

# Discriminación de diferentes tipos de bosque tropical mediante imágenes de satélite y datos auxiliares

## RESUMEN

Se presenta un procedimiento de análisis de datos espectrales y geográficos que permite obtener estimados de las probabilidades *a priori* de las categorías de cobertura del suelo en función del contexto geográfico. El modelo de probabilidades *a priori* así generado, se utilizó para realizar una clasificación bayesiana de máxima verosimilitud de una imagen Landsat TM, de la Región Central de Costa Rica. Después de modificar las probabilidades *a priori* la consistencia total de la clasificación en los sitios de entrenamiento mejoró de 74,6% (clasificación tradicional de máxima verosimilitud con probabilidades *a priori* iguales) a 91,9%, mientras que la precisión total de la clasificación en sitios controlados en el terreno por investigadores independientes mejoró de 68,7% a 89%. La precisión de la clasificación mejoró sobre todo para las categorías de bosques que son espectralmente similares.

**Palabras clave:** Bosque tropical; teledetección, espectrometría; cubierta vegetal; análisis estadístico; Costa Rica.

## SUMMARY

**Distinction of different tropical forest types using satellite images and auxiliary (or supplementary) data.** This paper proposes a data analysis procedure that generates probability estimates from class frequencies modeled with ancillary data and a Mahalanobis Distance threshold of previously classified pixels. Using this approach for the classification of an entire Landsat TM scene of central Costa Rica, it was possible to model the *a priori* class prior probabilities of 33 land cover categories in 537 geographical strata. After modifying the prior probabilities, the overall classification consistency of the training sites improved from 74.6% (traditional equal *a priori* maximum likelihood classification) to 91.9%, while the overall classification accuracy of sites controlled in the field by independent studies improved from 68.7% to 89.0%. The classification accuracy was most improved for the spectrally similar forest categories.

**Keywords:** Tropical forests; teledetection; spectrometry; vegetal cover; statistical analysis; Costa Rica.

Si logramos crear un modelo de la variación espacial de las probabilidades *a priori* de los diferentes tipos de bosque tropical mejoraremos la capacidad de discriminarlos.

Lucio Pedroni

Las diferencias espectrales entre bosques primarios, aprovechados y secundarios son muy sutiles. Por ello, esta investigación buscó un método de clasificación que permita realzar las diferencias entre las categorías mediante datos auxiliares. La hipótesis subyacente del estudio es que relaciones espaciales, entre las categorías de cobertura del suelo y ciertas variables del paisaje, podrían ser descritas cuantitativamente y luego incorporadas en el algoritmo de clasificación.

Se realizó un estudio de caso en la Región Central de Costa Rica y fueron consideradas como variables auxiliares tres características del paisaje: elevación sobre el nivel del mar, acce-

sibilidad y distancia desde la línea costera del Océano Pacífico.

La variable elevación se consideró como un parámetro útil para mejorar la discriminación de categorías que ocurren en rangos específicos de elevación, como los manglares, las plantaciones de café, el páramo y otros cultivos tropicales. Entre estas categorías, contaron también los bosques secundarios, puesto que los patrones de sucesión secundaria varían de acuerdo con la elevación (Finegan 1992 y 1996, Kappelle 1995, Kappelle *et al.* 1996).

La accesibilidad se definió como el tiempo en minutos requerido para alcanzar a pie un punto desde la carretera más cercana. Se supuso que esta variable podía contribuir a mejorar la discriminación de categorías de cobertura del suelo inducidas o establecidas por el ser humano, como cultivos, pastos, bosques secundarios y bosques aprovechados para la producción de madera.

La relación espacial entre las condiciones de acceso, el uso de la tierra y la probabilidad de deforestación ha sido documentada en numerosos estudios. En Costa Rica, por ejemplo, una relación entre deforestación y clima, pendiente, fertilidad del suelo e infraestructura para el acceso ha sido demostrada por Sader y Joyce (1988) y Veldkamp *et al.* (1992). La correlación entre deforestación y atributos del paisaje, especialmente las condiciones de acceso, fueron reportadas también en Brasil (Stone *et al.* 1991, Moran *et al.* 1994), Guatemala (Sader 1995), Guinea (Gilruth *et al.* 1995), Honduras (Ludeke *et al.* 1990), Madagascar (Green y Sussman 1990), México (Dirzo y García 1992), las Filipinas (Kummer y Tuner 1994). Puesto que los bosques secundarios se desarrollan en áreas deforestadas para dar paso a la agricultura o ganadería y luego fueron abandonadas, se esperó encontrar con una relación entre condiciones de acceso y la presencia de bosques secundarios.

Finalmente, en las condiciones específicas de la imagen de satélite estudiada, se observó que ciertas categorías de cobertura del suelo ocurrían

solamente en ciertos rangos de distancia desde la línea costera del Pacífico. Entre éstas, los manglares (solamente cerca de la costa), las plantaciones de palma aceitera (también solamente a pocos kilómetros de la costa), las plantaciones de banano (más frecuentes en la Región Atlántica, y por lo tanto a varios kilómetros de la costa del Pacífico) y los bosques inundados dominados por los yolillos (una palmera, también más frecuente en la zona Atlántica).

Las técnicas más comunes para utilizar datos auxiliares en la clasificación de datos multi-espectrales han sido resumidas por Hutchinson (1982) y Jensen (1996), entre otros. La técnica quizás más sencilla consiste en agregar una capa de datos auxiliares a los espectrales, antes de realizar la clasificación. Sin embargo, este método presenta sus inconvenientes; muchas variables de paisaje tienen distribuciones poco simétricas o hasta multimodales lo que viola el supuesto de normalidad requerido para la clasificación de máxima verosimilitud (Hutchinson 1982, Flack 1995, Jensen 1996). Para evitar este problema, algunos autores han estratificado la imagen antes del análisis espectral y clasificado cada estrato por separado (Franklin y Wilson, 1992), o bien, recodificado las clases espectrales según el estrato, después de la clasificación (Hutchinson 1982, Cibula y Nyquist 1987). Éstas son técnicas sencillas para utilizar datos de variables auxiliares en el proceso de análisis de imágenes digitales. Sin embargo, las prácticas de este tipo tienen la desventaja de generar artefactos (bordes) en la imagen clasificada, consecuencia de su naturaleza demasiado determinística y poco flexible (Maselli *et al.* 1995).

Una técnica que permite incorporar los datos de variables auxiliares en el proceso de clasificación sin requerir supuestos sobre la distribución y que no causa efectos determinísticos indeseables en el resultado es la modificación de las probabilidades *a priori* o clasificación Bayesiana (Swain y Davis 1978, Strahler 1980, Hutchinson 1982, Mather 1985, Maselli *et al.* 1995). Para

entender este método es necesario revisar brevemente la matemática de la clasificación por máxima verosimilitud.

La regla de decisión de máxima verosimilitud se basa en un estimado normal (Gaussiano) de la función de densidad de probabilidad (en inglés: *probability density function*) de cada clase de cobertura del suelo. La función de densidad de probabilidad de un pixel<sup>1</sup>  $x_k$  puede expresarse así (Foody *et al.* 1992):

$$p(x_k | i) = \frac{e^{-1/2(x_k - u_i) V_i^{-1}(x_k - u_i)}}{[(2\pi)^{n/2} |V_i|^{1/2}]}$$

donde:

- $p(x_k | i)$  función de densidad de probabilidad del pixel  $x_k$  como miembro de la clase  $i$
- $n$  número de canales presentes en la imagen
- $x_k$  vector de datos del pixel en todas las bandas
- $u_i$  vector promedio de la clase  $i$  para todos los pixeles, y
- $V_i$  matriz de varianzas y covarianza de la clase  $i$ .

La regla de decisión de máxima verosimilitud asigna el pixel  $x_k$  a la clase por la cual la ecuación resulta en el valor más alto de probabilidad. En la práctica, los algoritmos de clasificación de los programas de procesamiento de imágenes utilizan una forma logarítmica de la regla de decisión por máxima verosimilitud, donde todas las constantes se eliminan. Como demuestra Strahler (1980), después de algunas transformaciones matemáticas, la regla de decisión por máxima verosimilitud puede ser escrita de la manera siguiente:

$$F_{i,k}(x_k) = \ln |V_i| + (x_k - u_i) V_i^{-1}(x_k - u_i)$$

Donde  $F_{i,k}(x_k)$  se conoce como la "función discriminante". El pixel  $x_k$  se clasifica en la categoría donde la función discriminante resulta del valor más bajo.

La regla de decisión Bayesiana es idéntica a la regla de máxima verosimilitud, pero no da por sentado que

<sup>1</sup> Un "pixel" es el elemento más pequeño de una imagen digital. En el caso de una imagen Landsat T corresponde a un área de 28.5 x 28.5 metros.

cada categoría tiene exactamente la misma probabilidad de ocurrir. En casi todas las aplicaciones de percepción remota, algunas categorías de cobertura del suelo ocurren con mayor frecuencia que otras. La regla de decisión de máxima verosimilitud puede ser modificada para tomar en cuenta estas "probabilidades *a priori*" o "pesos" de las categorías. Las probabilidades *a priori* pueden entonces entenderse como la proporción de superficie esperada por cada una de las categorías de cobertura del suelo dentro de un área particular de estudio. La inclusión de las probabilidades *a priori* en la regla de decisión de máxima verosimilitud ocurre por medio de una transformación matemática de la Ley de Probabilidades Condicionales (Strahler 1980). El resultado de dichas transformaciones es la adición del término  $-2\ln P_i$  a la función discriminante:

$$F_{2k}(x_k) = \ln V_i + (x_k - u_i) V_i^{-1}(x_k - u_i) - 2\ln P_i$$

donde:  
 $P_i$  probabilidad *a priori* de la clase  $i$ , y

$F_{2k}(x_k)$  función discriminante que toma en cuenta las probabilidades *a priori*.

De forma gráfica se puede observar que el límite de decisión de la regla de máxima verosimilitud varía cuando se modifican las probabilidades *a priori* (Gráfico 1). Como consecuencia de esta variación se asigna un rango más amplio de valores espectrales (o números digitales) a la clase más frecuente o probable (A) y uno menor a la clase menos probable (B). En el caso extremo, cuando la probabilidad *a priori* de la clase B es cero, todos los píxeles se asignan a la clase A.

Cuando el contexto ecológico o geográfico de un píxel puede expresarse en función de una o más variables auxiliares para las que existen datos digitales, entonces la probabilidad *a priori* de las clases puede ser estimada en función de estas variables auxiliares y por cada píxel individualmente. Por ejemplo, un píxel ubicado cerca de la costa pacífica de Costa Rica, y que en realidad corresponde a un bosque de mangle, puede asignarse una probabilidad *a priori* muy baja para la categoría "páramo subalpino" y una probabilidad *a priori* muy alta para la categoría "bosque de mangle". Lo opuesto ocurriría para un píxel ubicado en una localidad de alta montaña con vegetación de páramo. De esta forma la probabilidad de obtener una clasificación correcta para ambos píxeles es más alta que utilizando el método tradicional de máxima verosimilitud, el cual supondría probabilidades *a priori* iguales por cada categoría en cualquier ubicación.

En la práctica, no es posible estimar probabilidades *a priori* distintas por cada píxel de una imagen; sin embargo, las variables auxiliares pueden ser utilizadas para fragmentar el área de estudio en estratos homogéneos, donde las condiciones ecológicas y geográficas varían tan poco que no sería posible suponer una variabilidad espacial de las probabilidades *a priori* de las clases de interés. Dentro de cada uno de estos estratos, las frecuencias observadas o estimadas de las categorías (por ejemplo, mediante un muestreo estratificado al azar en el terreno) pueden ser utilizadas para estimar las probabilidades *a priori*.

Se ha demostrado que modificando las probabilidades *a priori* en la clasificación de máxima verosimilitud se puede mejorar la precisión de la clasificación de categorías de cobertura espectralmente similares, sin afectar la decisión de clasificación para las clases espectrales cuyo patrón espectral de por sí no se confunden con otros (Mather 1985, Maselli *et al.* 1995). Sin embargo, la necesidad de realizar un muestreo estratificado al azar para obtener estimados de las frecuencias de las clases ha sido un gran inconveniente de este método en la mayoría de las aplicaciones. Sobre todo en ambientes tropicales de gran extensión, donde porciones importantes del territorio pueden tener condiciones prohibitivas de acceso o no estar cubiertos por fotografías aéreas recientes, realizar un muestreo al azar puede resultar muy costoso. Por esta razón, el método de clasificación Bayesiano no ha sido aplicado muy a menudo. En esta investigación se probó un método que permite solucionar el problema del estimado de las probabilidades *a priori* en áreas grandes, complejas y de difícil acceso.

### Materiales y métodos

El ámbito tropical seleccionado es la región central de Costa Rica correspondiente a la paso 15 y fila 53 de Landsat TM (Figura 1).

La región de estudio incluye alrededor de 30 950 km<sup>2</sup> lo que representa una superficie de terreno relativamente "grande" si se compara con otras áreas analizadas en experimentos anteriores de clasificación de bosques secundarios tropicales (Bron-

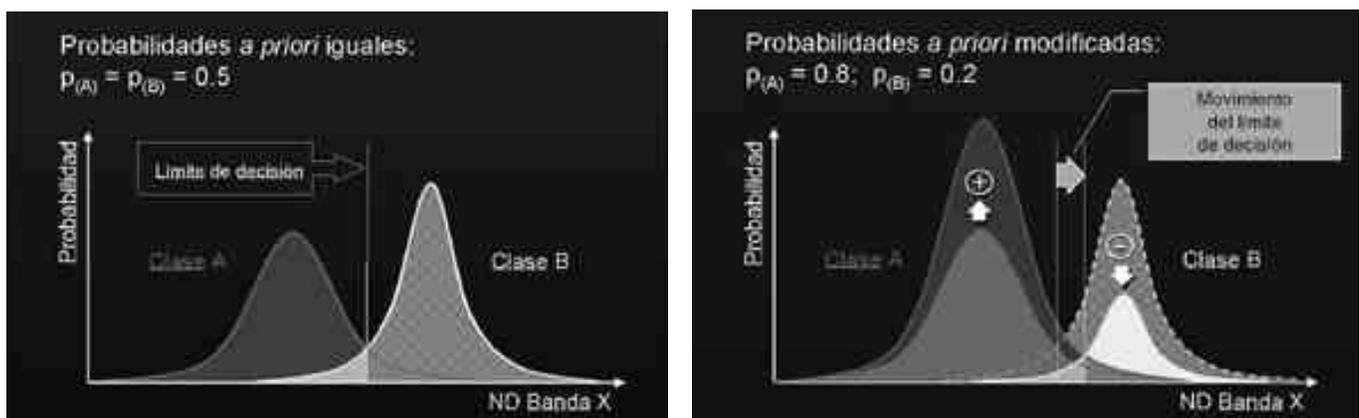
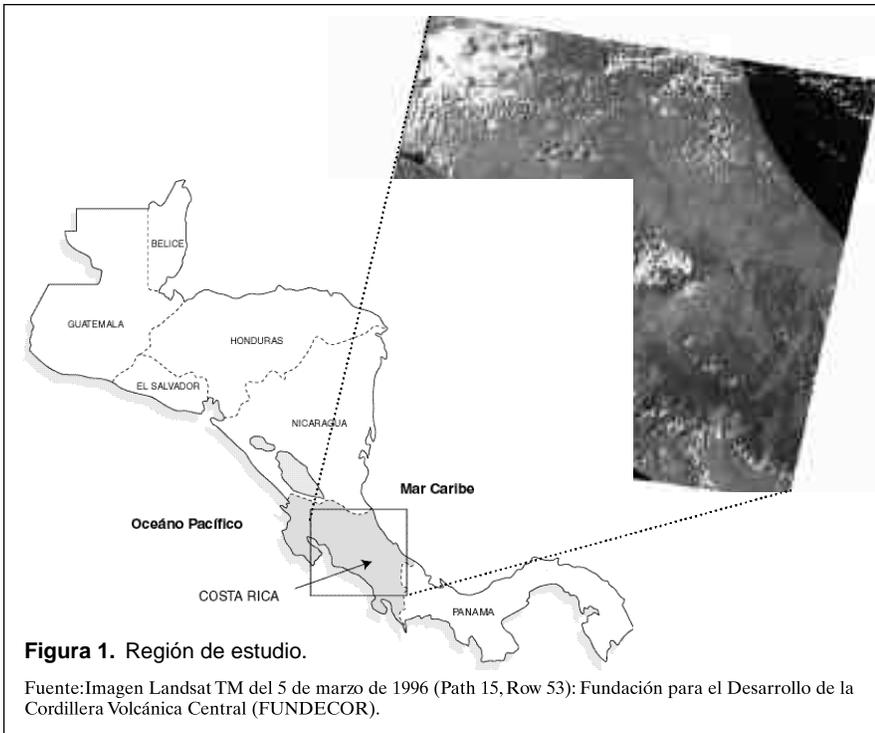


Gráfico 1. Movimientos del límite de decisión de máxima verosimilitud causado por probabilidades *a priori* modificadas.



zio *et al.* 1996, Foody y Curran 1994, Foody *et al.* 1996, Helmer 1999, Li *et al.* 1994, Mausel *et al.* 1993). Cerca de 5 433 km<sup>2</sup> (17,5%) de esta región está cubierta por agua; el resto son tierras con elevaciones entre 0 y 3 825 metros sobre el nivel del mar.

Debido a la presencia de la Cordillera Volcánica Central y la Cordillera de Talamanca y por la influencia de los vientos alisios, las condiciones climáticas son muy variables; sus valores de precipitación anual varían entre 1400 mm año<sup>-1</sup> a más de 7000 mm año<sup>-1</sup> (IMN 1987). En este rango de condiciones climáticas (y de substrato) existen numerosos ecosistemas naturales, 12 zonas de vida y 11 zonas de transición, según el sistema de clasificación de Holdridge *et al.* (1971). Como consecuencia de esta diversidad en condiciones de humedad, vegetación y topografía, los patrones espectrales son particularmente complejos y difíciles de diferenciar. Además, el tamaño relativamente pequeño de la mayoría de las propiedades, la presencia de numerosas fincas de uso múltiple, el alto grado de fragmentación de los bosques, la topografía quebrada y la presencia constante de nubes y neblinas hacen que esta región sea bastante difícil de estudiar con datos Landsat.

Con el fin de trabajar con porciones de imagen correspondientes a condiciones ecológicas y geográficas más homogéneas, se estratificó dicha área utilizando las tres variables auxiliares; elevación sobre el nivel del mar, tiempo de acceso y distancia desde la costa del Océano Pacífico. Para reducir el número de estratos que hubiera resultado de la combinación lineal de las tres variables (256<sup>3</sup> estratos, utilizando datos en 8 bits), la estratificación se efectuó identificando 537 conglomerados de datos con el algoritmo ISODATA del programa ERDAS Imagine 8.3.1.

Determinar la frecuencia de las categorías mediante un muestreo estratificado al azar en el terreno, o con fotografías aéreas hubiera sido difícil de concluir por cada uno de estos 537 estratos. Por lo tanto, se buscó un método alternativo, pero más práctico, basado en el modelaje estadístico de las frecuencias. El primer paso de este método fue realizar una clasificación supervisada de máxima verosimilitud, sin estratificación y sin modificación de las probabilidades *a priori*. Luego, utilizando la Distancia de Mahalanobis (DM), se seleccionaron los píxeles clasificados cuyos valores espectrales eran lo más cercanos a los vectores

promedio de las estadísticas de entrenamiento (o clases espectrales definidas con el método supervisado). La finalidad de este paso era utilizar, más adelante, los píxeles seleccionados como muestra de frecuencia de las categorías en cada estrato. Para la selección de los píxeles se optó por la DM, por ser quizás la mejor medida estadística para determinar la similitud espectral entre un píxel y el promedio de una clase espectral (Foody *et al.* 1992). Matemáticamente, la DM se describe mediante la siguiente fórmula:

$$DM = (x_k - u_i) V_i^{-1} (x_k - u_i),$$

donde:

DM distancia de Mahalanobis entre el píxel  $x_k$  y el promedio de la clase  $i$

$u_i$  vector promedio de la clase  $i$  para todo los píxeles, y

$V_i$  matriz de varianza y covarianza de la clase  $i$  (Foody *et al.* 1992).

Al seleccionar los píxeles con DM más corta, se supuso que un alto grado de similitud espectral entre un píxel clasificado y el promedio de la clase espectral asignada fuera un indicio de alta probabilidad de clasificación correcta. Sin embargo, aunque el umbral para la DM fue definido para un nivel de confianza bastante alto (95%), no era posible dar por sentado que todos los 909 311 píxeles que superaron este criterio de selección habían sido clasificados de forma correcta. En efecto, no podía excluirse la posibilidad que aún entre los píxeles espectralmente idénticos al promedio de las clases espectrales, alguna pequeña proporción de píxeles pudiera estar mal clasificada, puesto que los patrones espectrales de categorías distintas de cobertura del suelo a menudo se traslapan, sobre todo en el caso de los bosques. Por lo tanto, el uso incontrolado de los píxeles seleccionados con la DM, como muestra de frecuencia de las categorías de cobertura del suelo, hubiera sesgado el estimado de las probabilidades *a priori*. Para minimizar esta posibilidad, todos los píxeles seleccionados con la DM fueron sometidos a una prueba de credibilidad. Aquellos cuya asignación de clase no resultaba creíble fueron eliminados, antes de utilizar los remanentes para estimar las frecuencias de las clases

dentro de cada estrato. Para identificar los píxeles que debían eliminarse se determinó, por cada categoría de cobertura del suelo, el rango de valores de elevación, accesibilidad, y distancia desde la costa del Pacífico que se consideró posible para cada una de las clases espectrales. Estos rangos de valores fueron definidos mediante revisión de literatura, entrevistas a expertos locales y la experiencia personal sobre la distribución geográfica de las diferentes categorías de cobertura del suelo en la región de estudio.

El siguiente paso para modelar las frecuencias de las categorías en cada estrato consistió en agregar 0,1 píxeles a las frecuencias de cada grupo que no podía ser excluido de un estrato en particular, de acuerdo con los rangos de valor definido por cada categoría en las tres variables auxiliares. Como ya comprobaron Maselli, Filippis y Romani (1995), esta manipulación de los datos de frecuencia es necesaria para evitar que una categoría de cobertura del suelo sea excluida de un estrato en particular solo por no estar presente en la muestra de frecuencia.

Por último, los píxeles de los sitios de entrenamiento se sumaron a la muestra de frecuencia, lo que originó un cuerpo de 764 636 píxeles. De éstos 14,38% se obtuvieron de los datos de entrenamiento y 85,62% fueron seleccionados con el criterio de la DM y superaron la prueba de credibilidad geográfica. El tamaño de la muestra (764 636 puntos) hubiera sido imposible recolectar mediante las técnicas de muestreo estratificado al azar en el terreno, pero fue suficientemente grande para estimar la frecuencia de 33 categorías de cobertura del suelo en 537 estratos. Como estimado de las probabilidades *a priori* en cada estrato se utilizaron los valores relativos de las frecuencias estimadas.

Finalmente, para realizar la clasificación Bayesiana en los diferentes estratos de la imagen, se prepararon diversas macros en el lenguaje EML y SML de ERDAS Imagine. La función de estos programas era relacionar los estratos geográficos con sus correspondientes estimados de las probabilidades *a priori*. Para clasificar en secuencia cada estrato y luego unir el resultado de todas las clasificaciones se escribió un programa en Visual Basic.

Para comparar los resultados de la clasificación Bayesiana con aquellos obtenidos con la supervisión tradicional se generaron las dos siguientes matrices:

- n Consistencia de la clasificación de los datos de entrenamiento (979 sitios, de los que 826 fueron visitados en el campo y 153 identificados mediante interpretación visual de la imagen)
- n Precisión de la clasificación de datos de control obtenidos de 252 sitios visitados y descritos en el terreno por investigadores independientes (Helmer 1999 y FUNDECOR 1996).

### Resultados

Las probabilidades *a priori* se representan en función de las tres variables utilizadas para estratificar la región de estudio. Para la mayoría de las categorías, la probabilidad de ocurrencia varía entre 0% y 100%, demostrando un patrón muy en contraste con el supuesto implícito de la clasificación tradicional con probabilidades *a priori* iguales, donde cada categoría tiene siempre la misma probabilidad de ocurrir (3,03% en un esquema de clasificación en 33 cate-

gorías), independientemente del valor que suponen las variables del paisaje (Figura 2).

La mayor precisión con la clasificación Bayesiana se muestra en el Cuadro 1. La consistencia total de la clasificación Bayesiana en los 979 sitios de entrenamiento fue, con 91% (Kappa 0,914), 17,3% más alta de la consistencia que se alcanzó con la clasificación con probabilidades *a priori* iguales. La precisión total en los 252 sitios de control fue de 89% y 68,7% respectivamente. Las categorías que mostraron los mayores incrementos en precisión fueron las espectralmente similares de bosque.

Una comparación visual de los resultados de las dos clasificaciones, para dos porciones de la imagen se muestra en la figura 3. La primera porción corresponde a una región nublada sobre el mar Caribe, donde resalta la capacidad de la clasificación Bayesiana de no dejar clasificar categorías que son contextualmente imposibles, como las categorías “áreas urbanas” y “suelo descubierto” que no pueden exis-

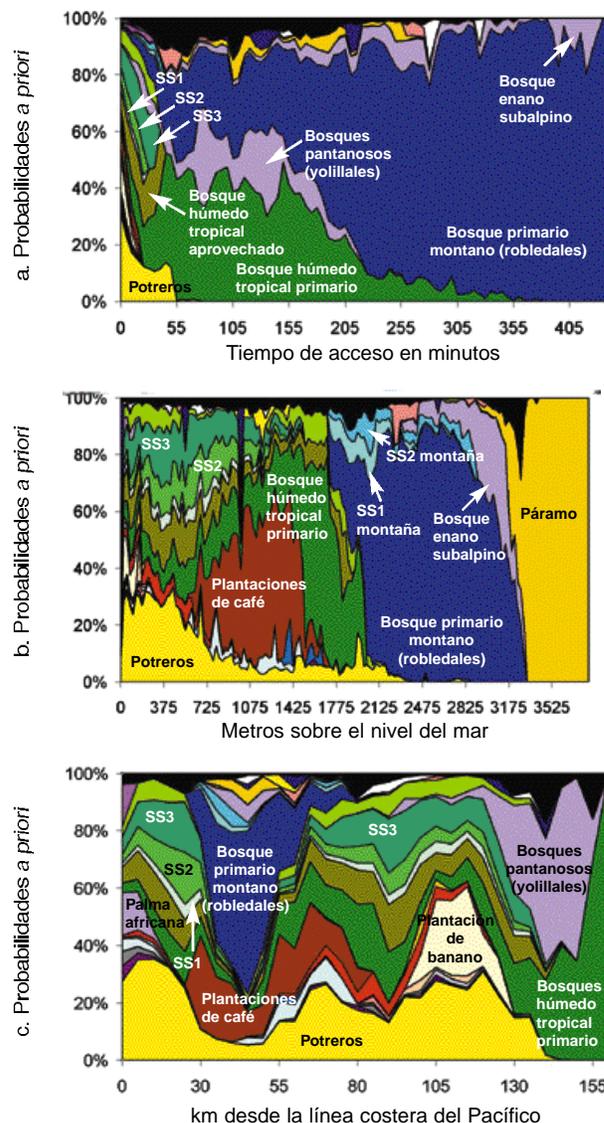


Figura 2. Modelo de probabilidad *a priori* en función de: a. tiempo de acceso. b. elevación sobre el nivel del mar. c. distancia desde la línea costera del océano Pacífico.

tir en el medio del mar. La segunda porción corresponde a una región de la zona atlántica de Costa Rica. Aquí se observa que la clasificación Bayesiana no produce un efecto de “sal y pimienta”<sup>2</sup> tan pronunciado como en la clasificación tradicional.

**Conclusiones**

La discriminación de bosques secundarios y alterados mediante la clasificación de datos Landsat TM ha sido posible en regiones tropicales de bajo relieve y con poca fragmentación de la cubierta forestal (Brondizio *et al.* 1996, Foody y Curran 1994, Foody *et al.* 1996, Li *et al.* 1994, Mausel *et al.* 1993, Moran *et al.* 1994). Los requerimientos para los autores que han obtenido tales éxitos han sido datos de terreno de alta densidad y calidad, y operaciones sobre el algoritmo de clasificación. Sin embargo, en regiones tropicales más complejas no ha sido posible, hasta la fecha, obtener resultados similares. La topografía quebrada, alta diversidad ecológica, fragmentación avanzada en las áreas de bosque e intervención humana permanente son factores que complican los patrones espectrales y reducen la posibilidad de obtener adecuados niveles de discriminación, solo analizando los datos espectrales. En dichas circunstancias, el uso de datos auxiliares para describir las condiciones de sitio y cuantificar las relaciones espaciales entre las diferentes categorías de cobertura del suelo y las condiciones del sitio pueden ser de gran utilidad para mejorar la calidad de la clasificación.

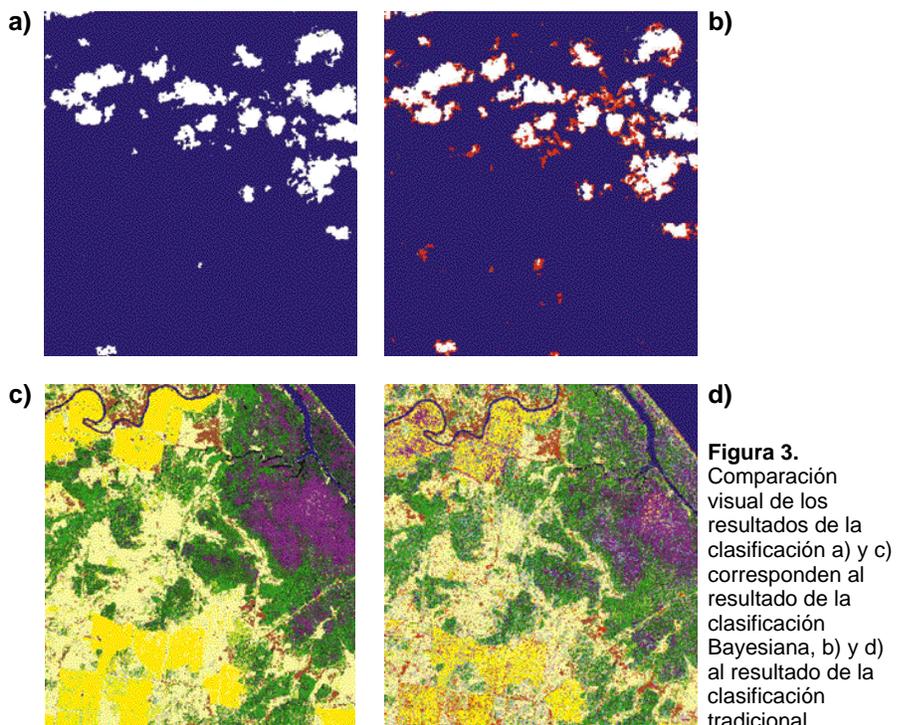
El método de clasificación Bayesiano, utilizado en la presente investigación, produjo una mejor clasificación del método convencional de máxima verosimilitud con probabilidades *a priori* iguales y representa, por tanto, una alternativa de clasificación prometedora para regiones tropicales complejas. La estimación de las probabilidades *a priori* se realizó utilizando una nueva técnica de modelaje en computadora. Esta técnica constituye una alternativa de bajo costo al método tradicional de mues-

<sup>2</sup> Bajo efecto "sal y pimienta" se entiende la presencia de numerosos píxeles individuales mal clasificados. El efecto visual es parecido a que se haya esparcido "sal y pimienta" sobre el mapa de cobertura del suelo producido por la clasificación.

**Cuadro 1.** Porcentaje de consistencia y precisión total de la clasificación

Categoría de cobertura del suelo	Consistencia de la clasificación en los sitios de entrenamiento			Precisión de la clasificación en los sitios de control		
	n	Prob. a priori iguales	Prob. a priori modificadas	n	Prob. a priori iguales	Prob. a priori modificadas
Potreros	27970	90,4	96,9	1763	86,3	95,0
Cultivos anuales	2592	88,8	97,1	0	---	---
Suelo agrícola arado	2997	93,9	99,0	0	---	---
Caña de azúcar	7624	94,2	98,8	482	67,6	82,8
Cultivos de ornamentales	715	70,1	96,6	0	---	---
Cultivos de piña	1033	99,8	100,0	297	98,3	98,3
Viveros bajo cedazo	905	98,3	100,0	236	94,9	95,8
Agricultura mixta	543	25,1	55,9	0	---	---
Plantaciones de bambú	3322	65,9	93,5	0	---	---
Plantaciones de banano	22841	81,9	97,9	355	84,5	96,3
Plantaciones de frutales	4383	61,9	85,8	246	50,8	69,9
Plantaciones de café	4890	77,6	95,4	528	79,9	97,2
Plantaciones de palma africana	3868	69,0	94,5	170	52,4	88,2
Cultivos de palmito	2680	79,6	90,1	0	---	---
Bosque primario	7819	45,4	82,0	1706	34,6	93,8
Bosque primario alterado	8347	27,5	71,6	285	26,7	55,8
SS <sup>(1)</sup> inicial	1694	33,0	66,0	0	---	---
SS <sup>(1)</sup> intermedia	3673	29,8	66,0	0	---	---
SS <sup>(1)</sup> avanzada	7514	31,1	68,6	296	57,8	77,4
Bosques pantanosos	7201	64,2	96,0	352	85,2	97,7
Plantaciones forestales	7108	55,8	87,0	412	40,5	55,6
Bosque primario montano	8109	83,7	99,1	2115	71,6	95,4
SS <sup>(2)</sup> inicial montana	589	55,5	84,7	494	15,8	58,9
SS <sup>(2)</sup> avanzada montana	669	50,8	63,8	618	30,3	73,9
Bosque enano subalpino	267	67,7	67,5	444	11,9	48,2
PS <sup>(3)</sup> en derrumbes montanos	82	89,2	98,8	0	---	---
Manglares	2513	93,0	99,2	490	95,1	95,9
Páramo subalpino	1920	99,1	99,8	1782	86,9	93,0
Suelo descubierto	1821	97,4	99,9	160	70,0	93,8
Áreas urbanas	742	96,6	100,0	160	48,8	84,4
Agua	10426	99,9	100,0	754	99,9	100,0
Nubes	3589	100,0	100,0	963	100,0	100,0
Sombras	4020	99,7	99,9	98	89,8	98,9
Precisión total		74,6	91,9		68,7	89,0
Kappa		0,73	0,91		0,66	0,88

(<sup>1</sup>) Sucesión secundaria en tierras tropicales húmedas de baja elevación según el modelo de sucesión de Finegan (1996)  
 (<sup>2</sup>) Sucesión secundaria en bosques húmedos montanos según el modelo de Kappelle (1995)  
 (<sup>3</sup>) Sucesión primaria (sobre substratos nuevos)



treo estratificado al azar, cuyo costo, especialmente en áreas grandes y de difícil acceso, no permite utilizar el método Bayesiano con probabilidades *a priori* moduladas en función de las variables del paisaje. De esta forma, la presente investigación contribuyó a solucionar dos problemas: la estimación de probabilidades *a priori* en áreas grandes y complejas y el mejoramiento de la discriminación de categorías distintas de bosque tropical. Por otro lado, los métodos utilizados aquí son más exigentes que los tradicionales en cuanto a datos, conocimientos y tiempo de procesamiento.

A pesar de mejorar la precisión en la clasificación, los niveles de discriminación de los bosques secundarios y alterados quedaron por debajo de los

deseables para el levantamiento de mapas de fincas medianas y pequeñas. Sin embargo, al contrario del resultado obtenido con la clasificación tradicional, se obtuvo una clasificación donde no aparecían píxeles asignados a categorías de cobertura del suelo poco creíbles de acuerdo con su contexto de paisaje. Por esto, dentro de estratos mayores, como zonas de vida, los estimados de área de las diferentes categorías de cobertura del suelo, obtenidos con la clasificación Bayesiana tienen mayores posibilidades de aproximar los valores reales.

Los métodos utilizados en esta investigación pueden ser recomendados para aplicaciones regionales, como el modelaje de carbono en áreas grandes y aplicaciones en biogeografía desti-

nadas a planificar la conservación y uso sostenible de los ecosistemas. 

**Agradecimientos:** Esta investigación fue financiada por la Organización Suiza para el Desarrollo y la Cooperación y el Centro Agronómico Tropical de Investigación y Enseñanza. El autor agradece a la Fundación para el Desarrollo de la Cordillera Volcánica Central (FUNDECOR) por la imagen Landsat TM, y al Instituto Geográfico Nacional de Costa Rica y al Departamento de Geografía de la Universidad de Costa Rica por los datos cartográficos digitales. Un reconocimiento especial al señor Martín Artavia y al Ing. Geoffrey Venegas por su valiosa contribución en el trabajo de campo.

Lucio Pedroni

Doctor. en Ingeniería Forestal

CATIE 7170 Turrialba, Costa Rica.

Tel: (506) 556 15 30

lpedroni@catie.ac.cr

### Literatura citada

- Brondizio, E.; Moran, E.; Mauseel, W.; Wu, Y. 1996. Land cover in the Amazon estuary: linking of Thematic Mapper with botanical and historical data. *Photogrammetric Engineering and Remote Sensing* 62:921-929.
- Cibula, W.G.; Nyquist, M.O. 1987. Use of topographic and climatological models in a geographical database to improve Landsat MSS classification for Olympic National Park. *Photogrammetric Engineering and Remote Sensing* 54:587-592.
- Dirzo, R.; García, M.C. 1992. Rates of deforestation in Los Tuxtlas, a neotropical area in southeast Mexico. *Conservation Biology* 6:84-90.
- Finegan, B. 1992. El potencial de manejo de los bosques húmedos secundarios neotropicales de las tierras bajas. Turrialba, Costa Rica, CATIE. 29 p.
- Finegan, B. 1996. Pattern and process in neotropical secondary rain forests: the first 100 years of succession. *Tree* 11:119-124.
- Finegan, B.; Palacios, W.; Zamora, N.; Delgado, D. 2000. Ecosystem-level forest biodiversity and sustainability assessments for forest management. In Raison, J.; Flinn, D. eds. *Indicators for Sustainable Forest Management*. Wallingford, UK, CABI/ITFRO.
- Flack, J. 1995. Interpretation of Remotely Sensed Data Using Guided Techniques (en línea). Western Australia. Consultado 2 feb. 2000. Disponible en <http://www.per.dem.csiro.au/staff/FlackJulien/thesis/node2.html>
- Foody, G.M.; Campbell, N.A.; Trodd, N.M.; Wood, T.F. 1992. Derivation and applications of probabilistic measures of class membership from the maximum-likelihood classification. *Photogrammetric Engineering and Remote Sensing* 58:1335-1341.
- Foody, G.M.; Curran, P.J. 1994. Estimation of tropical forest extent and regenerative state using remotely sensed data. *Journal of Biogeography* 21:223-244.
- Foody, G.M.; Palubinskas, G.; Lucas, R.M.; Curran, P.J.; Honzak, M. 1996. Identifying terrestrial carbon sinks: classification of successional stages in regenerating tropical forest from Landsat TM data. *Remote Sensing of Environment* 55:205-216.
- Franklin, S.E.; Wilson, B.W. 1992. A three-stage classifier for remote sensing of mountain environments. *Photogrammetric Engineering and Remote Sensing* 58:449-454.
- FUNDECOR (Foundation for the Development of the Central Volcanic Mountain Range). 1996. Field verified information and GPS coordinates of land cover.
- Gilruth, P.T.; Marsh, S.E.; Itami, R. 1995. A dynamic spatial model of shifting cultivation in the highlands of Guinea, West Africa. *Ecological Modelling* 70:179-197.
- Green, G.M.; Sussman, R. 1990. Deforestation history of the eastern rainforests of Madagascar from satellite images. *Science* 248:212-215.
- Helmer, E.H. 1999. The Landscape Ecology of Secondary Tropical Forest in Montane Costa Rica. PhD Dissertation. Oregon, Oregon State University.
- Holdridge, L.R.; Grenke, W.C.; Hatheway, W.H.; Lang, T.; Tosi, J.A.J. 1971. *Forest Environments in Tropical Life Zones: a Pilot Study*. Oxford, Pergamon Press.
- Hutchinson, C.F. 1982. Techniques for combining Landsat and ancillary data for digital classification improvement. *Photogrammetric Engineering and Remote Sensing* 48:123-130.
- IMN (Instituto Meteorológico Nacional). 1987. Atlas climatológico de Costa Rica. San José, Costa Rica.
- Jensen, J.R. 1996. *Introductory Digital Image Processing: A Remote Sensing Perspective*. 2 ed. New Jersey, Prentice Hall.
- Kappelle, M. 1995. Ecology of Mature and Recovering Talamancan Montane *Quercus* Forests, Costa Rica. Ph.D. Dissertation, Amsterdam, University of Amsterdam/National University of Costa Rica.
- Kappelle, M.; Geuze, T.; Leal, M.E.; Cleef, A.M. 1996. Successional age and forest structure in a Costa Rican upper montane *Quercus* forest. *Journal of Tropical Ecology* 12:681-698.
- Kummer, D.M.; Turner, B. L. 1994. The human causes of deforestation in southeast Asia. *BioScience* 44:323-328.
- Li, Y.; Moran, E.F.; Brondizio, E.S.; Mauseel, P.; Wu, Y. 1994. Discrimination between advanced secondary succession and mature moist forest near Altamira, Brazil using Landsat TM data. Proceedings of the American Society for Photogrammetry and Remote Sensing. Annual meeting. Reno, NV. p. 350-364.
- Ludeke, A.K.; Maggio, R.C.; Reid, L.M. 1990. An analysis of anthropogenic deforestation using logistic regression and GIS. *Journal of Environmental Management* 31:247-257.
- Maselli, F.; Conese, C.; De Filippis, T.; Romani, R. 1995. Integration of ancillary data into a maximum-likelihood classifier with nonparametric priors. *Journal of Photogrammetry and Remote Sensing* 50:2-11.
- Mather, P.M. 1985. A computationally-efficient maximum-likelihood classifier employing prior probabilities for remotely-sensed data. *International Journal of Remote Sensing* 6:369-376.
- Mauseel, P.; Wu, Y.; Li, Y.; Moran, E.; Brondizio, E.S. 1993. Spectral identification of successional stages following deforestation in the Amazon. *Geocarto International* 4:61-71.
- Moran, E.F.; Brondizio, E.S.; Mauseel, P.; Wu, Y. 1994. Integrating Amazonian vegetation, land-use, and satellite data. *BioScience* 44:329-338.
- Sader, S. A. 1995. Spatial characteristics of forest clearing and vegetation regrowth as detected by Landsat Thematic Mapper imagery. *Photogrammetric Engineering and Remote Sensing* 61:1145-1151.
- Sader, S.A.; Joyce, A.T. 1988. Deforestation rates and trends in Costa Rica: 1940-1983. *Biotropica* 20:11-19.
- Stone, T.A.; Brown, I.F.; Woodwell, G.M. 1991. Estimation by remote sensing, of deforestation in central Rondonia, Brazil. *Forest Ecology and Management* 38:291-304.
- Strahler, A.H. 1980. The use of prior probabilities in maximum likelihood classification of remotely sensed data. *Remote Sensing of Environment* 10:135-163.
- Swain, P.H.; Davis, S.M. 1978. *Remote Sensing: The Quantitative Approach*, New York, McGraw-Hill.
- Veldkamp, E.; Weitz, A.M.; Staritsky, I.G.; Huisung, E.J. 1992. Deforestation trends in the Atlantic zone of Costa Rica: a case study. *Land Degradation and Rehabilitation* 3:71-84.