > P(x|\omega_i)P(\omega_i)$$

Entonces la función discriminante se puede expresar de la siguiente manera:



CAPITULO 3



$$d_k = P(x|w_k)P(w_k)$$

Una forma alternativa seria la siguiente:

$$d_k = \log P(x|w_k) + \log P(w_k)$$



4 RELAJACIÓN DETERMINISTA

Los métodos bayesianos han sido basados en los modelos de Markov, usualmente su aplicación se puede ver en las funciones de energía para cada uno de los métodos bayesianos. Desafortunadamente esta aplicación necesita una gran capacidad computacional, la cual se puede solucionar con un método conocido como optimización combinatoria, este presenta grandes desventajas una de ellas, la mas conocida, es la capacidad de procesamiento computacional que requiere el método, este se puede evitar mediante dos formas, una forma es el uso de algoritmos determinísticos y el otro es el procesamiento paralelo para la realización del proceso, por razones obvias esta tesis se enfoco al uso de algoritmos determinísticos para la optimización del procesamiento de imágenes; esto se ve reflejado en la velocidad de procesamiento de los algoritmos.

4.1 ICM- ITERATED CONDITIONAL MODES

ICM es un algoritmo determinístico el cual dice que si se tiene una buena configuración inicial, es decir una buena clase inicial como por ejemplo, en el algoritmo de segmentación bayesiana, la calidad del resultado depende fuertemente de que tan cercanos sea los valores de energía del valle central a las clases dadas por la segmentación.

El algoritmo ICM, tiene las siguientes características:

- Empezar con una buena clase, en este caso se tendrán las clases dadas por Bayes, así como definir el número de iteraciones que va a hacer el barrido, va a estar dado por k .
- Este algoritmo no depende de la temperatura, esto se debe a que la energía mínima con la que se empieza es suficiente.



4.2 APLICACIÓN DE ICM

Se tiene X la imagen original, W la imagen segmentada por Bayes y W_i sus clases.

1. Comenzar en una “buena” configuración inicial W (resultado de Bayes), con $k=0$, siendo k el número de iteración.
2. En cada iteración o barrido completo de la imagen:
 - a) Escoger aleatoriamente un píxel de coordenadas (i,j) .
 - b) A partir de la configuración actual ω^k de la vecindad del píxel (i,j) , determine las posibles configuraciones de energía
 - c) Calcular la energía condicional asociada a cada clase en la vecindad.
 - d) Calcular la energía de cada clase w_i en la configuración de vecindad:

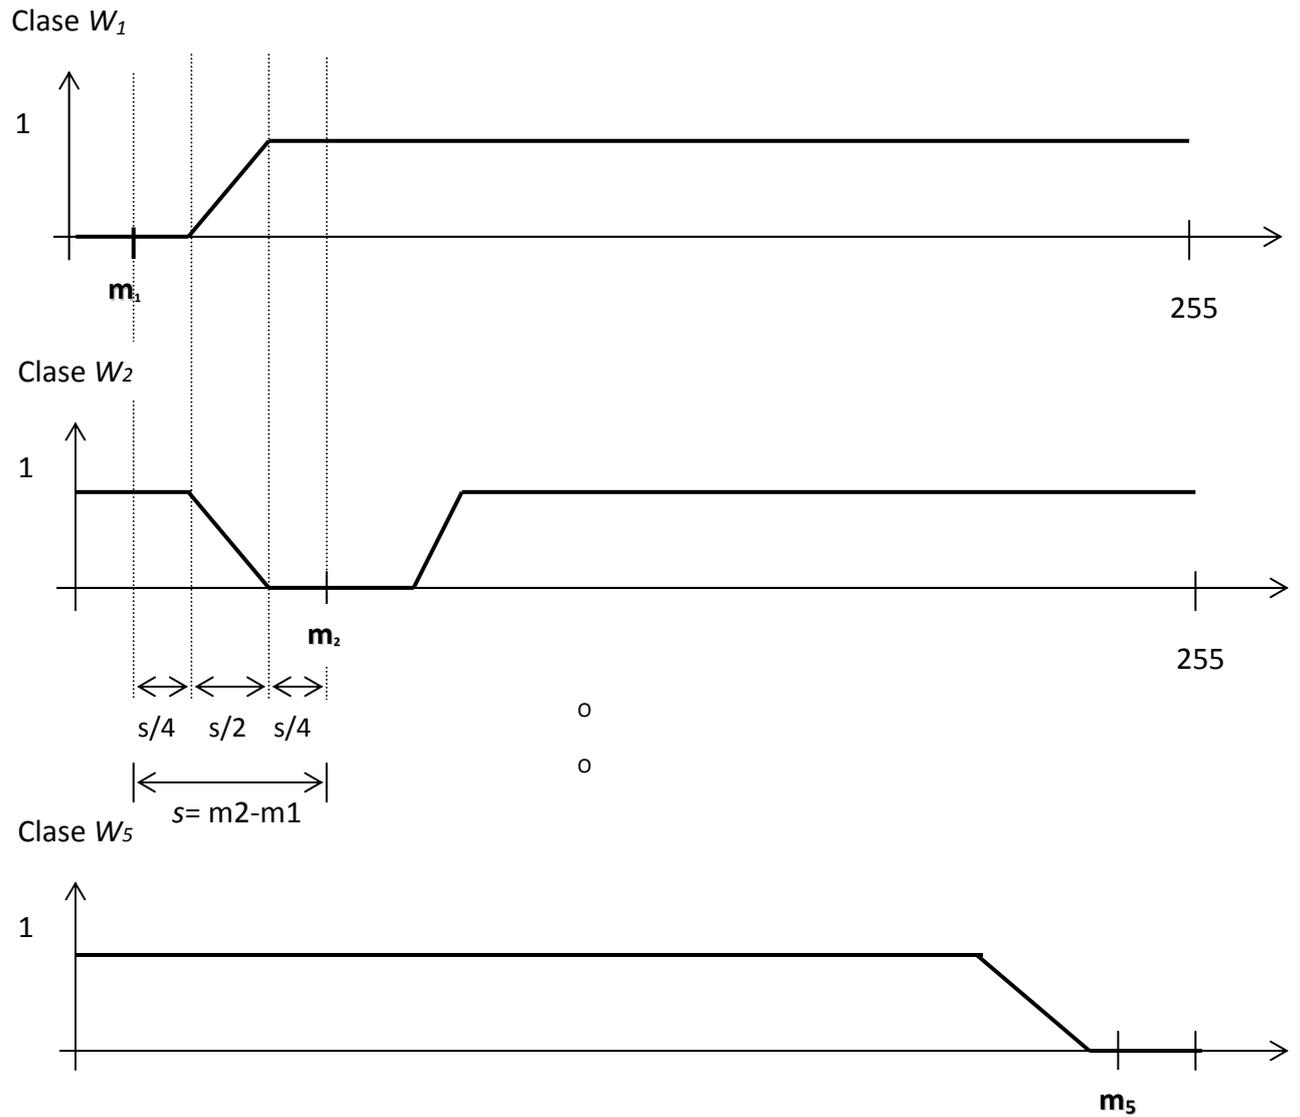
$$U(w_i|X) \approx U(X|w_i) + U(w_i)$$

Seleccionando la clase de energía mínima

$$w_i^{k+1} = \arg \min_{w_i \in \omega^k} U(w_i|X)$$



TERMINOS DE ENERGIA $U(X|w_i)$





5 RESULTADOS

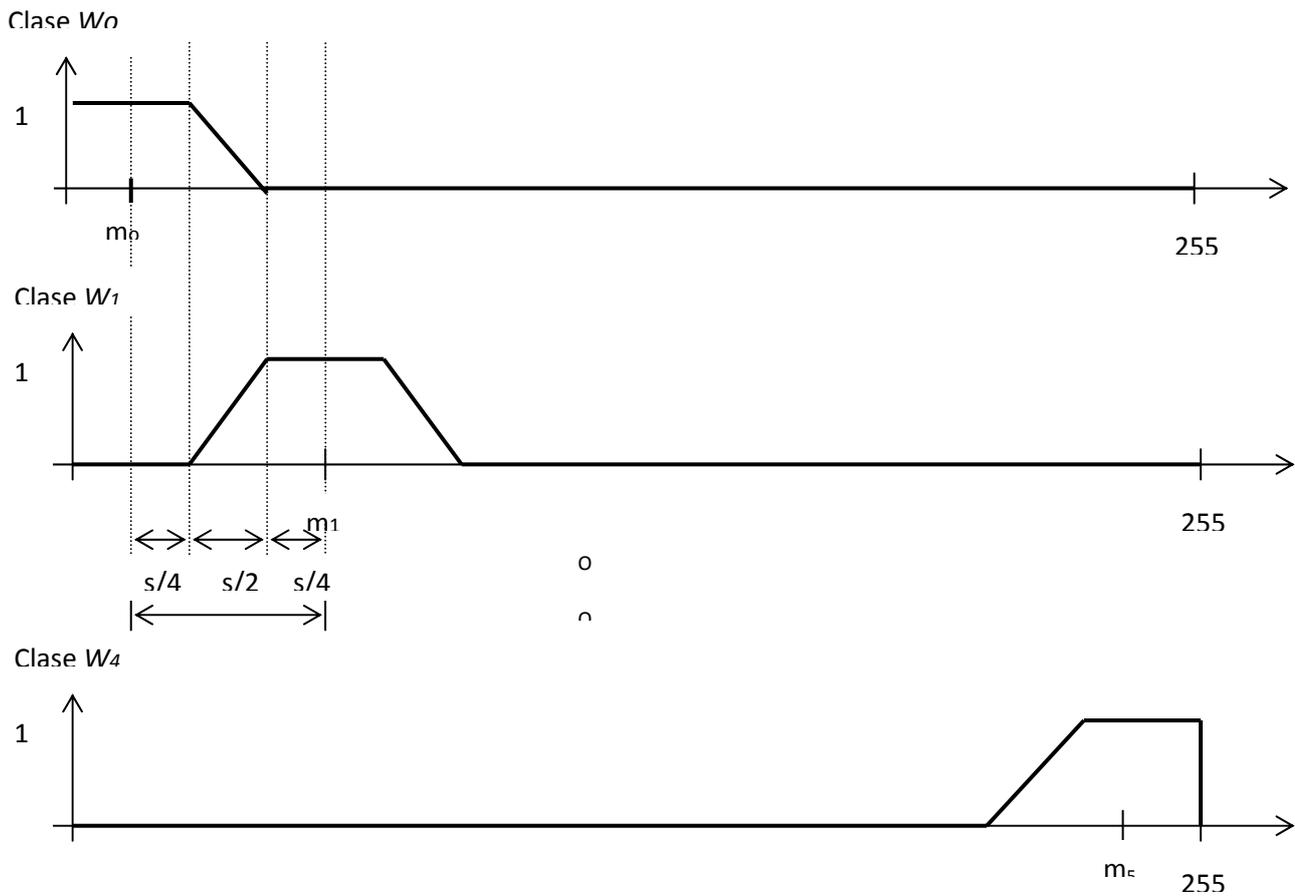
Segmentación Bayesiana

Primera Parte: Obtención de Parámetros

Sobre la imagen a trabajar, se definen 5 ventanas que identifiquen a 5 clases típicas: río, torre, campo de fútbol, techos blancos y techos opacos. Sobre cada ventana se calcula la media m .

Se aproximan las probabilidades conjuntas del numerador de la regla de Bayes mediante las funciones mostradas en la figura siguiente, las cuales indican la probabilidad condicional de que

un píxel dado pertenezca a la clase ω_k Términos de probabilidad condicional $P(X|w_i)$





Segunda Parte:

Pre-segmentación

Se emplea la función discriminante de Bayes

$$d_k = P(x|\omega_k)P(\omega_k)$$

Como no se conoce la probabilidad a priori $P(\omega_k)$, se consideran equiprobables, de un $\frac{1}{S}$ las probabilidades de las clases $P(\omega_k)$

Se analiza cada uno de los píxeles de la imagen X, clasificando a cada píxel de acuerdo con los valores máximos de la probabilidad $\text{arg max } P(\omega_k)$

$$d_k = P(x|\omega_k)P(\omega_k)$$

Tercera Parte: Segmentación

En esta etapa, se efectúa nuevamente una segmentación bayesiana. En este caso se utilizan las probabilidades a priori (ω_k) actualizadas. Esta actualización, se lleva a cabo dividiendo el número de píxeles que pertenecen a una clase entre el total de píxeles de la imagen.

Después de realizar la actualización de probabilidades, se clasifica cada uno de los píxeles de la imagen utilizando la misma función Bayesiana de la etapa anterior.

Durante el proceso de clasificación, el nivel de gris de cada píxel se proyecta sobre cada una de las funciones para determinar la probabilidad condicional de que el píxel pertenezca a la clase $P(\omega_i)$.

El número de funciones este determinado por el número de clases.



Analizando la figura, si el nivel de gris del píxel analizando, esta en el rango $0 < \omega_0 < m_0$, la probabilidad condicional para la clase ω_0 es de 1. Para las demás clases, las probabilidades serán de cero.

Pero si el nivel de gris del píxel analizado esta en el rango de $m_0 + \frac{s}{4}$ y $m_0 + \frac{3s}{4}$, entonces existen dos valores de probabilidad condicional para este píxel, ya que como se observa en la figura, este píxel puede pertenecer a la clase ω_0 o a la clase ω_1 . Para obtener la probabilidad condicional de que el píxel analizado pertenezca a la clase ω_0 , se utiliza la función siguiente:

$$W_0 = \frac{-2x}{s} + \frac{2m_0}{s} + \frac{3}{2}$$

Donde: $W_0 \rightarrow$ Es la probabilidad de la clase W_0

$x \rightarrow$ Es el píxel analizado

$m_0 \rightarrow$ Es la media de W_0

$s \rightarrow m_1 - m_0$

De igual forma, para obtener la probabilidad condicional de que el nivel de gris de píxel analizado pertenezca a la clase ω_1 , se utiliza la siguiente función:

$$W_1 = \frac{2x}{s} + \frac{2m_0}{s} + \frac{3}{2}$$

El píxel analizado, pertenecerá a la clase que tenga una probabilidad condicional mayor.



CAPITULO 5



Para la clase W_1 , si el nivel de gris a analizar es menor a $m_1 - \frac{3s}{4}$ (lado izquierdo de la figura de la clase W_1) y mayor a $m_1 + \frac{3s}{4}$ (lado derecho de la figura de la clase W_1), entonces la probabilidad condicional será igual cero.

Si el nivel de gris de píxel analizado es mayor o igual a $m_1 - \frac{s}{4}$ y menor o igual a $m_0 + \frac{s}{4}$, entonces la probabilidad condicional será de 1.

Para las clases W_2 y W_3 , se realiza un análisis similar, solo hay que tomar en cuenta el valor de las medias.

Para el caso de la clase W_4 , si se analiza la figura, y se observa que el nivel de gris del píxel analizando, esta en el rango $m_0 < x < 255$, la probabilidad condicional para la clase W_4 es de 1. Para las demás clases, las probabilidades serán de cero.



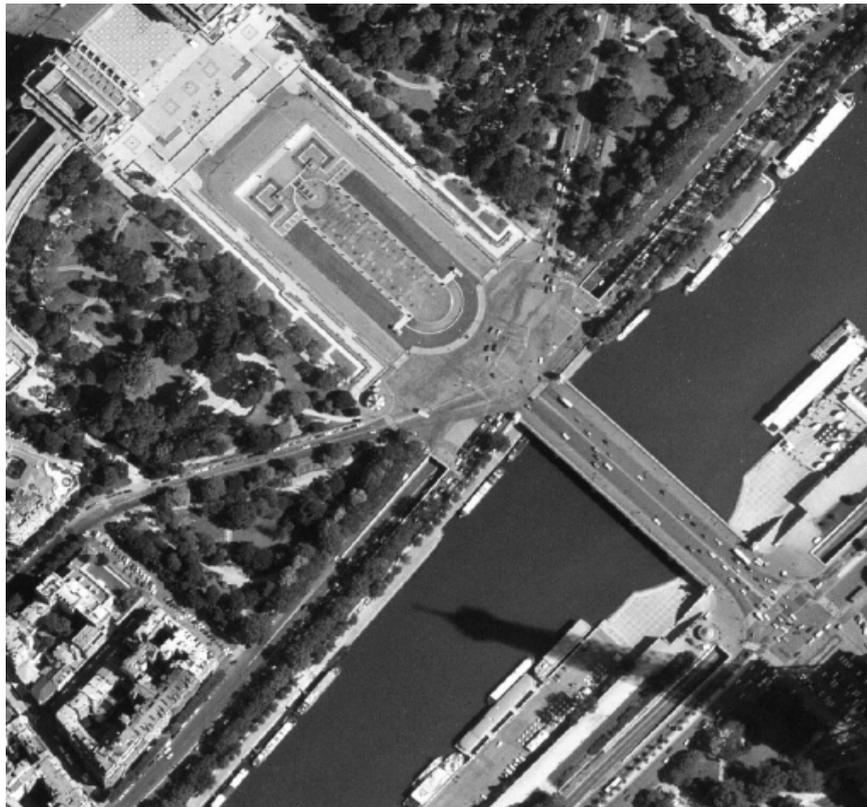
5.1 IMÁGENES DE PRUEBA

5.1.1 REPRESENTACION PIRAMIDAL

➤ RESULTADO DE SEGMENTACIÓN BAYESIANA

IMAGEN 1 → IMAGEN ORIGINAL-PARIS3

Imagen Original

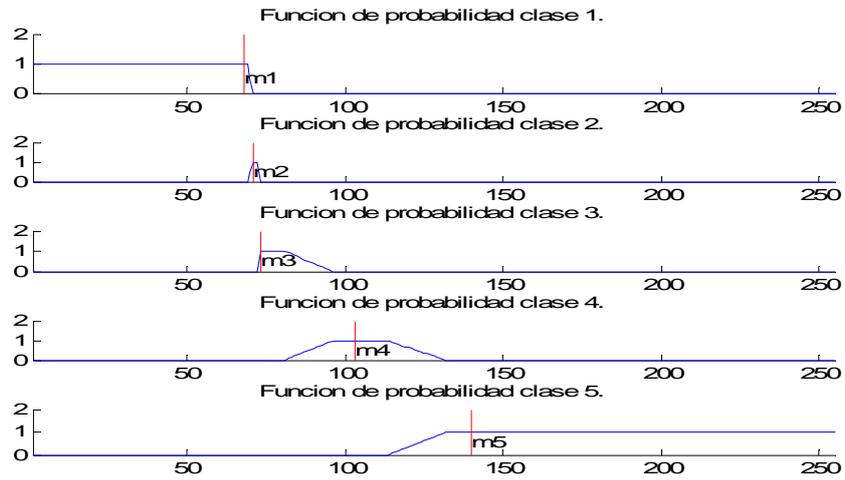




CAPITULO 5



PRE-SEGMENTACIÓN **PROBABILIDADES IGUALES (1/5)** → Tiempo usado: 0.45300 [S]



Presegmentacion con probabilidades iguales





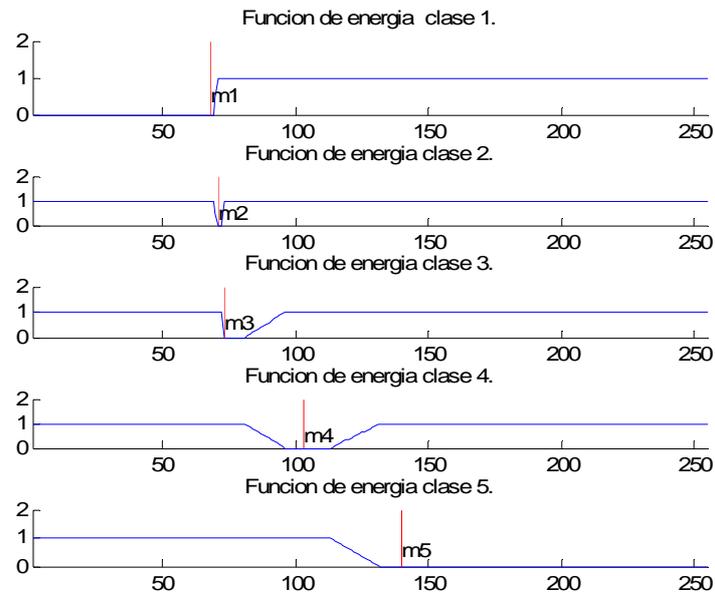
SEGMENTACIÓN - **PROBABILIDADES DIFERENTES** → Tiempo usado: 3.01500 [S]

Segmentacion de la imagen algoritmo de bayes





➤ ALGORITMO ICM



Tiempo usado por ICM en segundos en la iteración 1: **42.65600 [S]**

Tiempo usado por ICM en segundos en la iteración 2: **59.28200 [S]**

Tiempo usado por ICM en segundos en la iteración 3: **63.93700 [S]**

Tiempo total: **165.87500 [S] = 3.16 [Min]**



➤ **ALGORITMO ICM- ITERACION1**

Imagen algoritmo ICM: 1 iteracion



➤ **ALGORITMO ICM – ITERACION 2**

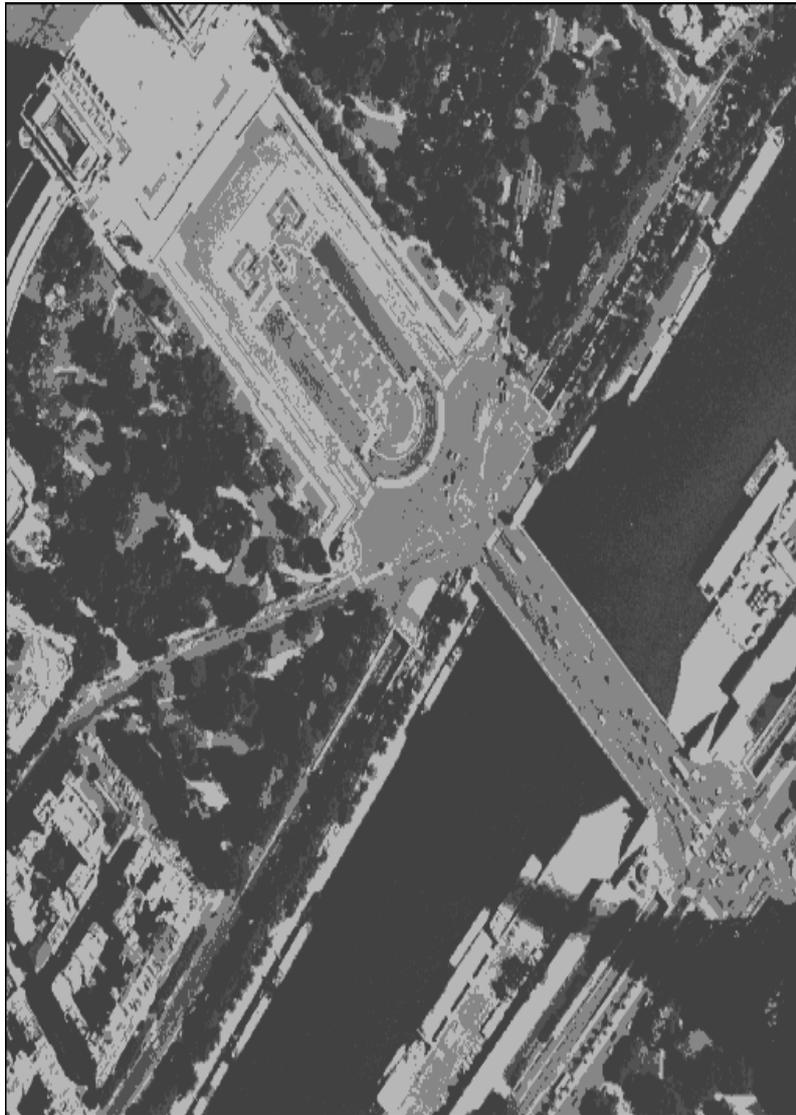
Imagen algoritmo ICM: 2 iteracion





➤ **IMAGEN FINAL OBTENIDA DESPUES DE 3 ITERACIONES (AMPLIACION)**

Imagen obtenida despues de 3 iteraciones



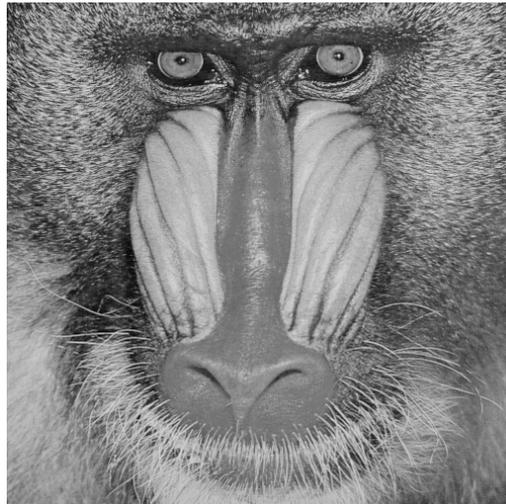


CAPITULO 5



IMAGEN 2 → IMAGEN ORIGINAL - BABOON

Imagen Original

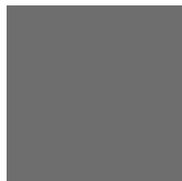


MEDIAS SELECCIONADAS

Primera Clase:



Segunda Clase:



Tercera Clase:



Cuarta Clase:



Quinta Clase:

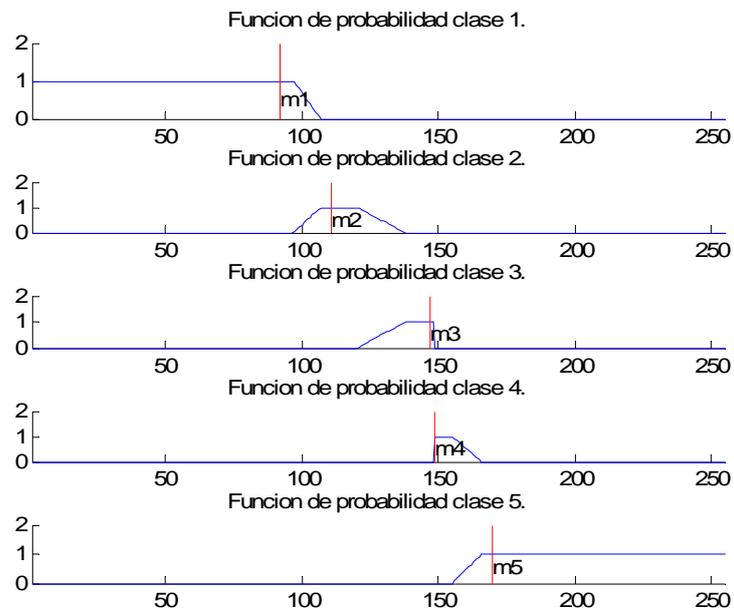




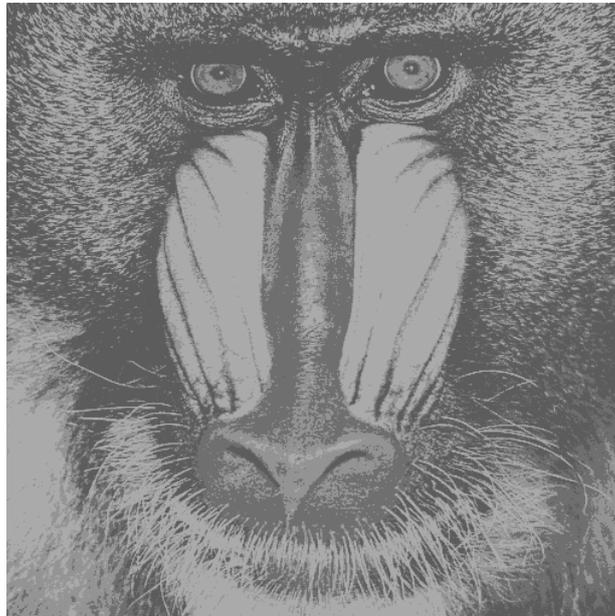
CAPITULO 5



PRE-SEGMENTACIÓN **PROBABILIDADES IGUALES (1/5)** → Tiempo usado: 0.45300 [S]



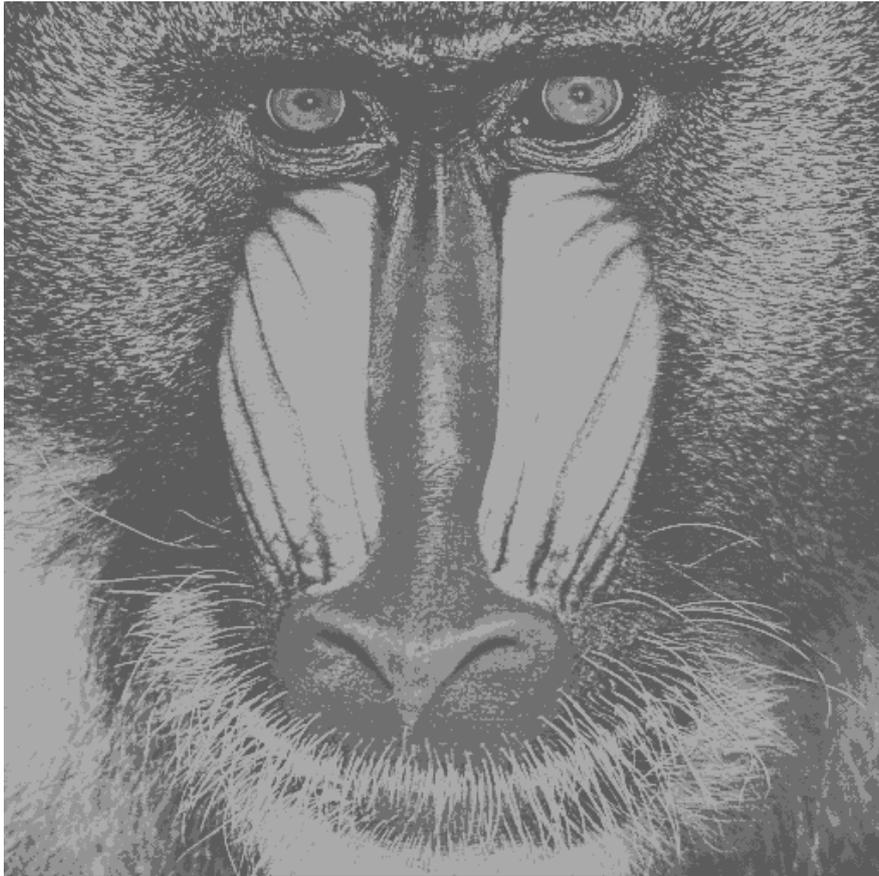
Presegmentacion con probabilidades iguales





SEGMENTACIÓN - **PROBABILIDADES DIFERENTES** → Tiempo usado: 2.90600 [S]

Segmentacion de la imagen algoritmo de bayes

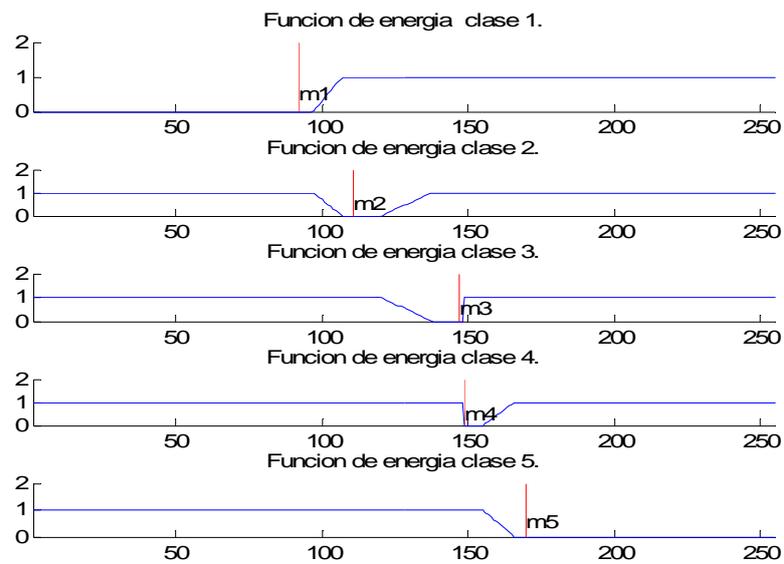




CAPITULO 5



➤ ICM



Tiempo usado por ICM en segundos en la iteración 1: **38.59400 [S]**

Tiempo usado por ICM en segundos en la iteración 2: **41.53100 [S]**

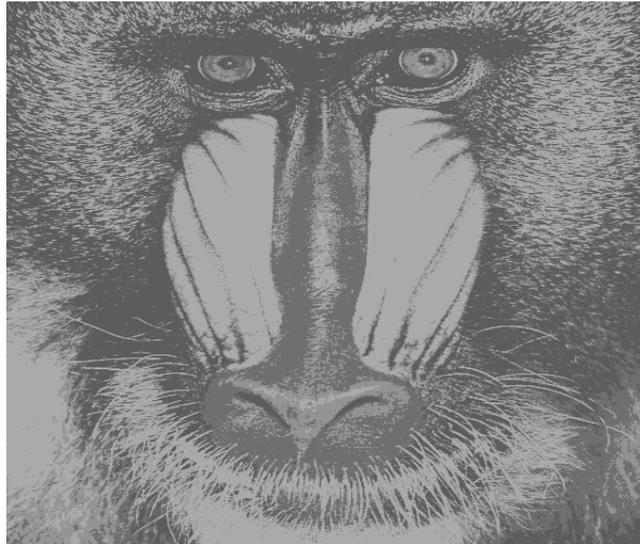
Tiempo usado por ICM en segundos en la iteración 3: **55.12500 [S]**

Tiempo total: **135.25000 [S] = 2. 15 [Min]**



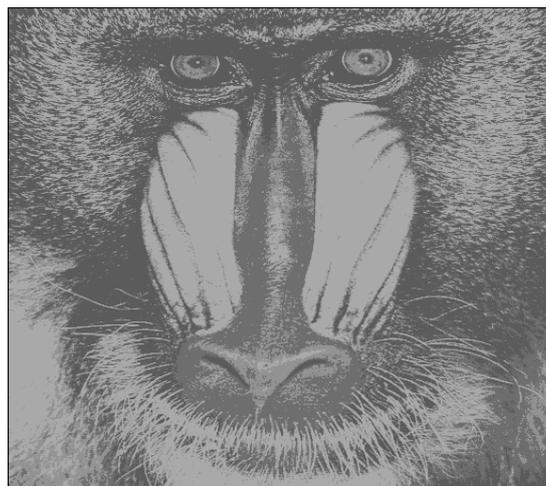
➤ **ALGORITMO ICM – ITERACION 1**

Imagen algoritmo ICM: 1 iteracion



➤ **ALGORITMO ICM – ITERACION 2**

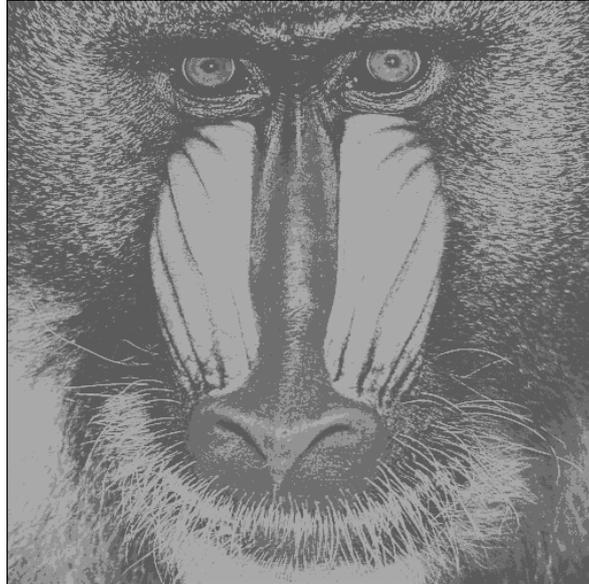
Imagen algoritmo ICM: 2 iteracion





➤ ALGORITMO ICM –ITERACION 3

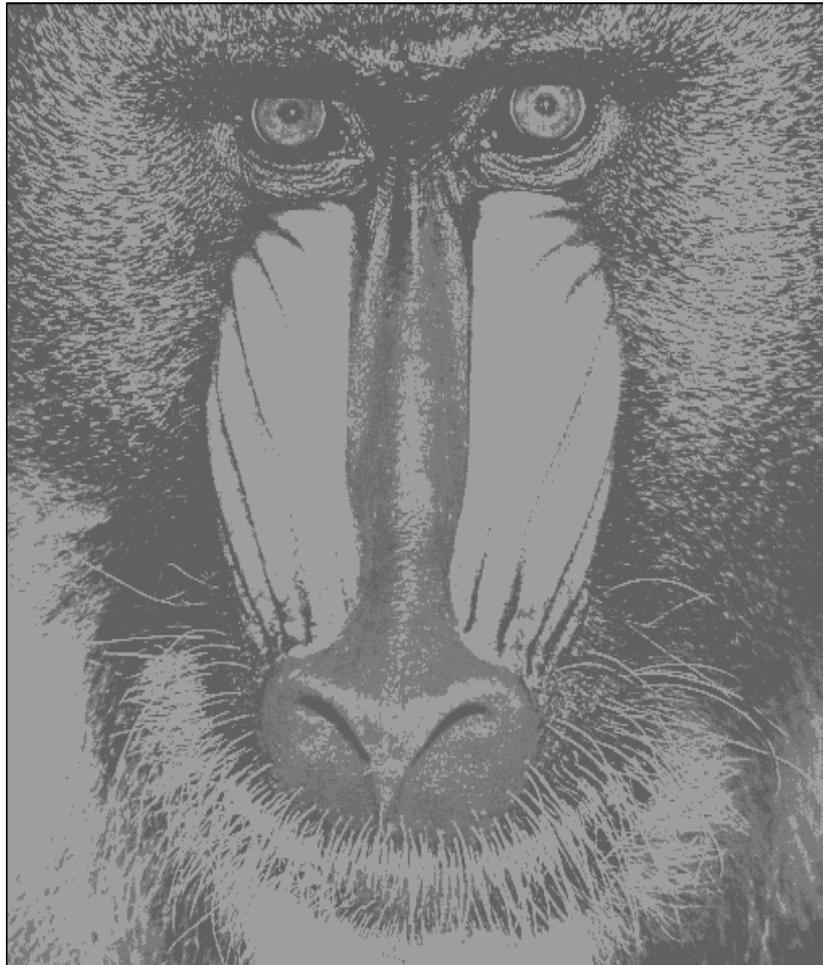
Imagen algoritmo ICM 3 iteracion





➤ **IMAGEN FINAL OBTENIDA DESPUES DE 3 ITERACIONES (AMPLIACION)**

Imagen obtenida despues de 3 iteraciones





CAPITULO 5



IMAGEN 3 → IMAGEN ORIGINAL - LENA

Imagen Original

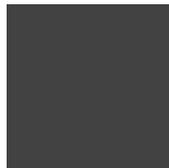


MEDIAS SELECCIONADAS

Primera Clase:



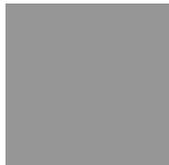
Segunda Clase:



Tercera Clase:



Cuarta Clase:



Quinta Clase:

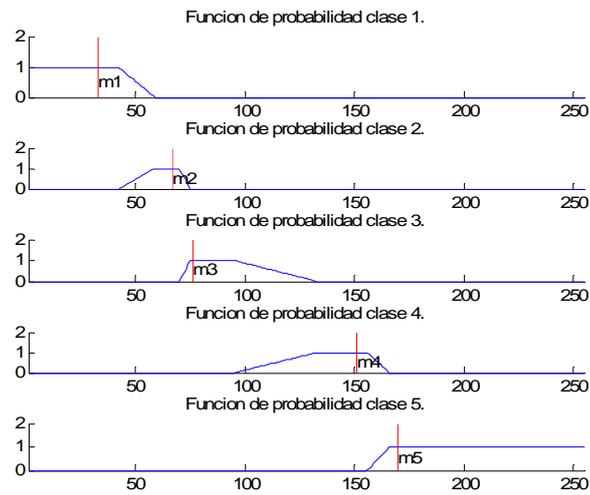




CAPITULO 5



PRE-SEGMENTACIÓN **PROBABILIDADES IGUALES (1/5)** → Tiempo usado: 0.46800 [S]



Presegmentacion con probabilidades iguales





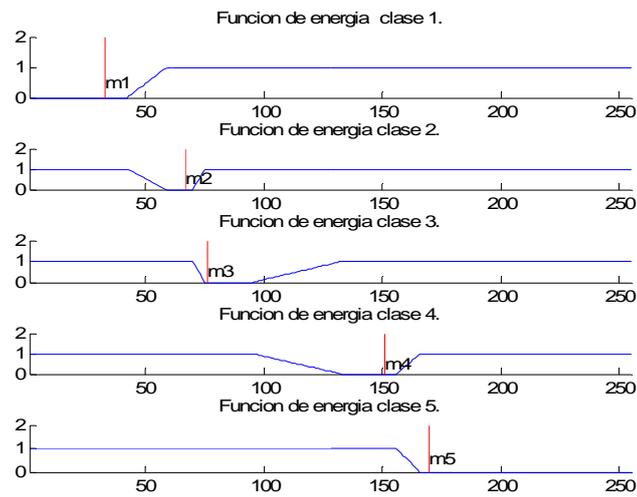
SEGMENTACIÓN - **PROBABILIDADES DIFERENTES** → Tiempo usado: 2.95300 [S]

Segmentacion de la imagen algoritmo de bayes





➤ ALGORITMO ICM



Tiempo usado por ICM en segundos en la iteración 1: **39.25000 [S]**

Tiempo usado por ICM en segundos en la iteración 2: **53.59400 [S]**

Tiempo usado por ICM en segundos en la iteración 3: **56.70300 [S]**

Tiempo total: **149.54700 [S] = 2.299 [Min]**



➤ **ALGORITMO ICM- ITERACION1**

Imagen algoritmo ICM: 1 iteracion



➤ **ALGORITMO ICM – ITERACION 2**

Imagen algoritmo ICM: 2 iteracion





➤ **ALGORITMO ICM –ITERACION 3**

Imagen algoritmo ICM: 3 iteracion





➤ **IMAGEN FINAL OBTENIDA DESPUES DE 3 ITERACIONES (AMPLIACION)**

Imagen obtenida despues de 3 iteraciones



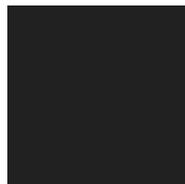


IMAGEN 4 → IMAGEN ORIGINAL - PARIS

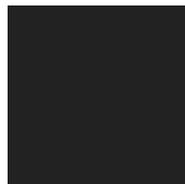


MEDIAS SELECCIONADAS

Primera Clase:



Segunda Clase:



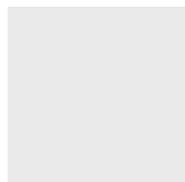
Tercera Clase:



Cuarta Clase:



Quinta Clase:

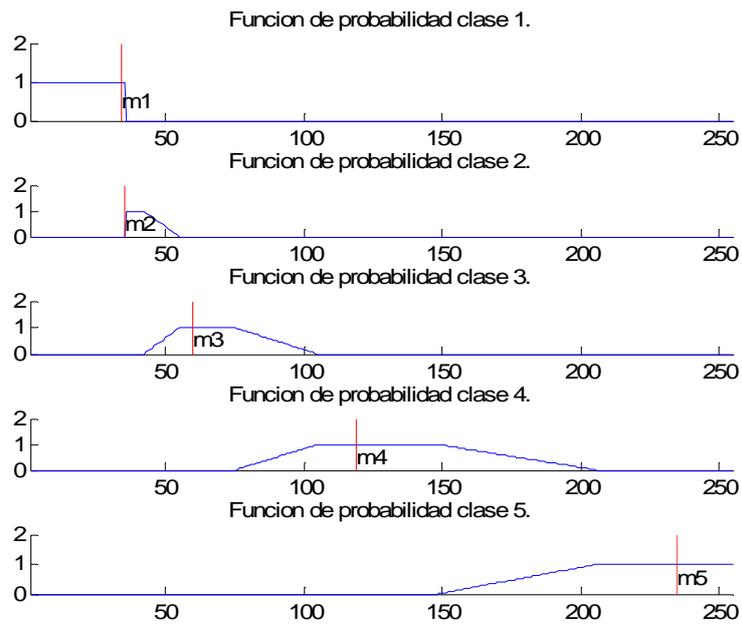




CAPITULO 5



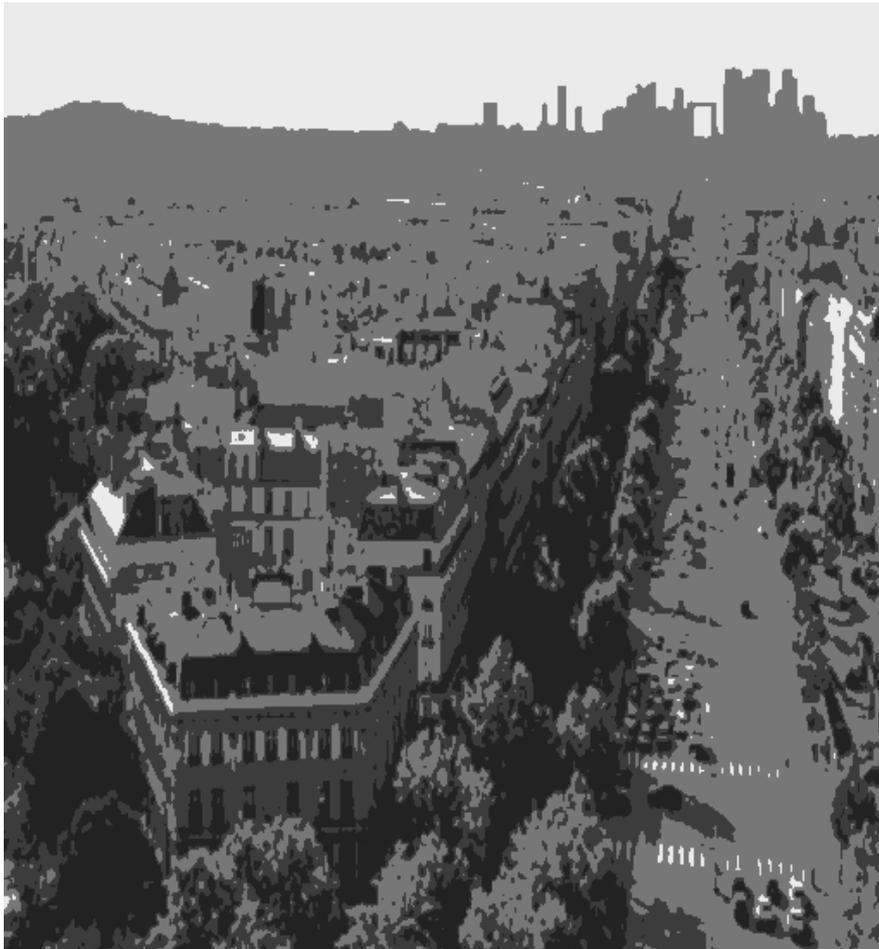
PRE-SEGMENTACIÓN-PROBABILIDADES IGUALES (1/5) → Tiempo usado: 0.46900 [S]





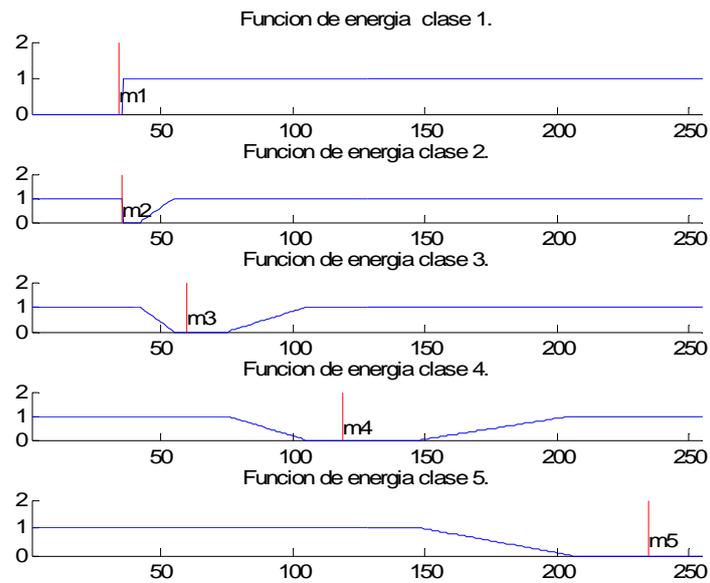
SEGMENTACIÓN-**PROBABILIDADES DIFERENTES** → Tiempo usado: 3.17200 [S]

Segmentacion de la imagen algoritmo de bayes





➤ **ALGORITMO ICM**



Tiempo usado por ICM en segundos en la iteración 1: **40.06300 [S]**

Tiempo usado por ICM en segundos en la iteración 2: **47.54700 [S]**

Tiempo usado por ICM en segundos en la iteración 3: **60.46900 [S]**

Tiempo total: **148.07900 [S] = 2.28 [Min]**



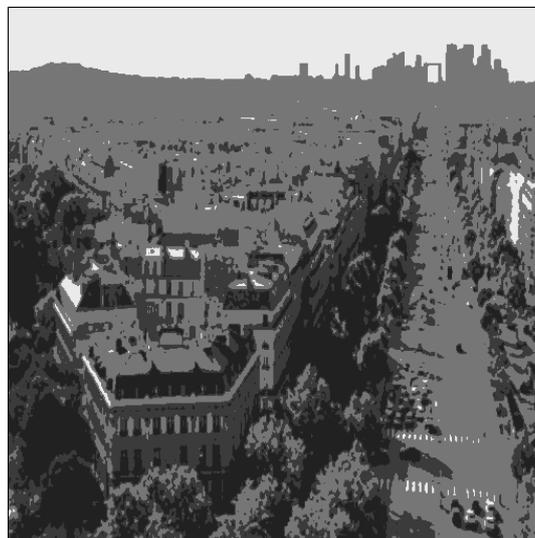
➤ ALGORITMO ICM- ITERACION 1

Imagen algoritmo ICM: 1 iteracion



➤ ALGORITMO ICM- ITERACION 2

Imagen algoritmo ICM: 2 iteracion





➤ ALGORITMO ICM- ITERACION 3

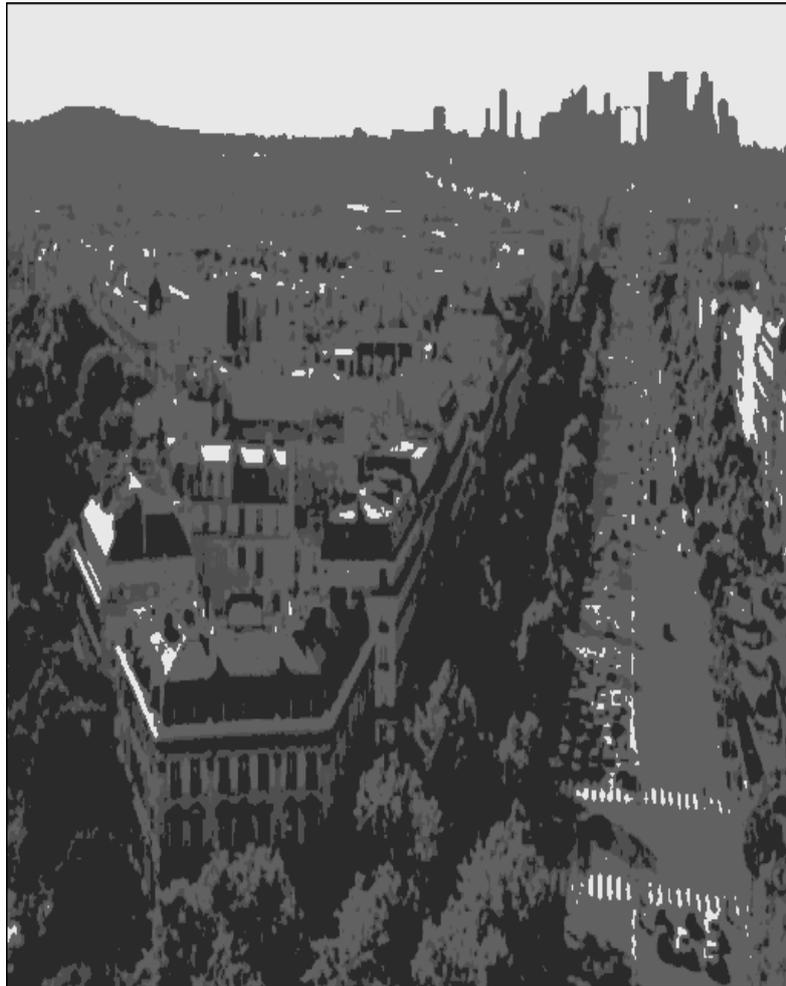
Imagen obtenida despues de 3 iteraciones





IMAGEN FINAL OBTENIDA DESPUES DE 3 ITERACIONES (AMPLIACION)

Imagen obtenida despues de 3 iteraciones





CAPITULO 5



IMAGEN 5 → IMAGEN ORIGINAL – PARIS2

Imagen Original



MEDIAS SELECCIONADAS

Primera Clase:



Segunda Clase:



Tercera Clase:



Cuarta Clase:



Quinta Clase:

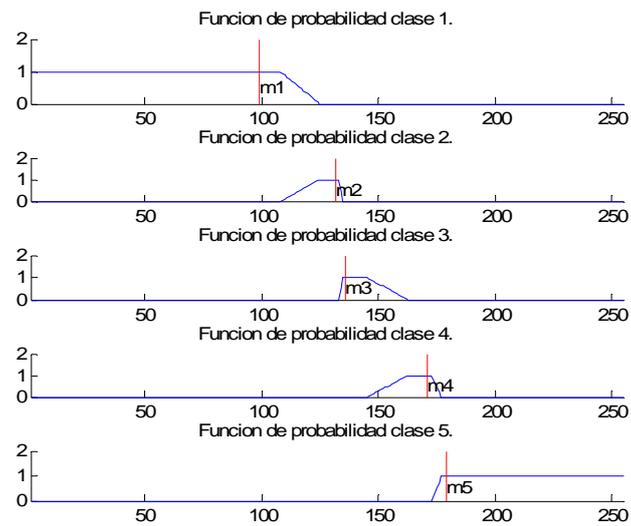




CAPITULO 5



PRE-SEGMENTACIÓN **PROBABILIDADES IGUALES (1/5)** → Tiempo usado: 0.43700 [S]



Presegmentacion con probabilidades iguales





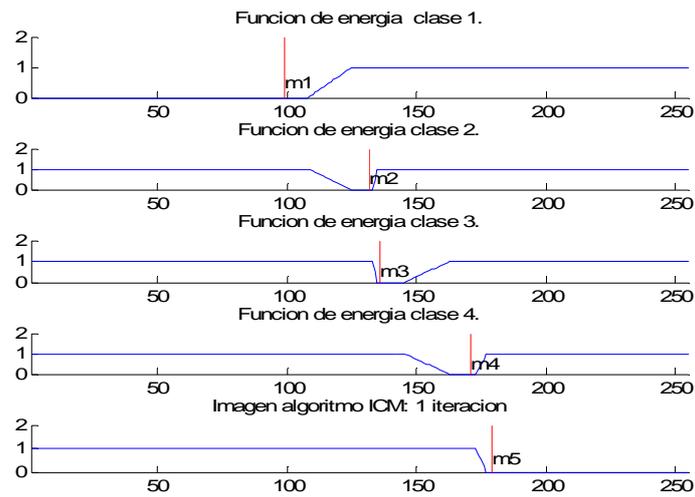
SEGMENTACIÓN -**PROBABILIDADES DIFERENTES** → Tiempo usado: 2.84400 [S]

Segmentacion de la imagen algoritmo de bayes





➤ **ALGORITMO ICM**



Tiempo usado por ICM en segundos en la iteración 1: **39.45300 [S]**

Tiempo usado por ICM en segundos en la iteración 2: **55.65600 [S]**

Tiempo usado por ICM en segundos en la iteración 3: **65.76500 [S]**

Tiempo total de ICM: **160.87400 [S] = 3.081 [Min]**



➤ **ALGORITMO ICM- ITERACION1**



➤ **ALGORITMO ICM – ITERACION 2**

Imagen algoritmo ICM: 2 iteracion





➤ **ALGORITMO ICM –ITERACION 3**

Imagen algoritmo ICM: 3 iteracion





➤ **IMAGEN FINAL OBTENIDA DESPUES DE 3 ITERACIONES**

Imagen obtenida despues de 3 iteraciones





5.1.2 REPRESENTACION NO PIRAMIDAL

En esta parte se aplicó la segmentación bayesiana así como el ICM a las imágenes originales, obteniendo los siguientes resultados.

IMAGEN 1 → IMAGEN ORIGINAL



PRE-SEGMENTACIÓN PROBABILIDADES IGUALES (1/5)





SEGMENTACIÓN -PROBABILIDADES DIFERENTES



ALGORITMO ICM



TIEMPO TOTAL DE PARIS2: 4.51.47 [MIN]



CAPITULO 5



IMAGEN 2 → IMAGEN ORIGINAL



PRE-SEGMENTACIÓN PROBABILIDADES IGUALES (1/5)





SEGMENTACIÓN -PROBABILIDADES DIFERENTES



ALGORITMO ICM



TIEMPO TOTAL DE PARIS: 4.56.24 [MIN]



CAPITULO 5



IMAGEN 3 → IMAGEN ORIGINAL

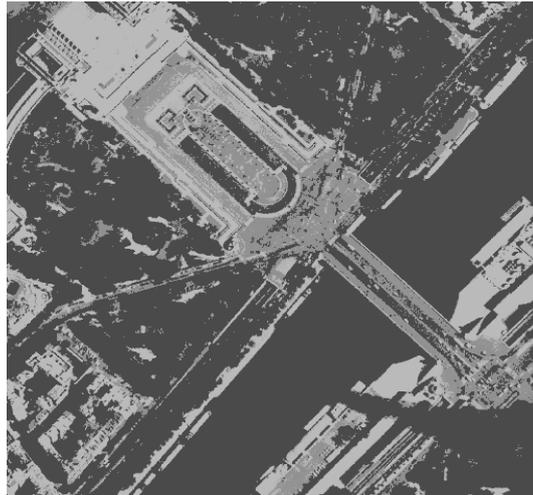


PRE-SEGMENTACIÓN PROBABILIDADES IGUALES (1/5)

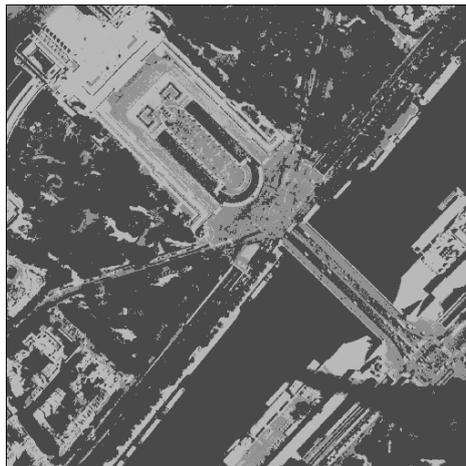




SEGMENTACIÓN -PROBABILIDADES DIFERENTES



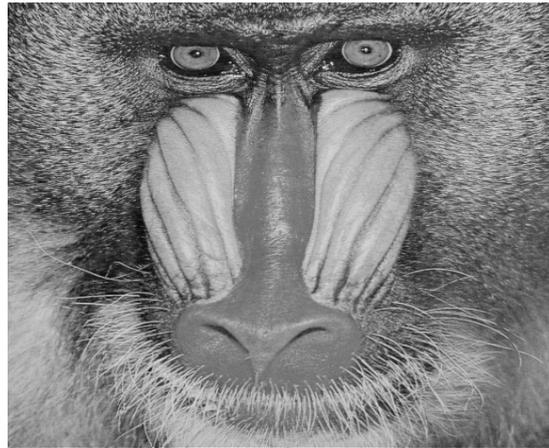
ALGORITMO ICM



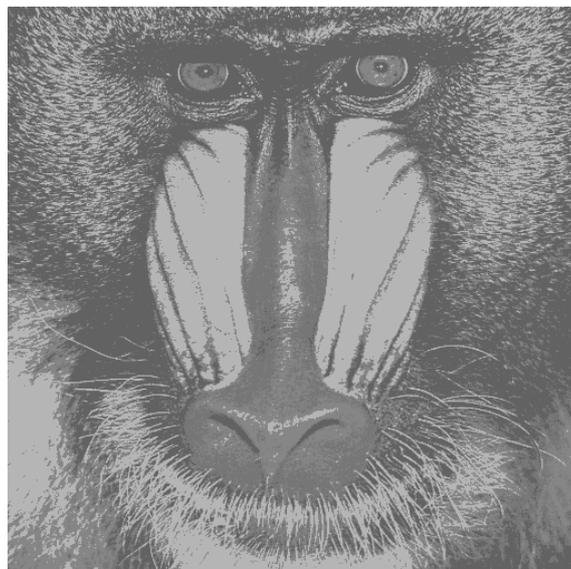
TIEMPO TOTAL DE PARIS3: 5.04.51 [MIN]



IMAGEN 4 → IMAGEN ORIGINAL

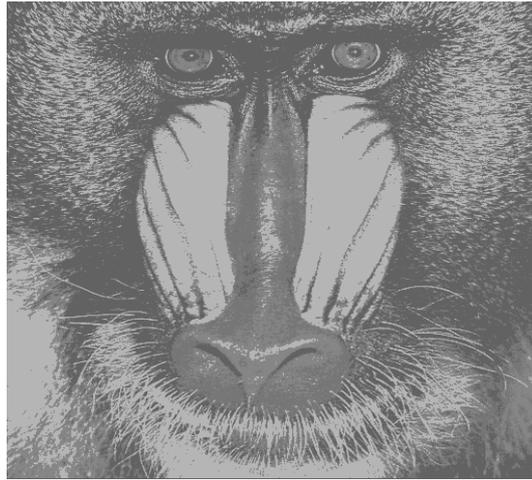


PRE-SEGMENTACIÓN PROBABILIDADES IGUALES (1/5)

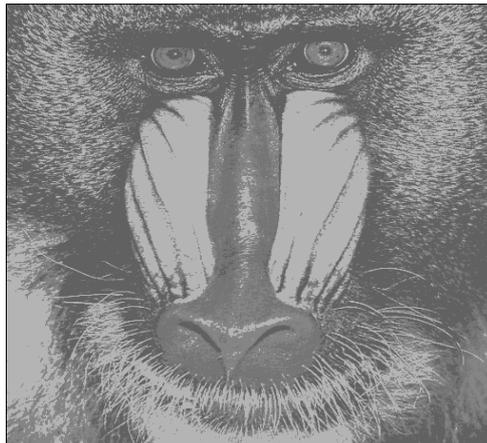




SEGMENTACIÓN -PROBABILIDADES DIFERENTES



ALGORITMO ICM



TIEMPO TOTAL DE BABOON: 5.10.93 [MIN]



CAPITULO 5



IMAGEN 5 → IMAGEN ORIGINAL



PRE-SEGMENTACIÓN PROBABILIDADES IGUALES (1/5)





SEGMENTACIÓN -PROBABILIDADES DIFERENTES



ALGORITMO ICM



TIEMPO TOTAL DE: 4.35.29 [MIN]

CYNTHIA VELAZCO VELASCO



5.2 COMPARACIÓN DE FUNCIONALIDAD

IMAGEN	TIEMPO DE PROCESAMIENTO PIRAMIDAL [MIN]	TIEMPO DE PROCESAMIENTO NO PIRAMIDAL [MIN]
PARIS3	3.16	5.04
PARIS2	3.08	4.51
PARIS	2.28	4.56
BABOON	2.15	5.10
LENA	2.29	4.35

5.2.1 RESULTADOS OBTENIDOS

Para probar los métodos de ICM y segmentación bayesiana, propuestos en esta tesis, se utilizaron cinco imágenes diferentes, de 256 niveles de grises y de tamaño de 512x512 píxeles cada una de las imágenes.

Siguiendo el método propuesto en el esquema de análisis se realizaron varias pruebas, observando que la pre-segmentación y segmentación dependen del valor de las medias que se escojan. Para el método ICM dependerá totalmente del número de iteraciones que se hagan, mientras más iteraciones se realicen mejor resolución tendrá la imagen final.



CAPITULO 5



Se empezaron con imágenes pequeñas de 128x128 píxeles y se observó que el tiempo de procesamiento disminuye y la calidad se presenta de la misma manera para todas las imágenes, desde las pequeñas de 128 píxeles hasta la de 512 píxeles.

Cabe mencionar que el tiempo de procesamiento, depende en gran medida del procesador que se use para realizar dicho procesamiento, en esta tesis se utilizó una computadora Pentium IV y Matlab 7. Se midió el tiempo de procesamiento de cada imagen y varió de

5 [min] (cuando se tenían 10 iteraciones), hasta aproximadamente 1 [hora], cuando se tenían más de 80 iteraciones. Cuando las iteraciones son mayores a 100 el tiempo de procesamiento incrementa hasta horas.



6 CONCLUSIONES

Por medio de la percepción remota, podemos obtener información de un fenómeno sin estar en contacto directo con el. La forma de obtener esta información es a través de fotografías aéreas y satelitales. Los datos que proporcionan estas fotografías son analizados mediante diferentes técnicas del Procesamiento Digital de Imágenes.

El objetivo de esta tesis es implementar un esquema estadístico para la segmentación y clasificación de fotografías aéreas de alta resolución. Para cumplir con este objetivo se utilizaron técnicas de segmentación bayesiana e ICM.

En la técnica de segmentación, se utilizó una herramienta muy importante; la matriz de obtención de medias. Esta matriz nos ayuda a obtener las medias para poder aplicar los métodos de segmentación y clasificación bayesiana.

Normalmente, para calcular la matriz de obtención de medias, se requiere de mucho tiempo para obtener un resultado, ya que se utilizan muchos recursos computacionales para su cálculo, por lo tanto, se propuso reducir este tiempo de procesamiento disminuyendo el número de niveles de gris, y calculando la matriz mediante un método rápido, tal como una representación piramidal.

Por parte del algoritmo ICM, se utilizó la función de energía, la cual depende totalmente de beta, de lo que se observó que si beta es mucho menor a cero, aumentan en gran proporción los tiempos de procesamiento, a parte que no se logran distinguir bien las medias, es decir la distancia de estas, en las figuras trapezoidales es de máximo 5 unidades, sin embargo este comportamiento de beta refleja una preferencia por los niveles de grises más oscuros. Por otro lado cuando beta es mucho mayor o igual a cero se observan bien las medias así como una disminución en tiempo de procesamiento.



CAPITULO 6



En el caso de la representación piramidal, se observó que con respecto al caso no piramidal, el tiempo de procesamiento, disminuye casi en un 50%, que si se le aplica directamente Bayes o ICM a la imagen original; la calidad de la imagen no se ve afectada.

Con lo dicho anteriormente, se ha cumplido eficazmente con el objetivo propuesto al inicio de tesis, y por lo tanto, este trabajo puede servir para obtener mayor información sobre las imágenes de una escena determinada, y con esto lograr una mejor planificación de las zonas urbanas y no urbanas de nuestro país.



7 GLOSARIO

- **Variable aleatoria:** variable que cuantifica los resultados de un experimento aleatorio. Variable que toma diferentes valores como resultado de un experimento aleatorio. Categoría cuantificable que puede tomar diferentes valores cada vez que sucede un experimento o suceso, el valor sólo se conocerá determinísticamente una vez acaecido el suceso. La materia manejada por el estadístico son variables aleatorias o sea fenómenos de interés, cuyos resultados (datos) observados pueden diferir entre una respuesta y otra.
- **Distribución de probabilidades:** modelo teórico que describe la forma en que varían los resultados de un experimento aleatorio. Lista de los resultados de un experimento con las probabilidades que se esperarían ver asociadas con cada resultado.
- **Función de probabilidad:** función que asigna probabilidades a cada uno de los valores de una variable aleatoria discreta.
- **Función de densidad de probabilidad:** función que mide concentración de probabilidad alrededor de los valores de una variable aleatoria continua.
- **Función de distribución:** función que acumula probabilidades asociadas a una variable aleatoria.
- **Valor esperado o esperanza matemática:** es el valor de la variable aleatoria para el cual la función de distribución se maximiza. Para funciones de distribución simétricas con un máximo central el valor esperado coincide con la Media ponderada.



CAPITULO 7



- **Valor Medio:** (o momento de primer orden de una distribución) operador matemático que caracteriza la posición de la distribución de probabilidades. Media ponderada de los resultados de un experimento.



8 BIBLIOGRAFÍA

- [1] Tesis: Análisis y Clasificación Semi Automática de Escenas Urbanas del Distrito Federal. Eliud Fernández Aguirre, Facultad de Ingeniería, Mexico, D.F., 2002, pp 55, 123.
- [2] Pattern Recognition and Image Preprocessing. Sing Tze Bow, Department of Electrical Engineering Northern Illinois University, Dekalb, Illinois, pp 61.
- [3] Apuntes de Señales Aleatorias. Dr. Miguel Moctezuma Flores.
- [4] Phd Thesis. Zoltan Kato, 1994