



**UNIVERSIDAD MICHOACANA
DE SAN NICOLÁS DE HIDALGO**



**DIVISIÓN DE ESTUDIOS DE POSGRADO
FACULTAD DE BIOLOGÍA**

**EVALUACIÓN DE TRES CLASIFICADORES DIFUSOS
EN EL ANÁLISIS DE IMÁGENES SATELITALES DE
BAJA RESOLUCIÓN (SPOT VEGETATION)**

TESIS

Que como requisito parcial para optar por el grado de

MAESTRO EN CIENCIAS

En Conservación y Manejo de Recursos Naturales, presenta

BIOL. TZITZIKI JANIK GARCÍA MORA

Director de Tesis: DR JEAN FRANÇOIS MAS CAUSSEL

Asesor Interno: M.C. J. MANUEL ORTEGA RODRÍGUEZ

Morelia, Michoacán

Junio de 2006

*D*edicatoria

A mí hijo Eduardo Kaleb. Por tí cada día quiero ser una mejor persona, te amo más que a nada en este mundo y espero que Dios me dé la dicha de verte llegar mucho más lejos que yo.

AGRADECIMIENTOS

A mi casa de estudios la Universidad Michoacana de San Nicolás de Hidalgo, en cuyas aulas me he formado, que otorgó la beca de maestría con recursos propios, y a la cuál espero regresar en un futuro próximo para aportar algo de lo mucho que me ha dado.

A los catedráticos del programa de Maestría en Conservación y Manejo de Recursos Naturales. De manera muy especial y en reconocimiento por su dedicación en la formación de calidad de los alumnos de maestría, al Dr. Javier Ponce Saavedra y al Dr. Tiberio Monterrubio, a quienes también agradezco su amistad y sus constantes palabras de aliento.

A los distinguidos miembros sinodales de la mesa tutorial, Dr. Eduardo Antaramián, Dra. María Luisa España Boquera y M.C. Alfredo Amador por sus oportunas y acertadas opiniones vertidas en este estudio.

Al Instituto de Geografía de la Universidad Nacional Autónoma de México con sede en Morelia donde fue desarrollado en su totalidad el presente trabajo.

A mi asesor de tesis Dr. Jean François Mas, por la confianza depositada en mí para desarrollar este trabajo, por su gran ejemplo de trabajo y dedicación, así como su disposición para atender en tiempo y forma a todas las dudas e inquietudes que surgieron durante estos dos años.

Al M.C. Juan Manuel Ortega, asesor interno por su disposición a apoyar y fortalecer este estudio, quién además, fue mi primer contacto en el conocimiento de la Percepción Remota y los Sistemas de Información geográfica.

Al equipo de trabajo del IG UNAM, M.C. Azucena Pérez-Vega, M.C. Aurore Bury, Geog. Ignacio Gonzáles, M. C. José Reyes Díaz, M.C. Faustino López, M.C. Ian Gao M.C. Alejandra Larrazábal, por el apoyo brindado en la elaboración de esta tesis y mi formación profesional, por sus consejos y por hacer del lugar de trabajo un espacio ideal para el aprendizaje así como por su invaluable amistad. De manera especial al Biol. Camilo Alcántara, quien siguió muy de cerca este proyecto desde sus inicios, apoyándome completamente aún en la distancia, tanto en lo profesional como en lo personal.

A mis compañeras y amigas del programa de maestría, Consuelo Marín y Fis. Daniela Pinheiro Bitencurti a quienes quiero, respeto y admiro profundamente.

A la administración de posgrado de la UMSNH a cargo del Dr. Javier Ponce Saavedra y Dr. Ricardo Pérez Murguía, quienes a poco tiempo de ocupar este puesto han logrado grandes avances en pro del programa.

Al Fondo Mixto de Fomento a la Investigación Científica y Tecnológica CONACYT – Gobierno del estado de Quintana Roo, por el apoyo financiero al proyecto Clave QROO-2003-C02-13228 del cuál se derivó este estudio, por las facilidades prestadas para el material y equipo de trabajo, así como por la beca recibida durante un año.

Al programa de Monitoreo Global de la Vegetación del Centro de Investigación de la Comunidad Europea por los datos VEGETATION aportados para el desarrollo del presente trabajo de tesis

Finalmente quiero agradecer a las personas más importantes en mi vida, a mi familia, sin ustedes esta meta hubiera sido muy difícil de cumplir. Gracias Mamá por ser también la madre de mi hijo en mis ausencias, eres una gran mujer, ejemplo de fortaleza integridad y amor incondicional. Gracias Papá por no perder jamás la fe en mí, por impulsarme siempre. A mis hermanos, Erick y Leonardo, por su interés y apoyo en mis proyectos, y sobretodo, gracias hijo mío por llegar a llenar mi vida de luz y esperanza.

**C. DR. JAVIER PONCE SAAVEDRA,
JEFE DE LA DIVISION DE ESTUDIOS DE POSGRADO
DE LA FACULTAD DE BIOLOGIA, UMSNH
P R E S E N T E**

Por este conducto nos permitimos comunicarle que después de haber revisado el manuscrito final de la Tesis de Grado titulada "EVALUACION DE TRES CLASIFICADORES DIFUSOS EN EL ANALISIS DE IMÁGENES DE BAJA RESOLUCION (*Spot vegetación*)", Presentado por la Biol. Tzitziki Janik García Mora, estudiante del programa de **Maestría en Conservación y Manejo de Recursos Naturales**, consideramos que reúne los requisitos suficientes para ser publicada y defendida en Examen Profesional de Grado.

Agradecemos de antemano su atención y reiteramos a Usted nuestra más alta y distinguida estima.

ATENTAMENTE

Morelia, Mich., a 27 de marzo de 2006

MIEMBROS DE LA COMISION REVISORA



**DR. JEAN FRANCOIS MAS CAUSSEL
DIRECTOR DE TESIS**



**DR. EDUARDO ANTARAMIAN
HARUTUNIAN
PRESIDENTE**



**DRA. MARIA LUISA ESPAÑA
BOQUERA
SECRETARIA**



**M.C. JUAN MANUEL ORTEGA
RODRIGUEZ
VOCAL**



**M. C. ALFREDO AMADOR GARCIA
VOCAL**

INDICE

i.	RESUMEN.....	vi
ii.	ABSTRACT	vii
I.	INTRODUCCIÓN	1
	1.1. JUSTIFICACIÓN	3
	1.2 HIPÓTESIS.....	3
II.	MARCO TEÓRICO.....	4
	2.1 CONCEPTOS GENERALES.....	4
	2.2 CLASIFICACIÓN DIFUSA.....	8
	2.2.1 Clasificadores difusos.....	8
	A Clasificador basado en la distancia	8
	B Clasificador basado en el teorema de Bayes.....	10
	C Clasificador basado en la teoría de Dempster Shapher	13
III.	ANTECEDENTES	15
	3.1 APLICACIONES DE LA PERCEPCIÓN REMOTA Y SIG	15
	3.2 USO DE IMÁGENES DE BAJA RESOLUCIÓN.....	16
	3.3 MÉTODOS DE DESMEZCLA DE PÍXELES.....	18
	3.3.1 El modelo lineal de mezcla	18
	3.3.2 Métodos difusos.....	19
	A Redes neuronales.....	19
	B Métodos difusos paramétricos	21
	3.3.3 Estudios comparativos.....	22
	3.3.4 Conclusiones.....	23
III.	OBJETIVOS.....	25
	3.1 OBJETIVO GENERAL.....	25
	3.2 OBJETIVOS PARTICULARES.....	25
IV.	DESCRIPCIÓN DEL ÁREA.....	26
	4.1 CARACTERIZACIÓN GEOGRÁFICA	26
	4.2 OROGRAFÍA	27
	4.3 HIDROGRAFÍA	27
	4.4 CLIMA.....	27
	4.5 PRINCIPALES ECOSISTEMAS	27
	4.6 FAUNA.....	29
	4.7 ÁREAS NATURALES PROTEGIDAS	30
	4.8 MANEJO COMUNITARIO.....	31
V.	MATERIALES Y MÉTODOS.....	33
	5.1. MATERIALES.....	33
	5.1.1 Productos ETM.....	33
	5.1.2 Productos SPOT Vegetation (VGT).....	34

5.1.3 Fotografías aéreas	36
5.2 METODOLOGÍA.....	36
5.2.1. Corrección geométrica.....	38
5.2.2. Sistema clasificatorio.....	38
5.2.3. Campos de entrenamiento.	41
5.2.4. Análisis de separabilidad de firmas espectrales.....	42
5.2.5. Clasificación de la imagen de referencia	44
5.2.6. Evaluación de la fiabilidad en la imagen de referencia (Landsat ETM)	45
5.2.7 Clasificación de la imagen SPOT VGT.....	48
5.2.8 EVALUACIÓN Y COMPARACIÓN DE LOS CLASIFICADORES DIFUSOS.....	49
A. Cálculo del error medio cuadrático (RMS error)	50
B. Cálculo del error medio absoluto (MAE).....	51
C. Distribución espacial del error.....	52
D. Cálculo del coeficiente de correlación.....	52
VI. RESULTADOS Y DISCUSIÓN.....	53
6 1. CORRECCIÓN GEOMÉTRICA.....	53
6.2 CAMPOS DE ENTRENAMIENTO.....	53
6.3 ANÁLISIS DE SEPARABILIDAD DE FIRMAS	55
6.3.1. Resultados para la imagen SPOT VGT	55
6.3.2 Resultados para la imagen Landsat ETM+.....	56
6.4 CLASIFICACIÓN Y EVALUACIÓN DE LA IMAGEN DE REFERENCIA.....	60
6.5 CLASIFICACIÓN Y EVALUACION DE LA FIABILIDAD DE LA IMAGEN SPOT VGT ..	64
6.6 CLASIFICACION DIFUSA.....	66
6.7 EVALUACIÓN Y COMPARACIÓN DE LOS CLASIFICADORES DIFUSOS.....	71
6.7.1 Cálculo del error medio cuadrático	71
6.7.2 Cálculo del Error medio Absoluto.....	73
6.7.3 Distribución espacial del error.....	74
6.7.3 Cálculo del coeficiente de correlación.....	78
6.8 IMÁGENES CLASIFICADAS CON ALGORIMOS DIFUSOS Y DATOS AUXILIARES.....	82
VII. CONCLUSIONES.....	86
VI. BIBLIOGRAFIA.	88
VII. ANEXOS.	93
7.1 PROPORCIONES OBTENIDAS DE LAS DIFERENTES CATEGORÍAS MEDIANTE EL USO DE CLASIFICADORES DIFUSOS Y DATOS AUXILIARES	93
7.2 DISTRIBUCIÓN ESPACIAL DEL ERROR DE LOS MAPAS DIFUSOS CON DATOS AUXILIARES.....	98
7.3 GRÁFICAS DE DISPERSIÓN, DE LAS PROPORCIONES DE CADA PÍXEL (EJE Y) EN FUNCIÓN DE SU VALOR FUZZY (EJE X).....	101
7.4. RESULTADOS DE ERROR Y CORRELACIÓN OBTENIDOS A PARTIR DE DE LOS DATOS OBTENIDOS MEDIANTE LA CLASIFICACIÓN DIFUSA CON DATOS AUXILIARES.....	103

ÍNDICE DE CUADROS Y FIGURAS

Fig.1 Tres aproximaciones básicas para el procesamiento de datos.....	5
Fig.2 Representación de un píxel a clasificar y sus respectivas distancias hacia tres coberturas tomando en cuenta su valor en dos bandas.....	9
Fig.3 Esquema del fundamento de la clasificación de máxima similitud.....	10
Fig. 4 Área de estudio ubicada en el estado de Quintana Roo.....	26
Fig. 5. Porcentajes de las coberturas presentes en el área de estudio.....	29
Fig. 6 Imagen Original del sensor SPOT VGT.....	35
Fig.7 Esquema metodológico general	37
Fig. 8 Puntos de control utilizados en la validación.....	46
Fig.9. Comparación de la proporción (T_i) contra el valor difuso correspondiente (X_i).....	49
Fig.10 Separabilidad (Divergencia Transformada) de las firmas de los campos de entrenamiento del mapa de referencia de acuerdo al número de bandas utilizadas.....	56
Fig.11 Comparación de firmas de selva mediana subperennifolia Vs. Agropecuario.....	57
Fig. 12. Comparación de firmas de agropecuario Vs. selva mediana subcaducifolia.....	58
Fig.13 Comparación de firmas de agropecuario Vs. vegetación hidrófila.....	58
Fig. 14 Comparación de firmas de selva mediana subperennifolia Vs. selva mediana subcaducifolia.....	59
Fig. 15 Clasificación de la imagen de referencia (Landsat ETM) con valores a priori.....	60
Fig. 16. Imagen SPOT VGT clasificada mediante el método de máxima verosimilitud.....	64
Fig. 17 Valores difusos de la categoría vegetación hidrófila	68
Fig. 18 Valores difusos de la categoría selva mediana subperennifolia.....	69
Fig. 19 Valores difusos de la categoría selva mediana subcaducifolia	70
Fig.20 Distribución del error en la estimación de la proporción de la categoría agropecuario.....	74
Fig. 21 Distribución del error en la estimación de la proporción de la categoría vegetación hidrófila...75	

Fig. 22 Distribución del error en la estimación de la proporción de la categoría selva mediana subcaducifolia.....	76
Fig. 23 Distribución del error en la estimación de la proporción de la categoría selva mediana subperennifolia.....	77
Fig. 24 Gráficas de correlación entre los valores difusos (X) y sus respectivas proporciones (Y).....	80
Fig. 25 Comparación de la grafica de correlación con la grafica de concordancia basada en el método propuesto por Bland (1986).....	85
Cuadro 1 Síntesis de algunos trabajos de desmezcla publicados en la literatura	24
Cuadro 2 Superficie ocupada por cada una de las coberturas del suelo presentes en el área de estudio delimitada por la imagen ETM de acuerdo al IFN 2000	28
Cuadro 3 Características de las bandas del sensor ETM+.....	33
Cuadro 4 Definición cualitativa propuesta para la interpretación de los valores de separabilidad.....	44
Cuadro 5 Matriz de error entre campos de entrenamiento e imagen clasificada.....	54
Cuadro 6 Coeficientes de separabilidad promedio de firmas de la imagen SPOT V GT.....	55
Cuadro 7 Valores de separabilidad de las bandas de la imagen de referencia.....	56
Cuadro 8. Matriz “dura” de fiabilidad de la imagen Landsat ETM	61
Cuadro 9 Porcentaje por clase en el área de estudio.....	61
Cuadro 10 Matriz “dura” de fiabilidad de la imagen Landsat ETM aplicando el método de ponderación de Card (1982).....	62
Cuadro 11 Matriz “difusa” de fiabilidad de la imagen Landsat ETM aplicando el método de ponderación de Card (1982).....	62
Cuadro 12 Matriz “difusa” de fiabilidad con correcciones de Card (1982).....	63
Cuadro 13 Matriz de fiabilidad de la clasificación de máxima verosimilitud del producto SPOT VGT.....	65
Cuadro 14 Error obtenido para cada categoría en cada uno de los clasificadores evaluados.....	71
Cuadro 15 Error medio absoluto obtenido para cada categoría en cada uno de los clasificadores evaluados.....	73
Cuadro 16 Coeficiente de correlación obtenidos para cada categoría en cada uno de los clasificadores evaluados.....	78

Cuadro 17 Reducción del error medio cuadrático aplicando las probabilidades a priori.....	82
Cuadro 18 Reducción del error medio absoluto aplicando las probabilidades a priori	82
Cuadro 19 Aumento de la correlación de mediante el uso de datos auxiliares	83

i. RESUMEN

A nivel nacional y mundial es necesario diseñar políticas de gestión y conservación que cuenten con datos actualizados sobre la distribución y dinámica de los recursos forestales. Una herramienta valiosa para generar este tipo de datos es la percepción remota a través de la clasificación de imágenes de satélite. Las imágenes SPOT VGT representan una buena alternativa: son gratuitas, se caracterizan por una alta resolución temporal y son de rápido procesamiento al cubrir todo el país con una sola imagen. Es posible utilizar estas imágenes bajo técnicas de procesamiento que permitan extraer la información sobre las categorías que existen dentro de un píxel que cubre un kilómetro cuadrado en el terreno. Una de estas técnicas de procesamiento son los clasificadores difusos, que han demostrado ser útiles para la clasificación sub-píxel, a través de la estimación de la proporción de las diferentes coberturas del suelo que entran en la composición de un píxel.

En este trabajo se probaron tres clasificadores difusos en cinco categorías. Estos clasificadores están basados en: a) El teorema de Bayes, b) La teoría de Dempster Shapher, y c) La distancia espectral. Las proporciones obtenidas para cada una de las 5 categorías a discriminar fueron comparadas con las de una imagen de mejor resolución (Landsat ETM +) del mismo día, clasificada por medio del algoritmo de máxima similitud y con datos auxiliares en forma de imágenes de probabilidad a priori. La validación de los datos se llevó a cabo mediante el cálculo del error medio cuadrático y de la correlación entre valores difusos y proporciones.

Los resultados son similares a los obtenidos anteriormente en estudios publicados en la literatura y considerados como satisfactorios, sin embargo al observar de gráficamente la distribución de los datos vemos que no hay concordancia por lo que no podemos inferir las proporciones a partir de los valores difusos. Es importante contar con un buen estimador del desempeño de los clasificadores ya que diferentes métodos de evaluación muestran resultados contradictorios, lo cual puede llevar a la subestimación del error. Como alternativa se propone el uso del coeficiente de concordancia propuesto por Bland et al (1986) en lugar del cálculo de correlación ya que en otros campos de la ciencia ha mostrado ser un método más robusto en la comparación de dos variables continuas.

ii. ABSTRACT

Worldwide the design of gestion and politics needs to be based upon updated information concerning forest resources distribution dynamics. Remote Sensing has been proved to be an important tool to produce such data. SPOT VEGETATION imagery is a good alternative to be used with subpixel classification methodologies; these images are free, have a high temporal resolution and can be processed rapidly. Soft classifiers have been used in many studies to unmix a pixel by estimating fuzzy membership. This has been shown to be cost effective and very promising.

This study evaluates three soft classifiers, the first one based on Bayesian theory, the second based on Dempster Shapher theory and the last one on the spectral distance. A land cover map derived from a Landsat ETM image of the same day and classified using a conventional method and ancillary data was adopted as source of fine scale validation data. The validation was carried out using the RMS error and correlation coefficients calculation.

The results are similar to those from previously published studies and seem to provide satisfactory classification. Nevertheless, the data behavior graphically, contradicts the apparent good performance of the algorithms by showing no concordance between the fuzzy values and the true land cover proportions. It is very important to count with a reliable evaluation of classifiers, because each one of them shows distinct results and seems to under estimate the real error.

This study proposes as a better alternative the use of concordance coefficient proposed by Bland et al (1986) instead of the correlation coefficient, thus other science branches have found it produce more robust results.

I. INTRODUCCIÓN

Gracias al desarrollo de la tecnología, hoy en día es posible llevar a cabo el monitoreo remoto de la cobertura terrestre a través de imágenes de satélite. Esto representa una gran ventaja sobretodo en casos donde se requiere hacer estudios en áreas extensas, de difícil acceso, o bien en periodos de tiempo cortos (Chuvieco 2002).

Debido a su importancia y potencial de aplicación, han surgido una gran variedad de sensores con diferentes enfoques. A grosso modo podemos decir que existen dos tendencias en la evolución de los sensores multiespectrales; por un lado los que se han enfocado en mejorar la resolución espacial, como Landsat, SPOT, Ikonos o Quick bird, aunque con una resolución temporal baja, y por otro los satélites con alta resolución temporal y resolución espacial baja, como MODIS, NOAA - AVHRR, y SPOT VEGETATION.

Las imágenes de baja resolución espacial surgieron con la finalidad de estudiar fenómenos multitemporales. A partir de los años 80's se comenzaron a utilizar para la clasificación de la vegetación en áreas extensas, por la gran superficie que abarca una sola imagen y su bajo costo (Cihlar 2000)

Un píxel en la imagen integra la respuesta del área completa con todos los objetos cubiertos por el campo instantáneo de vista (IFOV por sus siglas en inglés) del sensor. El problema de usar imágenes de baja resolución espacial es que un píxel representa una extensión grande, donde el tamaño de la mayoría de los objetos en el suelo es menor que el área que cubre un píxel en la imagen (Thakkar 2004).

Los sensores SPOT VGT, tienen una resolución espacial de 1000 metros, por lo que en general es muy difícil encontrar unidades homogéneas en el píxel por el contrario, las imágenes a estas amplias resoluciones contienen píxeles mezclados. Estos se definen como aquellos que cubren más de un objeto en el suelo.

En el caso de una clasificación tradicional, donde un píxel se asigna a una sola categoría, la información contenida dentro de dicho píxel se generaliza, efecto que se acumula con cada uno de los píxeles de la imagen. La toma de decisiones con base en estos resultados es muy riesgosa. Por esta razón se han desarrollado y probado otro tipo de metodologías, que intentan extraer la información que existe dentro de cada píxel en una imagen, que se conocen como clasificaciones subpíxel o desmezcla (“unmixing” en la literatura en inglés). La clasificación a nivel subpíxel es el proceso de ir “detrás” de lo que se encuentra visible de manera inmediata en la imagen

Para el análisis de éste tipo de imágenes pueden aplicarse clasificadores difusos, los cuales asignan a un píxel varias clases de cobertura presentes en la imagen y sus respectivas probabilidades representativas, bajo el supuesto de que la probabilidad puede interpretarse como un valor de pertenencia.

En este trabajo de tesis se probarán tres tipos de clasificadores difusos en una zona del sureste mexicano, en el centro del Estado de Quintana Roo.

La aplicación y análisis de métodos difusos es un campo relativamente nuevo, y poco difundido en nuestro país, aún más en imágenes de baja resolución, lo cuál resalta la importancia de este trabajo.

1.1 JUSTIFICACIÓN.

A nivel mundial existe una gran necesidad de conocer la distribución espacial de los recursos naturales. En el ámbito de la conservación se ha probado que las estrategias deben estar encaminadas a la conservación de hábitats y no de individuos. En nuestro país esto es de suma importancia debido a la gran biodiversidad que se encuentra presente.

La falta de datos actualizados sobre la distribución de las coberturas del suelo se debe, en gran parte, a que el trabajo de campo es tardado y costoso, y las imágenes de satélite más apropiadas para este fin son caras y se requiere un gran número de estas para cubrir el país. Por ejemplo, para cubrir la nación se necesitan más de 120 imágenes Landsat o 600 imágenes SPOT. Para evitar este problema se han utilizado imágenes más económicas o gratuitas aunque de menor resolución espacial como las AVHRR.

Ante el éxito de AVHRR, se desarrollaron otros sensores con características similares (baja resolución espacial y alta resolución temporal) pero diseñados especialmente con el fin de monitorear las coberturas del suelo. Entre estos sensores destaca SPOT-VEGETATION.

Sin embargo, la baja resolución espacial puede ser tratada con métodos difusos para extraer la información contenida dentro del píxel, con lo que este problema puede reducirse y obtener buenos resultados.

1.2 HIPÓTESIS

El uso de un enfoque difuso en la clasificación de imágenes de baja resolución (SPOT VGT), es útil para obtener, las proporciones de las coberturas dentro de un píxel, mejorando significativamente los resultados obtenidos, en comparación con una clasificación convencional.

II. MARCO TEORICO

2.1 CONCEPTOS GENERALES.

El análisis de la cobertura terrestre es un tema de suma importancia en los ámbitos gubernamental, académico y social para poder evaluar, planear y monitorear el estado de las condiciones ambientales.

Hoy en día es común el uso de la **percepción remota** (PR) y los **Sistemas de Información Geográfica** (SIG) en el ámbito de los estudios territoriales. Los SIG tienen tres componentes importantes; el hardware computacional, el conjunto de módulos del software y un apropiado contexto organizacional (Burrough, 1986).

Estos componentes tienen como insumos **imágenes de satélite**, matrices de "n" número de columnas por "m" número de renglones que representan un área geográfica, cada una de estas celdas (píxel) contienen un valor único (número digital) que representa la variación de características medidas a través de la región en diferentes bandas espectrales.

Estas imágenes pueden provenir de **sensores activos**, (si poseen una fuente de luz propia) o **sensores pasivos** (si dependen de una fuente de luz externa). Pueden ser **pancromáticas** si poseen una sola banda que abarca casi todo el visible, o **multiespectrales** si registran separadamente la energía reflejada o emitida en diferentes zonas (o bandas) del espectro electromagnético.

De acuerdo a las características del sensor, las imágenes pueden diferir en su **resolución espectral**, de acuerdo al número, anchura y sobretodo la continuidad de la información en las bandas; **la resolución espacial**, por su nivel de detalle, y la **resolución temporal**, por la frecuencia de las tomas (Chuvienco 2002).

Aunque generalmente, para desarrollar un estudio, lo que se elige es el tipo de imagen más apropiada para obtener el resultado deseado, a menudo el factor determinante es el método, que puede minimizar los requerimientos respecto a la naturaleza, cantidad y calidad de los datos de entrada (Hootsmans, 1996).

Esta idea es interesante al tomar en cuenta que generalmente contaremos con limitaciones para el desarrollo de un proyecto (recursos financieros, disponibilidad de datos, y de tiempo), por lo que lo más recomendable es determinar qué factor es el que podemos controlar, el método o los insumos, y buscar como obtener los mejores resultados en la relación costo-beneficio.

En la figura 1 se esquematiza esta idea. De manera muy general podemos decir que los métodos e imágenes ideales nos darán los mejores resultados, pero también obtendremos resultados aceptables con imágenes alternativas acentuando la atención en mejorar el método, o bien con un método convencional y datos excelentes.

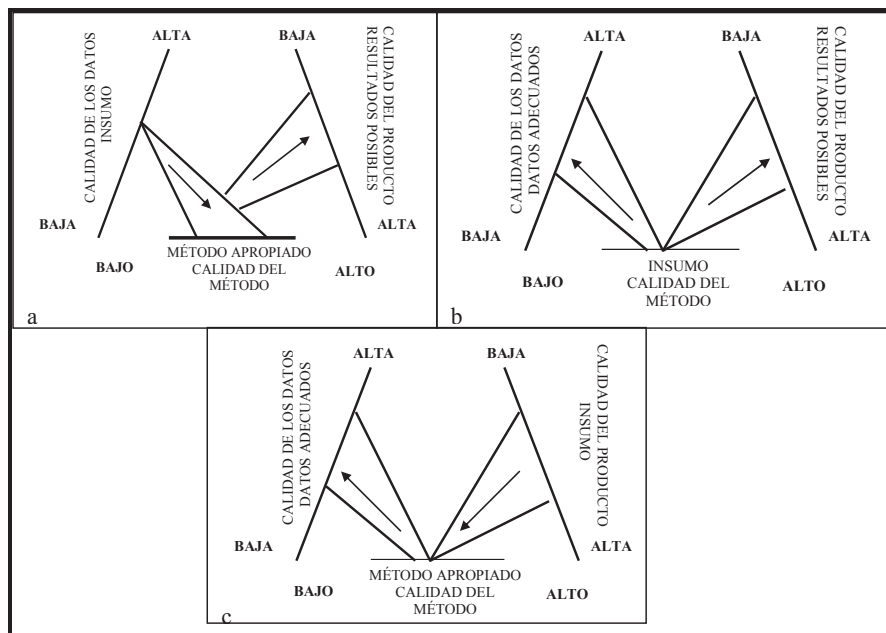


Fig.1 Tres aproximaciones básicas para el procesamiento de datos (Tomado de Hoostmans, 1996)

En los últimos años se ha dado un aumento significativo de la calidad y diversidad de las imágenes de satélite, al incrementarse la resolución espacial y radiométrica de los sensores de alta tecnología. Por otro lado, los SIG son capaces de manejar multidatos, multiplataformas y sofisticadas bases de datos geográficos (Blonda et al., 1991). Sin embargo, el desarrollo de nuevas metodologías no ha ido a la par en el desarrollo de algoritmos para el análisis de los datos. El método más utilizado para la clasificación de imágenes de satélite, sigue siendo el algoritmo de máxima similitud (Haglund, 2000).

La **clasificación** es la fase culminante del tratamiento digital de imágenes. Como fruto de la clasificación se obtiene una cartografía y un inventario de las categorías objeto de estudio (Chuvienco, 2002).

Los pasos generales para una clasificación convencional son básicamente los siguientes:

Antes del procesamiento, se debe hacer una **corrección geométrica** de la imagen, para ubicarla en la posición adecuada de acuerdo a las coordenadas que le corresponden, y radiométrica, para reducir o eliminar la alteración de la respuesta espectral debida a factores externos ambientales.

En la interpretación visual, muchas veces es recomendable hacer un **realce de la imagen**, por ejemplo ajustando su contraste, y elaborar **composiciones en color** para distinguir entidades con mayor facilidad. En ocasiones, se recomienda usar “composiciones” en “**falso color**”, sobretodo en estudios de vegetación ya que en el infrarrojo destaca la reflectancia de esta categoría.

En una clasificación digital supervisada, se trazan los **campos de entrenamiento**, que son polígonos marcados en la imagen que representan los patrones que el algoritmo debe de reconocer e identificar en la imagen para hacer la clasificación (Tso et al., 2001). Cada una de las clases presentes debe de estar representada por campos de entrenamiento.

A partir de los valores digitales de los píxeles comprendidos en los campos de entrenamiento se calculan las **firmas espectrales**, que forman la base para una clasificación de la imagen completa.

Para la clasificación de imágenes provenientes de satélites de resolución media o baja, este mismo método es el más recurrido. En estas imágenes se presentan una gran cantidad de píxeles mezclados o “**míxeles**”, porque el tamaño de píxel no es lo suficientemente fino (Haglund, 2000).

Los clasificadores tradicionales también son llamados clasificadores “duros”, por tomar una decisión tajante acerca de la pertenencia de un píxel a una categoría dada. En este tipo de clasificación se usan píxeles discretos y el resultado es sólo una clase por píxel donde la información sobre la pertenencia a otras clases se pierde. (Hootsmans, 1996).

El algoritmo más comúnmente utilizado, como ya se indicó, es el de **máxima similitud**, que está basado en la probabilidad bayesiana, usando la información de media y varianza/covarianza de un conjunto de sitios de entrenamiento, para estimar la probabilidad posterior de que un píxel pertenezca a una clase (Eastman, 2003).

2.2 CLASIFICACIÓN DIFUSA

Los clasificadores difusos o “suaves” expresan el grado de pertenencia de un píxel para cada una de las clases consideradas (Eastman, 2003). Son recomendables, en zonas donde se presentan paisajes con gran variedad de mosaicos, ya que no generalizan la información pudiendo identificar zonas de transición así como estadios intermediarios de la vegetación. En las imágenes de baja resolución, pueden darnos información, sobre las proporciones de las diferentes coberturas del suelo que componen un píxel. En este sentido se han venido desarrollando trabajos para aprovechar estas herramientas, extrayendo la mayor cantidad de información de las imágenes, así como mejorando la certidumbre de las clasificaciones.

2.2.1 Clasificadores difusos

En este estudio, se utilizaron 3 clasificadores difusos: el primero basado en la distancia, el segundo en el teorema de Bayes y el tercero en el teorema de Dempster Shaper. La descripción de cada uno de ellos se presenta a continuación.

A. Clasificador basado en la distancia

Es el criterio más sencillo para asignar un píxel a una de las categorías contempladas. Se Considera un espacio espectral, donde cada píxel se ubica de acuerdo a su número digital, y cada clase contiene un centroide, resultado del conjunto de valores de los píxeles de los campos de entrenamiento. El método de la **mínima distancia** consiste en incluir el píxel sujeto a clasificarse, en la clase que presenta la distancia menor, en el espacio espectral, entre el píxel y el centro de la clase, tomando en cuenta todas las bandas que intervienen en el análisis, esto se representa en la figura 2 (Chuvienco 2002).

La pertenencia de conjuntos difusos se calcula con base en la distancia euclidiana estandarizada de la desviación estándar de la firma, usando una pertenencia sigmoïdal. La lógica es que la media de una firma representa el punto ideal de la clase donde la pertenencia al conjunto difuso es de 1. Cuando la distancia aumenta, la pertenencia de conjunto difuso disminuye, hasta alcanzar el valor de Z, predeterminado, donde la pertenencia disminuye a cero (Eastman, 2003).

En este tipo de clasificación es posible usar un método normalizado o no normalizado. Un procedimiento no normalizado asume que la pertenencia difusa para cada clase se deriva de manera independiente, y puede existir información incompleta o traslape de las firmas. La suma de los valores para un píxel para todas las clases puede ser, en este caso, diferente de uno. El procedimiento normalizado asume que existe información completa y que las firmas no se traslapan, por lo que la pertenencia del píxel al conjunto difuso para todas las clases sumaría uno (Ibídem).




Fig.2. Representación de un píxel a clasificar y sus respectivas distancias hacia tres coberturas tomando en cuenta su valor en dos bandas (Tomado de Chuvieco 2002).

B Clasificador basado en el teorema de Bayes.

Este clasificador calcula la probabilidad posterior que tiene un píxel de pertenecer a cada clase considerada, de acuerdo al teorema de Bayes.

Es equivalente a la clasificación de máxima similitud estándar. En éste, el fundamento del método, ejemplificado de manera sencilla por Swain y Davis (1978), en el que se supone contamos con dos pares de dados: uno normal (con caras numeradas del 1 al 6) y otro con un par de puntos adicionales en cada cara (numerados del 3 al 8). Conociendo el valor de una tirada, el problema sería saber de qué par de dados se derivó, si de los normales o de los aumentados. Un criterio es calcular la probabilidad, asignando el resultado al par de dados más probable (Chuvieco 2002) como se muestra en la figura 3.

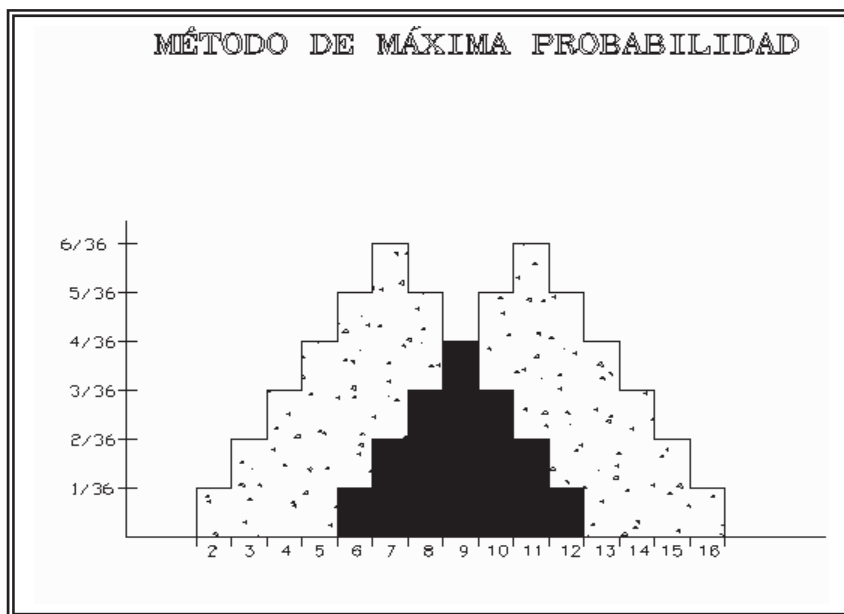


Fig.3 Esquema del fundamento de la clasificación de máxima similitud

(Tomado de Chuvieco 2002).

La diferencia entre el método difuso y el convencional, es que en el segundo el píxel se clasifica en la categoría más probable, así sea ésta el 51% o 99%. Una vez terminada la clasificación perdemos por completo esta información de porcentaje de similitud o pertenencia. En el caso de la clasificación difusa estas probabilidades son rescatadas y representadas como un mapa, de manera que el resultado es un conjunto de imágenes (una por clase) que expresan la probabilidad de cada píxel de pertenecer a cada clase.

La base para el teorema de Bayes (en la notación de la teoría de la probabilidad), establece que:

$$p(h|e) = \frac{p(e|h) * p(h)}{\sum_i p(e|h_i) * p(h_i)}$$

Donde:

$p(h|e)$ = la probabilidad de que la hipótesis sea verdadera dada la evidencia (probabilidad a posteriori).

$p(e|h)$ = la probabilidad de que la evidencia dada por la hipótesis sea verdadera (derivada de los campos de entrenamiento)

$p(h)$ = la probabilidad de que la hipótesis sea verdadera, independientemente de la evidencia (probabilidad a priori)

En este contexto, la matriz de varianza / covarianza derivada de los campos de entrenamiento es la que permite establecer la probabilidad condicional multivariada, es decir $p(e|h)$. Esta cifra es después modificada por la probabilidad a priori de que la hipótesis sea verdadera y finalmente normalizada mediante la suma de las consideraciones sobre todas las clases. Este último paso es importante ya que asume que las clases consideradas son las únicas clases posibles en la interpretación del píxel en cuestión. Aún cuando exista poco soporte para alguna interpretación en particular será tomada como fuerte si es la mas fuerte de las opciones dadas (Eastman 2003).

El uso más importante de este clasificador, es la clasificación subpíxel, por ejemplo para determinar el nivel en el cual existen píxeles mezclados en la imagen expresado en proporciones relativas.

En el contexto del análisis de mezcla las probabilidades se interpretan directamente como supuestos de la representación condicional. Es decir si en una clasificación convencional un píxel tuvo 68% de probabilidad de pertenecer a la categoría A y 32% a la categoría B, se interpreta como que el píxel completo pertenece a la clase A. En cambio en la clasificación basada en el teorema de Bayes esto se interpretaría como que dentro del píxel hay un 68% de la categoría A y 32% de la B.

Esto requiere que varios supuestos se cumplan. Primero, que las clases dadas por los campos de entrenamiento sean exhaustivas, es decir que no existan otras posibles interpretaciones para el píxel. Segundo, que las distribuciones de probabilidad condicional no se traslapen en el caso de píxeles puros. En la práctica estos supuestos son difíciles de cumplir. Pueden ser incorporados los valores de proporción esperados por cada categoría. (Eastman, 2003).

C. Clasificador basado en la teoría de Dempster Shapher

El clasificador difuso basado en la teoría de Dempster-Shapher, reconoce explícitamente la posibilidad de ignorancia. En el proceso se usa la información derivada de los sitios de entrenamiento para clasificar cada píxel de la imagen. El resultado es una imagen por clase, que expresa, de acuerdo a la elección, la plausibilidad o credibilidad “Belief” de que un píxel pertenezca a una categoría dada. (Eastman, 2003).

Este clasificador no asume que contamos con la información completa sobre todas las clases que se encuentran presentes; así mismo esta falta de información no se asume como evidencia contra la hipótesis.

En el lenguaje de la teoría de Dempster-Shapher el grado en el que la evidencia provee respaldo concreto para una hipótesis se conoce como **creencia** (belief) y el grado en el que la evidencia no rechaza la hipótesis se conoce como **plausibilidad**. La diferencia entre estas dos es conocida como intervalo de creencia (belief), que actúa como una medida de incertidumbre sobre una hipótesis específica. Se pueden producir mapas de intervalos de creencia sobreponiendo los mapas de creencia y plausibilidad.

Además de estos dos conceptos, la lógica de la teoría de Dempster-Shapher expresa el grado en el cual el nivel de conocimiento no distingue entre las hipótesis (clases de cobertura). Pueden incorporarse porcentajes esperados de cobertura (a priori).

El algoritmo de este clasificador, descompone los datos en declaraciones de creencia o plausibilidad. Primero se evalúa y modifica la evidencia de probabilidad de los campos de entrenamiento, con las probabilidades a priori, y después se normalizan, con el valor máximo que ocurre en cualquier lugar de la imagen.

La teoría se basa en asumir que en algún lugar de la imagen hay al menos un píxel que representa perfectamente a una clase (más probablemente alguno dentro de un campo de entrenamiento). De cualquier modo, no hay garantía de que los valores de las clases dentro de un píxel sumen 1.

La teoría de Dempster-Shapher requiere que las clases bajo consideración sean mutuamente exclusivas y exhaustivas. De cualquier modo puede haber un píxel que efectivamente pertenezca a alguna clase desconocida, para la cual no haya sido provisto un sitio de entrenamiento, por lo cual se incorpora “otra” clase, a la que se asignan los valores de píxeles que no corresponden a ninguna de las clases contempladas.

La razón más importante para el uso de este clasificador, es verificar la calidad de los campos de entrenamiento y la posible presencia de clases desconocidas durante el proceso de clasificación (Eastman op cit.).

III. ANTECEDENTES

3.1 APLICACIONES DE LA PERCEPCIÓN REMOTA Y SIG

La percepción remota satelital cuenta con numerosas aplicaciones en el estudio territorial, gracias a las ventajas que ofrece frente a otros medios de observación más convencionales como la fotografía aérea o los trabajos de campo, aunque más que sustituirlos los complementa adecuadamente. Entre las ventajas que ofrece destacan la cobertura global y exhaustiva de la superficie terrestre, la perspectiva panorámica, la observación multiescala, la información sobre regiones no visibles del espectro, la cobertura repetitiva, la transmisión inmediata y la disponibilidad en formato digital (Chuvieco 2002).

El análisis de la cobertura terrestre por medio de imágenes de satélite, ha avanzado rápidamente desde el lanzamiento del primer satélite de la serie ERTS (Earth Resource Technology Satellites), que nació con el objetivo específico de estudiar la cobertura terrestre. Este satélite fue lanzado por la NASA, el 23 de Julio de 1972, marcando el inicio de la serie LANDSAT, a la cuál siguieron otros proyectos específicamente diseñados para la observación medio ambiental (Ibídem).

En las últimas décadas y muy especialmente durante los últimos años, han surgido una gran cantidad de datos provenientes de sensores muy variados y de misiones espaciales muy diversas, aumentando exponencialmente las investigaciones científicas y las aplicaciones operativas de esta técnica (Chuvieco op cit.).

3.2 USO DE IMÁGENES DE BAJA RESOLUCIÓN

A pesar de que existe una tendencia creciente por obtener imágenes de mejor resolución espacial, estas presentan la desventaja de ser muy costosas y de poca disponibilidad temporal. Además, para áreas grandes se requiere un gran número de imágenes, complicando su procesamiento. Dada esta problemática, ante la imposibilidad de contar con estos productos, y la gran necesidad de contar con monitoreos de los recursos naturales, y el interés de estudiar alguna fecha particular en la que no se encuentra otro tipo de datos, se ha recurrido a la utilización de imágenes de baja resolución espacial, pero alta resolución temporal, que resultan mucho más accesibles.

Desde finales de la década de los 80's, han sido ampliamente utilizadas las imágenes de baja resolución espacial AVHRR para monitorear grandes áreas (Cihlar 2000). Estas imágenes cuentan con una resolución espacial de 1.1 km. Como ejemplos de su uso en estudios a escala global podemos citar el Programa Internacional De La Geósfera-Biosfera (IGBP), (Loveland et al. 1999), otro realizado por la Universidad de Maryland (UMD), el Forest Resources Assessment (FRA 2000) (FAO 2001), así como estudios de monitoreo de cambios de la vegetación tropical en proyectos como TREES PROJECT (Mayaux et al. 1999).

En nuestro país, en el año de 1997 el Instituto de Geografía de la Universidad Nacional Autónoma de México (UNAM) y la Comisión Nacional para el uso y el conocimiento de la Biodiversidad (CONABIO), realizaron el proyecto "Obtención de cartas de vegetación a partir de imágenes AVHRR de alta resolución", cuyo objetivo principal fue la elaboración de mapas de vegetación anual y estacional y entre los años 1999 – 2000.

Aunque esos productos derivados de AVHRR han sido bien recibidos por la mayoría de los usuarios, existen organizaciones que requieren de mayor detalle temático y las imágenes AVHRR han demostrado no ser apropiadas para estudios a escala nacional o continental por las limitaciones radiométricas y geométricas. En este sentido SPOT VEGETATION (VGT), a bordo de SPOT-4 y SPOT-5, brinda una mejor estabilidad de las plataformas y características espectrales que aumentan la aceptación global de la mayoría de los usuarios. (Mayaux op cit.)

Con datos VGT se realiza el proyecto de cobertura mundial Global Land Cover (GLC 2000) realizado por Francia, Bélgica, Italia, Suecia y la Comisión Europea (Fase Inicial 1998). El sensor trabaja con un campo de visión de 2200 km y una resolución de 1.15 km. (Bartholomé 1997).

Aún con las mejoras que presentan estos productos, persiste el problema de la resolución espacial, ya que en un kilómetro cuadrado en general encontraremos no una, sino varias categorías mezcladas dentro del píxel, existiendo el problema de la generalización y pérdida de la información al conducir una clasificación convencional, que es la más usada en la mayoría de los trabajos realizados con imágenes provenientes de sensores remotos. A partir de esta problemática se desarrollaron diferentes enfoques para tratar de extraer información contenida dentro de los píxeles. Los más utilizados se describen a continuación.

3.3 MÉTODOS DE DESMEZCLA DE PÍXELES

3.3.1 El modelo linear de mezcla

Con el objetivo de obtener información sobre la composición dentro de los píxeles, se han propuesto diversas metodologías. Una de estas es la que se basa en el modelo linear de mezcla (MLM), en el que el valor del píxel en cualquier banda espectral es considerado como una combinación linear de respuesta de cada componente dentro de un píxel (Shimabukuro, 1991).

El modelo se expresa matemáticamente como:

$$d_i = \sum_{j=1}^r S_{ij} a_j + e_i$$

donde:

d_i : reflectancia espectral en la $i^{\text{ésima}}$ banda espectral de un píxel (valor del píxel en la banda i , convertido para el valor de reflectancia).

a_j : proporción del $j^{\text{ésimo}}$ componente dentro del píxel

S_{ij} : reflectancia espectral conocida del $j^{\text{ésimo}}$ componente en la $i^{\text{ésima}}$ banda espectral.

e_i : error de estimación para la $i^{\text{ésima}}$ banda espectral.

Un ejemplo de ésta técnica utilizada con el objetivo específico de rescatar la información a nivel subpíxel es el trabajo de Verhoeve de 2000, quien utilizó el modelo linear de mezcla en productos SPOT VGT en zonas de manglares de África para evaluar la dinámica de estos ecosistemas. Considerando tres categorías (agua, humedales y tierra firme) obtuvo una alta correlación entre los valores de proporción verdaderos y los estimados (0.97, 0.96, y 0.94 respectivamente), además obtuvo una confiabilidad global promedio de 88.9 % en la estimación de proporciones de estas tres coberturas en un píxel.

3.3.2 Métodos difusos

El término de lógica difusa fue introducido por Zadeh en los 60's, es un superconjunto de la lógica booleana o convencional que se ha extendido para manejar el concepto de verdad parcial, es decir valores entre lo completamente verdadero y completamente falso.

A. Redes neuronales.

Este es un método, que intenta imitar el funcionamiento del cerebro humano, por supuesto de manera simplificada, que puede aportar mejores resultados que los métodos de clasificación tradicional.

Dentro de los estudios que demuestran la utilidad de redes neuronales, en específico el método de "Back propagation" para obtener información a nivel subpíxel, está el desarrollado por Swinnen et al. (2000) con imágenes SPOT VGT en Europa. Ellos probaron discriminar 11 y 3 clases. Para validar los resultados obtenidos obtuvieron el error medio absoluto promediando los resultados de todas las clases, por lo que reportan un único resultado de error: 0.79 para 11 clases y 0.38 para tres clases. La descripción de éste método de validación se describe en el marco teórico, pero es importante mencionar que el rango de error varía entre 0 y 2.

Dentro de sus principales ventajas, está que es un método no paramétrico, por lo que no se requiere cumplir con supuestos estadísticos sobre la distribución de los datos, la tasa de cómputo es alta por su paralelismo masivo derivado del denso arreglo de interconexiones, o pesos, y procesadores simples conocidos como neuronas (Tso et al 2001)

Su implementación ha aumentado considerablemente durante los últimos 10 años. A pesar de que el método es complicado de llevar a cabo, es extremadamente sensible a la información de entrenamiento, que debe ser exhaustiva, y el usuario debe determinar la arquitectura de la red, así como definir parámetros tales como la tasa de aprendizaje, que tiene una incidencia directa en el tiempo de procesamiento y el éxito del entrenamiento. Esto es un problema al no existir reglas claras para escoger los parámetros de la red neuronal (Tso op cit).

Otra limitación importante es lo contradictorio de los resultados obtenidos mediante la implementación de esta metodología, que depende directamente de la cercanía de los sitios elegidos para validar la confiabilidad resultante.

Por ejemplo, Fernández et al. (2004) realizaron un estudio con imágenes SPOT VGT en la región experimental "BOREAS", en Canadá. Esta es una región amplia donde les fue posible tener campos de entrenamiento suficientemente lejanos a los sitios de verificación, además contaron con información muy confiable sobre la cobertura "real" derivada de mapas de cobertura a escala más fina. La fiabilidad, medida mediante el cálculo del error medio cuadrático promediado para todas las clases (RMSE), entre los valores estimados y los verdaderos, muestra diferencias notables en el algoritmo de redes neuronales cuando los sitios de verificación se encuentran a 100 metros (RMSE = 6.9) y cuando se encuentran a más de 400 metros (RMSE = 18.7) En éste último caso hubo un aumento del error casi del 300%.

Aún cuando varios estudios muestran mejores resultados para redes neuronales en comparación con otros métodos, por ejemplo los difusos paramétricos, estos últimos presentan más consistencia (menor diferencia en el error) al validar en sitios lejanos a los campos de entrenamiento.

B. Métodos difusos paramétricos

Los métodos difusos paramétricos han probado ser más eficientes que la clasificación convencional en varios estudios. Por ejemplo, Fisher et al. (1993), hicieron una prueba de detección de cambio en fechas cercanas en un área donde sabían que no habían ocurrido cambios. Los resultados mostraron que mientras que el clasificador convencional detectó un cambio de 40.76%, evidentemente falso, el clasificador difuso (Fuzzy C medias) redujo este cambio a 0.32%, tasa muy aceptable para la mayoría de las aplicaciones.

Si bien es cierto que estos métodos requieren que se cumplan supuestos estadísticos (p.ej. distribución normal de los datos) para obtener buenos resultados, son más simples de comprender y de aplicar.

Un ejemplo de la aplicación de estos métodos en la desmezcla de píxeles, es el estudio realizado por Bastin (1997) quien probó los clasificadores de probabilidades derivadas de la clasificación de máxima similitud, así como Fuzzy C medias, (FCM) donde las distancias medidas del píxel hacia el centroide de las diferentes categorías se rescatan como valores de pertenencia a cada una de estas. En este trabajo, totalmente experimental, se aplicaron ventanas de 3*3, 5*5, 7*7 y 11*11 en una imagen Landsat ETM para obtener píxeles grandes que luego fueron comparados con los resultados derivados de la clasificación de la imagen original. En el caso de la ventana de mayor tamaño (11*11), mediante el cálculo de la fiabilidad se obtuvo un coeficiente de correlación promedio para cuatro clases hipotéticas de 0.623 en el caso de Fuzzy C medias, y 0.417 para el método de probabilidades de máxima similitud, ambos valores significativos para un nivel de confianza de 99%.

3.3.3 Estudios comparativos

Es interesante comparar diferentes métodos en la misma área de estudio, ya que esto nos permite evaluar el desempeño de cada uno de los algoritmos evitando la disparidad del sistema clasificatorio, variables atmosféricas radiométricas y geométricas, entre otros factores.

Como ejemplo de este tipo de trabajos Atkinson (1997), evaluó tres técnicas para generar mapas a nivel sub píxel, en imágenes NOAA AVHRR (Modelo lineal de mezcla, redes neuronales y fuzzy c-medias). Los datos obtenidos de cada clasificador con respecto a la verdad (representada por la clasificación de máxima similitud de una SPOT HRV), se validaron mediante el cálculo del RMS error para las cuatro clases consideradas (agricultura, bosque, suelo desnudo y otras coberturas). El mejor desempeño lo mostraron las redes neuronales con un rango de error de 8.52 % a 17.02%, contra un rango de 11% a 25% del modelo de mezcla y 13% a 23% del Fuzzy C Medias.

Otro estudio comparativo es el desarrollado por Frizzelle et al. (2001), quienes trabajaron con una imagen Landsat TM de la región noreste de Santa Bárbara USA, considerando 8 clases (tres tipos de bosque, tres tipos de vegetación arbustiva, pastizal y suelo desnudo). Probaron los algoritmos de redes neurales y probabilidades derivadas de máxima similitud, mediante el cálculo del coeficiente de correlación entre los valores de proporción obtenidos de los clasificadores difusos y los valores de verdad representados por la interpretación de fotografías aéreas. Obtuvieron un rango de correlación de -0.02 a 0.46 para el clasificador de probabilidades y de -0.09 a 1.00 para redes neuronales.

3.3.4 Conclusiones.

Los resultados presentados en la literatura son variados y contradictorios por lo que es difícil y riesgoso concluir que un método es mejor que otro, ya que el desempeño de cada algoritmo depende del tipo de imagen utilizada, el número y tipo de clases a discriminar y la experiencia del productor, entre otros factores. De la misma manera, es muy importante escoger un buen método para la validación de los resultados, que permita, por un lado, comparar con otros trabajos publicados y por otro ser lo suficientemente robusto y confiable para tomar decisiones con base en los resultados obtenidos.

Los métodos más usados en la validación son el cálculo del RMS error (Error medio cuadrático de cada categoría) y RMSE (error medio cuadrático promediado para todas las categorías) cuyos rangos van de 0 a 1, es decir del 0 al 100%, así como también el cálculo de la correlación, esto lo podemos observar en el cuadro 1, donde se presentan los trabajos que se consideraron como más relevantes por su similitud con este trabajo en cuanto a los objetivos a alcanzar.

Menos frecuentemente se emplea el cálculo del error medio absoluto (MAE), cuyo rango varía entre 0 y 2, es decir entre 0 y 200%, donde el peor caso sería que el valor estimado presente un valor de 100% de una o varias categorías completamente distintas al 100% del valor de verdad. También puede presentarse calculado por cada categoría, que sería lo más adecuado; sin embargo, se ha encontrado publicado sólo el valor promediado para todas las categorías, como en el caso de Swinnen et al. (2000).

Cuadro 1. Síntesis de algunos trabajos de desmezcla publicados en la literatura.

AUTOR	IMAGEN DE BAJA RESOLUCIÓN	NUMERO Y TIPO DE CLASE	AREA DE ESTUDIO	MÉTODO DE DESMEZCLA	IMAGEN DE VALIDACIÓN O REFERENCIA	MÉTODO PARA DETERMINAR LA FIABILIDAD
Atkinson et al. 1996	NOAA AVHRR	4 (vegetación, Arbustiva, bosque, agricultura, suelo desnudo y otros)	Sur de UK	Redes neuronales Modelo lineal de mezcla Fuzzy C medias	SPOT HRV	RMS y coeficiente de correlación.
Foody et al. 1997	AVHRR	3 (Agua, pastizal y bosque)	Mato Grosso (Brasil)	Redes neuronales	LANDSAT TM	RMS, coeficiente de correlación.
Bastin 1997	Simuladas derivadas de la imagen TM en ventanas de 11*11	4 clases (denominadas 1,2,3 y 4)	No se cita	Probabilidades de máxima similitud. Fuzzy C medias	LANDSAT TM	RMS Coeficiente de correlación
Verhoeve 2000 et al.	VGT (1Km ²)	3 (Humedales, agua y tierra firme)	Humedales en África	Modelo lineal de mezcla	SPOT -XI	Coeficiente de correlación
Swinen 2000	VGT S10 (1Km ²)	3 (Vegetación arbórea, herbácea y área sin vegetación)	Continente europeo	Redes neuronales	CORINE (LANDSAT TM)	Error medio absoluto (MAE)
Haglund 2000	MSU-SK (160m ²)	8 (Agua, urbano, agricultura, pantano, deciduo, ciénega, coníferas y sin vegetación)	Región Báltica (Europa)	Distancia, Teoría Dempster Shapher y teoría de Bayes	CORINE (LANDSAT TM)	RMS
Frizzelle et al. 2001	LANDSAT TM	8 (coníferas, roble, bosque deciduo, arbustos de encino, arbustos de bosque subperenifolio, otros tipos de arbustos, pastizal, área sin vegetación)	Noreste de Santa Bárbara California	Redes neuronales. Probabilidades de máxima similitud.	Fotografías aéreas	RMS Coeficiente de correlación.
Fernández e tal. 2002	SPOT VGT	6 (bosque, bosque hoja aguja, bosque hoja ancha, bosque, herbácea, sin vegetación y agua)	Región boreal (Canadá)	Redes neuronales	LANDSAT TM	RMS coeficiente de correlación.
Shalan et al. 2003	LISS (23m)	5 (agricultura, urbano, arenoso, bosque, pastizal)	West bengal India	Probabilidades de máxima similitud. Fuzzy C medias	IRS (5.8M)	Entropía coeficiente de correlación
Oki et al. 2004	AVHRR	3 (Vegetación área Urbana /suelo desnudo agua)	Humedales en Siberia	Modelo lineal de mezcla	LANDSAT TM	RMSE
Weiguo et al. 2004	MODIS	4 (estéril, agua, pastizal y bosque)	Centro y Norte de Turquía	Árbol de regresión, redes neuronales.	LANDSAT TM	RMS y coeficiente de correlación.

III. OBJETIVOS.

3.1 OBJETIVO GENERAL

- Evaluar tres clasificadores difusos en la clasificación subpíxel de coberturas del suelo en imágenes de baja resolución espacial (SPOT VEGETATION)

3.2 OBJETIVOS PARTICULARES

- Elaborar mapas difusos de cobertura
- Evaluar la confiabilidad de los mapas difusos
- Detectar las bondades o fallas de cada clasificador difuso

IV. DESCRIPCIÓN DEL ÁREA

4.1 CARACTERIZACIÓN GEOGRÁFICA

El área de estudio corresponde a la región centro del Estado de Quintana Roo (Fig. 4), entre las coordenadas geográficas $-89^{\circ} 4' 23''$ y $-86^{\circ}48' 48''$ de longitud oeste y $19^{\circ}15'56''$ y $21^{\circ}11'15''$ de latitud norte. Abarca los municipios de Solidaridad, la mayor parte de Felipe Carrillo Puerto y José María Morelos, así como una porción del municipio de Lázaro Cárdenas, así como una porción de Yucatán.

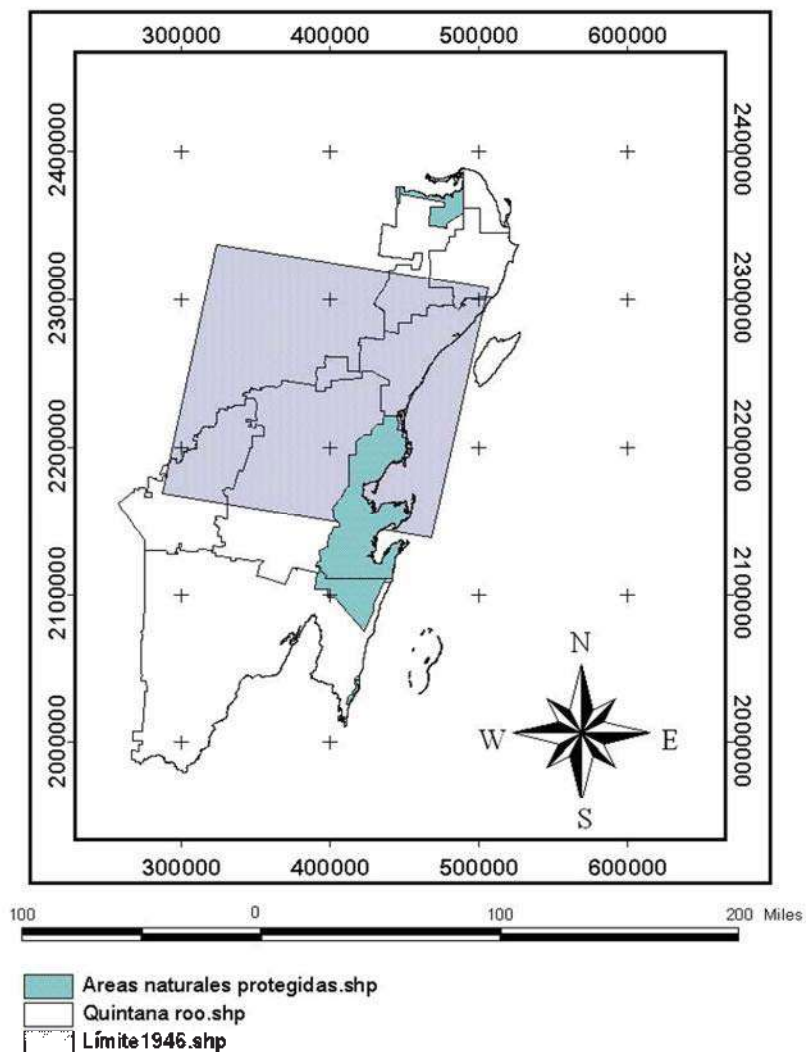


Fig. 4. Área de estudio ubicada en el estado de Quintana Roo.

4.2 OROGRAFÍA

El municipio se encuentra sobre una planicie de origen tectónico, el relieve es prácticamente plano con algunas colinas de tamaño pequeño y numerosas hondonadas; la altura promedio es de 10 metros sobre el nivel del mar (msnm). Las principales elevaciones son los cerros: Charro (230 msnm), Gavilán (210 msnm), Nuevo Becar (180 msnm) y El Pavo (120 msnm), (Portal del gobierno de Quintana Roo, 2006).

4.3 HIDROGRAFÍA

La roca caliza, sumamente permeable, que forma el suelo de esta región no permite la existencia de corrientes de aguas superficiales, pero existen varias 33 lagunas de las cuales la más importante es Bacalar, La Unión, Chumpoko, Campechen, otras lagunas menores son: Kana, Boca Paila, San Miguel y Catoche; en la parte oeste del municipio se localizan las lagunas: Cobá, Verde y Nochacam (Ibídem). Existen cenotes ubicados en la línea costera, entre los que destaca el Cenote Azul, y otros alejados de la costa.

4.4 CLIMA

El clima del municipio es cálido subhúmedo con lluvias en el verano. La temperatura media anual es de 26° C. Los vientos predominantes son los del sureste. La precipitación pluvial anual oscila entre los 1,300 y los 1,500 milímetros, con estación de lluvia de marzo a octubre. El clima se ve afectado por los ciclones, que aumentan la precipitación sobre todo en verano (Ibídem).

4.5 PRINCIPALES ECOSISTEMAS

La vegetación se conforma de selva mediana subperennifolia y subcaducifolia, y selva baja subperennifolia, que son particularmente valiosas para la explotación forestal debido a la presencia de maderas preciosas como la caoba y el cedro. Por otra parte, en zonas próximas a las áreas inundables y al mar se han desarrollado

comunidades de manglares, aunque la superficie que ocupan es relativamente pequeña. La zona costera posee manchones de vegetación de dunas (Ibídem).

En el área de la costa se localizan áreas de manglar y algunas ciénagas con especies tales como el mangle rojo y el mangle blanco. En la zona de las dunas costeras existe predominio de la uva de mar, así como la palma cocotera entre otros. Las áreas inundables o sujetas a inundación presentan vegetación de tule (Ibídem).

De acuerdo al Inventario Nacional Forestal (Palacio et al. 2000), como se muestra en el cuadro 2, en la zona de estudio, la mayor superficie está ocupada por la selva mediana subperenifolia, con un 43% de la superficie, conformando para todo el estado la extensión de vegetación más importante en el país por su continuidad. En segundo lugar por extensión se encuentra el pastizal con 22%, luego la selva mediana subcaducifolia y la agricultura con el 15% y 14% respectivamente. Las categorías restantes suman en conjunto el 6%.

Cuadro 2. Superficie ocupada por cada una de las coberturas del suelo presentes en el área de estudio delimitada por la imagen ETM de acuerdo al IFN 2000.

Cobertura	Superficie km2	Porcentaje
Agricultura	6,437	15%
Selva mediana subperenifolia	18,536	43%
Selva baja subperenifolia	445	1%
Pastizales inducidos y cultivados	9,404	22%
Selva mediana subcaducifolia	6,107	14%
Manglar	560	1%
Vegetación Hidrófila	1,127	3%
Cuerpos de agua continentales	78	0.18%
Selva baja subcaducifolia	509	1%

En la siguiente figura 5, se esquematiza la información del cuadro anterior, donde “AGRO” se refiere a la cobertura de agricultura “SMSP” a la selva mediana subperennifolia, “SBSP” a la selva baja subperennifolia, “PAST” a los pastizales cultivados e inducidos, “SMSC” a la selva mediana subcaducifolia, “HIDRO” a la vegetación hidrófila y “SBSC” a la selva baja subcaducifolia.




Fig. 5. Porcentajes de las coberturas presentes en el área de estudio.

4.6 FAUNA

Los animales de la región son en su mayoría de origen neotropical, sin embargo están presentes animales de origen neártico, como el venado. Los principales grupos representados son los anfibios, reptiles, aves y mamíferos. Se ha detectado la presencia de 309 especies en el corredor Cancún - Tulum de las cuales las aves son las más difundidas. Las más representativas son los zanates, garzas blancas y colibríes, además de pequeños mamíferos como la zorra gris, ardillas, ratones, tlacuaches y murciélagos, que junto con la gran variedad de fauna marina representan un recurso importante de la localidad (Portal del gobierno de Quintana Roo, 2006).

No obstante la alta riqueza específica, la gran biomasa y la elevada producción primaria bruta, en términos agronómicos convencionales las selvas son

improductivas, de ahí la tendencia a destruirlas o modificarlas en favor de agroecosistemas monoculturales simples (Chargoy, 1999). Sin embargo, de los tres estados que conforman la península de Yucatán, en Quintana Roo se encuentran los geocomplejos naturales mejor conservados. Esto se debe al importante y adecuado manejo comunitario y a la existencia de áreas naturales protegidas (Chiappy 2004).

4.7 ÁREAS NATURALES PROTEGIDAS

Aproximadamente el 25% de la superficie total de Quintana Roo se encuentra bajo algún esquema de protección ecológica, con el propósito de conservar los recursos naturales y la diversidad biológica del Estado. Las reservas ecológicas protegidas son: Área de protección de flora y fauna de Uaymil, Reserva de la Biosfera de Sian Ka'an, Reserva de la Biosfera de Banco Chinchorro, Reserva especial de la biosfera de Isla Contoy, Parque Nacional de Tulum, Parque marino nacional Arrecifes de Cozumel, Parque marino nacional costa occidental de Isla Mujeres, Punta Cancún y Nizuc; Unidad de evaluación y monitoreo de la biodiversidad San Felipe Bacalar, Parque urbano de Kabah, Parque natural laguna de Chankanaab, área de protección de flora y fauna silvestre y acuática de Laguna Colombia, zona sujeta a conservación ecológica el Santuario de manatí en la Bahía de Chetumal, Reserva privada El Edén y Reserva de U Yumil C'Eh (El paraje del Señor de los Venados) (Portal del gobierno de Quintana roo 2006).

Una de las áreas de protección más importantes en el área de estudio es La Reserva de la Biosfera de Sian Ka'an, "Puerta del cielo", que alberga mas de 300 especies de aves acuáticas y una gran variedad de mamíferos. En esta reserva se reproducen especies como el jaguar, el puma, el ocelote, el tigrillo, el mono araña, el venado cola blanca, y otros en peligro de extinción, como el manatí. La biodiversidad de la selva incluye: bosque tropical, sabana, manglares y costa. Así mismo, forma parte de la reserva llamada el Gran Arrecife Mesoamericano para protección de las áreas de coral desde Quintana Roo hasta Honduras (Ibídem).

4.8 MANEJO COMUNITARIO.

La conservación ecológica de la selva tropical depende más de alternativas de producción que tengan como base la experiencia antigua de la agricultura, adecuándola a las exigencias contemporáneas, que del establecimiento de zonas de reserva (Chargoy, 1999).

Tradicionalmente las estrategias para la conservación consideraban la exclusión de la población local de su manejo, a través de reservas forestales y/o áreas naturales protegidas. Con el tiempo se evidenció la necesidad de contar con la participación de las comunidades, por lo que en 1983 se estableció el Plan Piloto Forestal (PPF), cuyo concepto central era que el uso racional del recurso forestal debía ser un ingreso económico, seguro y atractivo para la población local (Primack et al. 1999).

Para esto hay dos elementos centrales, la presencia de un agente externo que promueva a nivel local la implantación de nuevas prácticas y estructuras, y el avance de una organización campesina compatible con el concepto de empresa forestal (Ibídem).

En el estado de Quintana Roo, una organización compuesta por 16 ejidos está manejando 360,000 hectáreas de bosque subtropical húmedo para beneficiar a sus miembros y al mismo tiempo preservar el bosque. Del total del área de bosque, 150,000 hectáreas se reservan para producción permanente de cedro y caoba fundamentalmente. Después de negociar con las empresas madereras, los participantes -- 3.000 en 1991 -- comenzaron a procesar los troncos, lo cual agrega valor al producto y reporta a las comunidades un ingreso mayor que la simple extracción de la madera en bruto.

Antes de que los ejidos manejaran el bosque, las comunidades residentes no derivaban ningún beneficio de las operaciones de tala. Ahora los participantes están trabajando para mantener el bosque natural, realizando la corta en ciclos de 25 años, lo cual permite que las especies nativas se regeneren, e incrementando la proporción de cedro y caoba mediante la siembra enriquecida. Después de ocho años, las comunidades ya están viendo una buena regeneración del bosque natural, junto con ingresos y un incentivo para continuar con su buena labor (Primack op cit.).

V. MATERIALES Y MÉTODOS.

5.1. MATERIALES.

5.1.1 Productos ETM

La imagen utilizada como referencia proviene del sensor ETM+ de la serie de satélites LANDSAT de fecha 21 de Abril de 2000, y corresponde a la parte central del Estado de Quintana Roo, tiene una resolución espacial de 30 m, lo que permite la elaboración de mapas a una escala 1:100,000. Está compuesta por 8 bandas espectrales, de las que 6 bandas son multiespectrales y pueden ser combinadas de distintas formas para obtener composiciones de color u opciones de procesamiento. La banda pancromática (banda 8) cuenta con una resolución espacial de 15 m, y la banda 6 (infrarrojo térmico) de 60 m. Estas dos últimas bandas no se usaron en el presente estudio

Cuadro 3. Características de las bandas del sensor ETM+

	Longitud de onda	Resolución espacial
Banda 1	0.45 - 0.52 μ m (azul)	30 metros
Banda 2	0.52 - 0.60 μ m (verde)	30 metros
Banda 3	0.63 - 0.69 μ m (rojo)	30 metros
Banda 4	0.75 - 0.90 μ m (infra-rojo cercano)	30 metros
Banda 5	1.55 - 1.75 μ m (infra-rojo)	30 metros
Banda 6	10.4 - 12.50 μ m (infra-rojo térmico)	60 metros
Banda 7	2.08 - 2.35 μ m (infra-rojo cercano)	30 metros
Banda 8	0.52 - 0.90 μ m (infra-rojo cercano verde)	15 metros

La imagen fue previamente corregida para el IFN 2000, mediante 40 puntos de control, con un error medio cuadrático (RMS error) reportado de 0.56 en el eje x y 0.50 en el eje Y. las características del sistema de referencia de origen fueron Proyección Universal Transversa de Mercator (UTM), zona 16, Datum North American (NAD) 1927, Elipsoide - Clarke 1866.

5.1.2 Productos SPOT VEGETATION (VGT)

VEGETATION-2 (a bordo del satélite SPOT-5) funciona desde el 1 de marzo de 2003. Las imágenes son tomadas a 830 km de altitud, examinan de forma continua la superficie terrestre en cuatro bandas espectrales: azul (b0, 0.440-0.470 μm), roja (b2; 0.610-0.690 μm), infrarrojo cercano (b3; 0.7660 –0.890 μm), infrarrojo medio (Mir; 1.590 – 1.690 μm), con una resolución espacial aproximada de 1,150 metros. El ciclo del satélite SPOT es de 26 días, pero dado el amplio ángulo de vista del VGT, los datos están disponibles en su mayoría de manera diaria. Cada cinco días el punto es visualizado en un ángulo geométrico similar (Spot-VEGETATION Technical Information).

El área de aplicación de los productos derivados del satélite SPOT VEGETATION es extensa. Abarca la ocupación y la utilización de los suelos, el estudio de los cambios de la biosfera, la interactividad entre clima y vegetación, la gestión del medio ambiente, la evaluación de los incendios forestales y de las zonas de quema, el seguimiento de los recursos de agua, la vigilancia de los riesgos de inundaciones, así como la evaluación de los daños en la cubierta vegetal. Se concede el acceso gratuito a las observaciones de más de tres meses, lo cuál permite que la falta de recursos no sea una limitante. Los datos VGT se caracterizan por su buena cobertura y consistente calidad de la imagen y lo que las hace particularmente interesantes para investigaciones usando técnicas de detección de cambio (Ibídem).

Con el fin de contar con datos de referencia de la misma fecha de la imagen de referencia (Landsat ETM), se solicitó el envío de la imagen SPOT VGT del 21 de Abril de 2000 a través del programa “SPOT VEGETATION” del centro de investigación de la comunidad europea.

La imagen original abarca 2,250 km desde los 106°06'25" a los -51°17'8" de longitud y de los 16°25'10" a los 71°55'42" de latitud. Se obtuvo previamente corregida, en coordenadas PLATE_CARREE, WGS 84 con un error medio cuadrático (RMS error) reportado menor a 30 metros y una corrección radiométrica con un error reportado menor al 5%. El número de columnas es de 6540 y 6617 renglones. El formato de origen es HDF.




Fig. 6. Imagen Original del sensor SPOT VGT.

5.1.3 Fotografías aéreas

El uso de fotografías aéreas para la verificación en lugar de visitas de campo, permitió enfrentar limitaciones de tiempo y presupuesto.

Las fotografías aéreas digitales utilizadas, tienen una resolución espacial aproximadamente de 1 m, fueron tomadas en el año 2000 en el ámbito del inventario forestal nacional 2000 (Mas et al., 2002). Las líneas de vuelo a nivel nacional tienen una separación entre líneas de vuelo es de 50 Km. en las zonas centro y sur, y de 100 Km. en el norte. En toda la longitud de estas líneas se obtienen imágenes digitales en color, cubriendo una franja continua de entre 1.5 y 3 Km. de ancho, con una sobreposición entre tomas del 60% (Palacio et al. Op cit).

Se hizo un corte del muestreo aéreo distribuido por todo el territorio nacional, al área de interés. Dentro de esta línea aérea se eligieron fotos con el propósito de verificar la fiabilidad de la clasificación de la imagen Landsat.

5.2 METODOLOGÍA

A continuación se describe por un lado la metodología desarrollada, para clasificar la imagen de mejor resolución espacial (Landsat ETM) la cuál se clasificó de manera tal, que estuviera lo más apegada a la verdad de campo, esta imagen se utilizó como “imagen de referencia”. Así mismo se describe el procesamiento y evaluación de la imagen de baja resolución espacial (SPOT VGT). Los valores de los píxeles en la imagen de referencia dentro de un kilómetro cuadrado, que corresponden a cada píxel de la imagen spot VGT, permitieron calcular las proporciones reales con las cuales se compararon los valores difusos resultantes de cada uno de los clasificadores difusos.

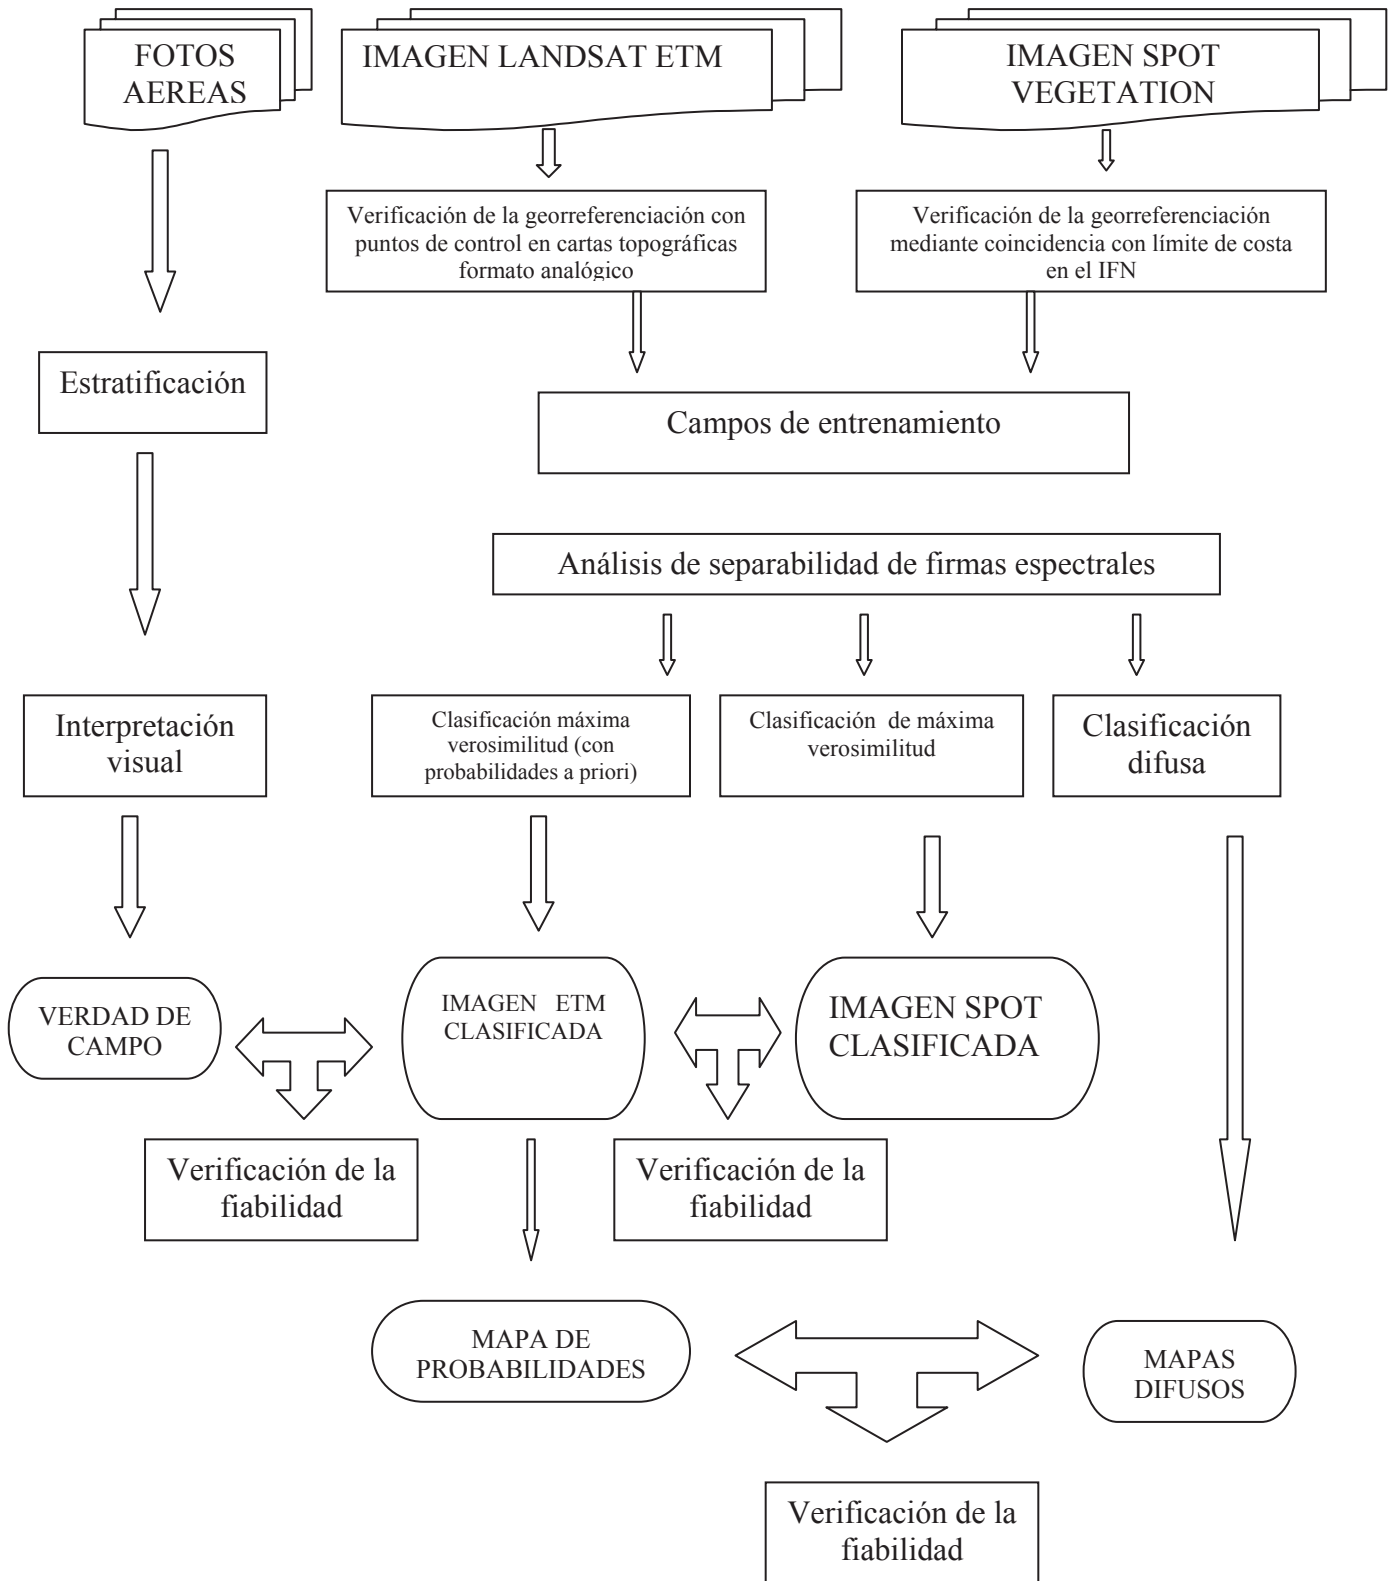


Fig.7 Esquema metodológico general

5.2.1. Corrección geométrica.

Este paso es importante debido a que de la buena coincidencia geométrica de las dos imágenes asegura que los errores encontrados se puedan atribuir solamente al desempeño de los clasificadores y no a errores de posición.

La verificación de la corrección geométrica de la imagen ETM+ de 2000, se realizó con base en 30 puntos de control, tomando como referencia cartas topográficas impresas de INEGI escala 1:50,000, ambas en coordenadas UTM Datum NAD 27.

La imagen SPOT VGT se reproyectó a coordenadas UTM NAD27 México para coincidir con la imagen de referencia. Se verificó de manera visual su posición geométrica con base en la sobreposición del vector de la línea de costa derivado del inventario nacional forestal 2000.

5.2.2 Sistema clasificatorio

Se optó por utilizar categorías compatibles con la cartografía del “Inventario Forestal Nacional 2000” y la “Evaluación de la dinámica espacio temporal de la frontera agrícola de Quintana Roo”. El uso de una leyenda compatible permite disminuir la complejidad en las diferentes etapas de comparación.

La leyenda original del mapa de referencia, así como los criterios de discriminación para cada categoría de acuerdo al IFN 2000, fue la siguiente:

- 1. Agricultura de Riego:** Superficie en la que el suelo es utilizado para cultivos agrícolas, mismos que reciben agua mediante algún sistema de riego o que aprovechan la humedad residual del suelo, ya sea antes de empezar, o después de haber terminado la temporada de lluvias.
- 2. Agricultura de temporal:** Superficie en la que el suelo es utilizado para cultivos agrícolas que reciben agua de lluvia únicamente.
- 3. Vegetación secundaria:** (acahual) Derivada de la perturbación del bosque tropical. Incluye áreas con vegetación secundaria donde predominan arbustos y árboles. Se considera como una fase sucesional temprana o intermedia, que con el tiempo y en condiciones naturales favorables se puede restablecer la vegetación original.
- 4. Selva mediana subperennifolia:** Vegetación arbórea de 20 m o más de altura; durante la estación seca del 25 al 50 % de los árboles pierden el follaje. Algunos de los taxa más representativos son: Aseis, Pterocarpus, Carpodiptera, Manilkara, entre otros.
- 5. Selva mediana subcaducifolia:** Vegetación arbórea de entre 15 y 20 m de altura. Más del 50 % de los árboles pierden el follaje durante la estación seca. Se desarrolla en climas cálido semisecos. Los géneros típicos son: Enterolobium, Hymenaea, Orbignya, entre otros.

6. **Pastizal:** Comunidades vegetales caracterizadas por la dominancia de gramíneas (pastos o zacates) o graminoides. Aquí se incluyen pastizales determinados tanto por condiciones naturales de clima y suelo, como aquellos promovidos por influencia humana.

7. **Vegetación hidrófila:** Incluye dos subtipos **Mangle:** Vegetación arbórea de alturas bajas y medianas (3 a 15 m generalmente), dominada por una o más especies de mangle, que se desarrolla en esteros, lagunas costeras, estuarios y costas protegidas. Géneros típicos incluyen: *Rhizophora*, *Avicennia*, *Laguncularia* y *Conocarpus*. **Popal tular:** Vegetación herbácea que se desarrolla en las orillas de los cuerpos de agua, o bien en aguas de poca profundidad, en zonas costeras o continentales tanto en zonas tropicales como templadas. Géneros típicos incluyen: *Calanthea*, *Thalia*, *Heliconia* y *Typha*.

8. **Área sin vegetación aparente:** Áreas que parecen ser desprovistas de una cobertura vegetal. La ausencia de vegetación puede ser determinada por condiciones naturales (clima muy árido, salinas), o bien porque la vegetación fue eliminada totalmente por actividades humanas, como son la minería a cielo abierto, depósitos de jales, sobrepastoreo, entre otros usos no perceptibles en imágenes de satélite

9. **Asentamiento humano:** Área ocupada por zonas edificadas, urbanas, suburbanas e industriales principalmente.

10. **Cuerpo de agua:** Se refiere a los depósitos mayores de aguas interiores del país, tanto naturales como artificiales (lagos, lagunas, presas y bordos), perceptibles en imágenes de satélite.

Adicionalmente se incluyeron las categorías de nube y sombra.

Para la imagen SPOT VEGETATION se consideraron solamente 5 clases, debido a la dificultad de entrenar en sitios con superficie muy pequeña (ciudades, área sin vegetación, vegetación halófila) o en sitios donde no se observó diferencia en los patrones de una y otra categoría, los que finalmente podían agruparse en un nivel jerárquico superior. Las clases fueron:

1. **Agropecuario** (incluye pastizal, agricultura de riego, agricultura de temporal)
2. **Selva mediana subperenifolia**
3. **Selva mediana subcaducifolia**
4. **Vegetación hidrófila (mangle y popal tular)**
5. **Cuerpo de agua**

De igual manera se consideró nube y sombra.

Para poder llevar a cabo la validación, las categorías de agricultura de riego, agricultura de temporal y pastizal fueron reclasificadas para ser equivalentes a las del mapa resultante de la imagen SPOT VGT.

5.2.3. Campos de entrenamiento.

Los campos de entrenamiento se marcaron con ayuda de conocimiento experto y auxiliados por fotografías aéreas, seleccionando áreas que se consideraron con 100% de pertenencia a cada categoría dada. Los campos se digitalizaron sobre una composición en falso color. Se trazaron un total de 104 campos de entrenamiento en la imagen SPOT VGT y 250 en la ETM, distribuidos de manera uniforme sobre la imagen, intentando que representaran de la mejor manera a cada una de las categorías.

En la imagen SPOT VGT, una vez obtenidos los campos de entrenamiento se hizo una matriz de confusión tomando a los campos de entrenamiento como valor de verdad y a la imagen de máxima verosimilitud como la imagen a validar, esto con el objeto de corroborar de manera preliminar que los campos de entrenamiento efectivamente se clasificaran dentro de la categoría que representan. Cuando hubo píxeles clasificados en diferentes clases, se procedió a hacer un análisis cuantitativo de las firmas espectrales para evaluar su separabilidad.

5.2.4. Análisis de separabilidad de firmas espectrales.

El término “separabilidad” se refiere al grado en el cual se distinguen espectralmente las categorías. Por un lado es útil para determinar cuántas y cuáles bandas se necesitan para obtener una separabilidad aceptable (esto se hizo para la imagen de referencia). Por otro lado, también para probar la adecuada separación de las clases, considerando que los valores de separabilidad de firmas están correlacionados con la separación de clases, de acuerdo a la información dada por medio de los campos de entrenamiento.

Los métodos para estimar separabilidad se basan en medidas de distancias estadísticas entre las clases espectrales de interés. La divergencia estadística asume que los números digitales en una categoría se distribuyen normalmente, considerando la separabilidad como medida del solape entre categorías vecinas. Se trata de calcular ese valor para un espacio multivariado (tantas variables como bandas espectrales intervengan en el proceso), considerando el vector de medias y la matriz de varianza-covarianza entre pares de categorías (Lundberg et al. 1973).

Los métodos más populares son el de la divergencia (D), el de la distancia de Bhattacharyya (distancia-B), el de la divergencia transformada (TD) y el de la distancia de Jeffreys Matusita (JM).

Maussel et al. (1990) condujeron un estudio en un campo experimental en Texas, considerando 6 clases. Mediante la combinación de 70 bandas probaron que los índices de separabilidad más acertados son la divergencia transformada y la distancia de Jeffreys Matusita, mostrando una correlación casi perfecta con la fiabilidad de la clasificación (0.96, 0.97).

El método de divergencia transformada (TD), además de mostrar una excelente confiabilidad es computacionalmente más simple que los otros métodos citados.

La divergencia transformada se define estadísticamente como:

$$TD_{i,j} = 2000 * [1 - \exp(-D_{i,j} / 8)] \quad (1)$$

donde:

TD(i,j) = divergencia transformada entre clases i y j

D(i,j) = divergencia entre clases i y j

D(i,j) = $0.5 * T [M(i)-M(j)] * [InvS(i)+InvS(j)] * [M(i)-M(j)]$
 $+ 0.5 * Trace [InvS(i)*S(j) + InvS(j)*S(i) - 2*I]$

donde

M(i) = vector medio de la clase i, donde el vector tiene N elementos de bandas (N bandas es el numero de las bandas usadas)

S(i) = matriz de covarianza para la clase i, la cual tiene N bandas por N elementos de bandas.

InvS(i) = matriz inversa de S(i)

Trace[] = trazado de la matriz (suma de los elementos de la diagonal)

T[] = matriz transpuesta

I = identificador de la matriz

En esta fórmula es posible encontrar valores entre 0 y 2000, donde el valor de 2000 representa la separabilidad máxima entre los pares de clases (Maussel et al. 1990).

Para la interpretación de los valores de separabilidad, se adoptaron las reglas mostradas en el cuadro 4 (pcigeomatics.com).

Cuadro 4. Definición cualitativa propuesta para la interpretación de los valores de separabilidad.

0 – 1000	Separabilidad muy pobre
1000 - 1900	Separabilidad pobre
1900 - 2000	Buena separabilidad

En el caso de firmas con muy pobre separabilidad, lo recomendable es, o bien eliminar una de las firmas o combinarlas. En el caso de pobre separabilidad, las firmas se separan en algún grado, así que es deseable aumentar los campos de entrenamiento de cada una para intentar aumentar en lo posible la separabilidad.

5.2.5. Clasificación de la imagen de referencia

La imagen de referencia (Landsat ETM+) de mejor resolución espacial, se clasificó de manera que representara fielmente a la verdad de campo. Esto es de suma importancia ya que el resultado se utiliza para evaluar la clasificación difusa de la imagen SPOT VGT.

Un método que ha mostrado muy buenos resultados para amentar la fiabilidad de los mapas es el uso de datos auxiliares. En este trabajo se usaron para separar clases diferentes espectralmente parecidas, ya que conforme aumenta la variabilidad aumenta también la probabilidad de confusión entre objetos espectralmente similares. La aproximación utilizada involucra la modificación de las reglas de decisión del algoritmo de máxima similitud. En la mayoría de los casos se asume que las probabilidades a priori son iguales para todas las clases.

En este caso, se dieron valores a priori en la clasificación de máxima similitud en formato de imagen. Para este efecto se corrigió de manera visual el Inventario Forestal Nacional con datos de campo y conocimiento experto, y de éste se derivaron mapas de vegetación potencial que funcionaron como imágenes de probabilidad.

5.2.6 Evaluación de la fiabilidad en la imagen de referencia (Landsat ETM)

Debido a que los datos no pueden estar exentos de error, es necesario evaluar el nivel de correspondencia entre los dos conjuntos de ubicaciones, tomando en cuenta que cada una tiene sus propias fuentes de error.

Para validar la clasificación de la imagen Landsat ETM se seleccionaron fotografías aéreas, utilizando un método de muestreo probabilístico aleatorio estratificado. En éste todas las unidades de muestreo presentes en el mapa tienen una probabilidad mayor a cero de ser seleccionadas. Cada estrato corresponde a cada una de las clases del mapa. De ésta manera se asegura que las categorías de pequeña superficie sean muestreadas, lo que no hubiera ocurrido en un muestreo totalmente aleatorio (Mas et al. 2003).

Para cada categoría se seleccionaron 20 fotografías que representaron los sitios de verificación. Hubo casos en los que por el tamaño de la categoría, no se alcanzó este número, y se tomaron todas las fotografías disponibles. También se hizo un recorrido en campo con los mapas resultantes de la clasificación observando la correspondencia de las clases, sobretodo en las categorías donde quedó confusión al interpretar las fotografías aéreas o bien no hubo número suficiente de éstas para alguna categoría. En la figura 8, se presenta con puntos azules los centros de las fotografías aéreas utilizadas y en verde los puntos GPS tomados en campo.

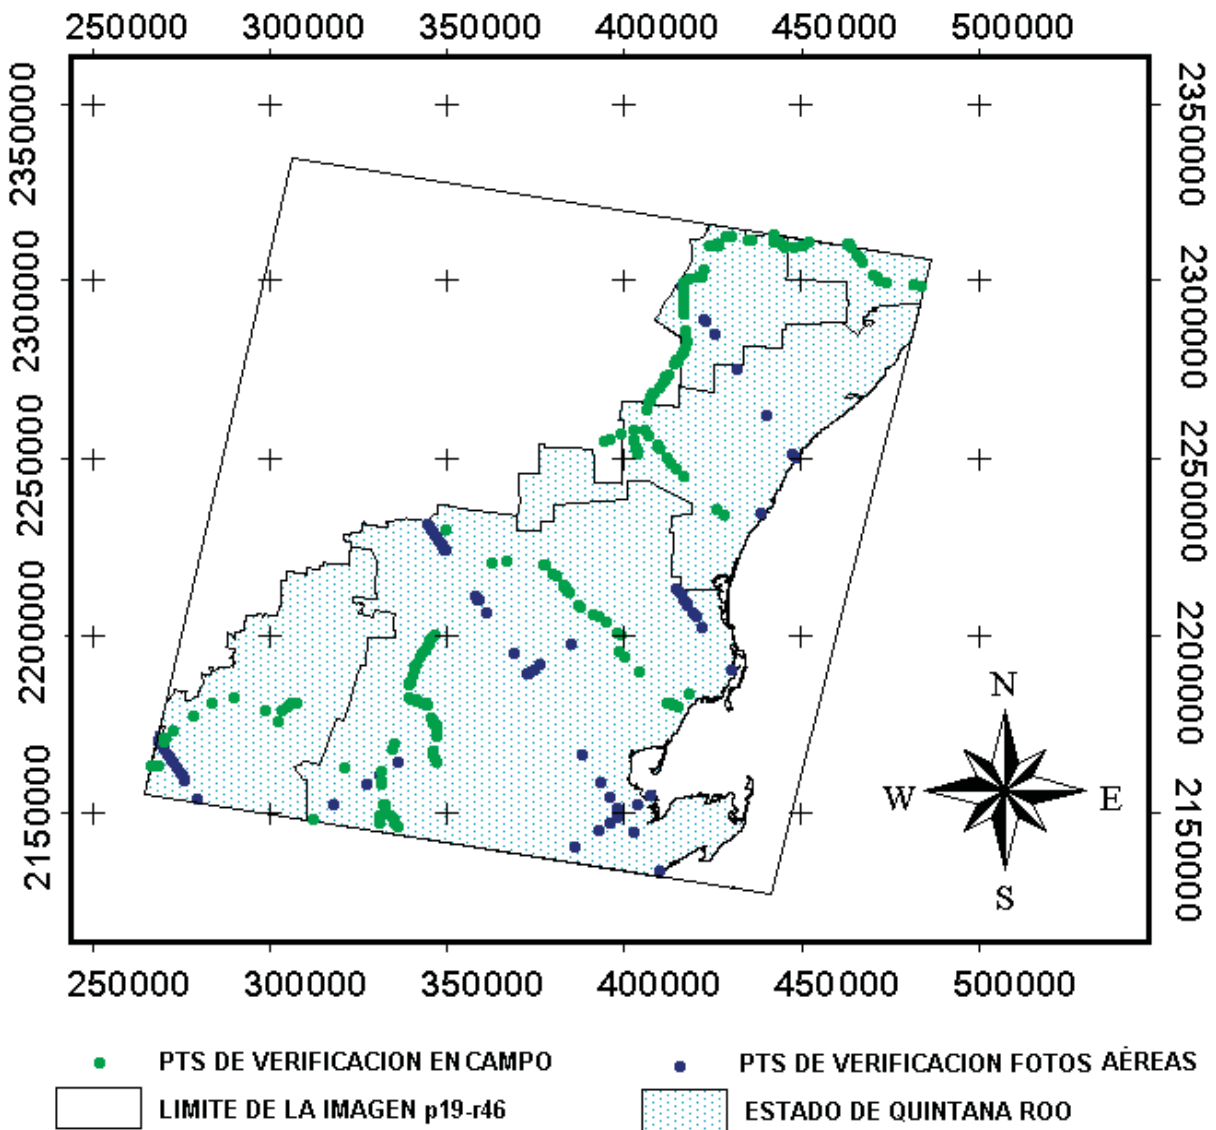


Fig. 8. Puntos de control utilizados en la validación.

Cada una de las fotografías se interpretó de manera visual, anotando en cada caso en la columna A la categoría de mayor superficie y la B la que le siguió en extensión. Con los valores obtenidos de las fotos aéreas se construyó la matriz de error, cruzando la información de los sitios de verificación representados por las fotos aéreas en la categoría A, con los sitios correspondientes en el mapa. A ésta se le denominó “matriz dura”.

Woodcock y Gopal (2000), consideran que el uso de conjuntos difusos en la validación expande la cantidad de información que puede proveerse (la naturaleza, frecuencia y magnitud y fuente de error) en un mapa temático. Los conjuntos difusos permiten niveles de pertenencia para múltiples categorías de mapa. Una escala lingüística permite que los comentarios que comúnmente se hacen de un mapa al evaluarlo puedan ser usados para evaluarlo cuantitativamente. Proponen que en lugar de una validación tradicional, en la cuál el resultado es totalmente correcto o erróneo (1 o 0), se use una calificación de 1 a 5, donde los valores representan desde una clasificación totalmente errónea, comprensible pero mal, una respuesta aceptable, una buena respuesta y una respuesta absolutamente correcta.

Los sitios de verificación de este trabajo son grandes, e incluyen varias categorías, lo que genera ambigüedad al confrontar las fotografías aéreas con el mapa clasificado. Además varias clases en cada foto tuvieron valores iguales o cercanos al 50%, y el hecho de que una de estas clases ocupara la primera casilla en importancia en realidad fue muy subjetivo. Dadas estas condiciones, se consideró adoptar el esquema descrito de Woodcock et al op cit (2000), y elaborar otra matriz de confusión esta vez aceptando la segunda categoría, o categoría B, en caso de que no coincidiera con la primera. A esta matriz se le denominó "matriz difusa".

En la realidad no todas las categorías tienen el mismo peso, ya que una categoría de mayor superficie, que resulte mal clasificada afectará más la confiabilidad global del mapa que una de pequeña superficie en la misma situación. Esto se agrava cuando, como es el caso, se tiene un número equivalente de puntos de control en cada una de las categorías. Para dar el peso correspondiente a cada clase dentro del mapa, de acuerdo a la superficie que ocupan, se empleó la corrección de Card (1982).

Suponiendo una matriz con j columnas, i líneas, n_{ij} es el número en cada celda, n_{+j} es la suma de las celdas de la columna j , Π_j es la proporción en el mapa de la categoría j , Card calcula cada elemento P_{ij} de la matriz corregida aplicando:

$$P_{ij} = \Pi_j n_{ij} / n_{+j}$$

5.2.7 Clasificación de la imagen SPOT VGT

Como primer paso se hizo una clasificación convencional mediante el algoritmo de máxima verosimilitud con los datos de baja resolución SPOT VGT usando campos de entrenamiento para 6 categorías. Posteriormente se hizo la clasificación con lógica difusa mediante los métodos difusos o de clasificación suave, uno basado en la teoría de Dempster Shapher, otro basado en la teoría de Bayes y otro basado en la de mínima distancia.

De manera adicional se usaron estos mismos tres clasificadores suaves, pero esta vez dando valores de probabilidad a priori para cada una de las categorías, restringiendo las áreas de distribución de cada una límites predefinidos, esto con el objetivo de evaluar si la fiabilidad aumenta mediante el uso de este tipo de datos auxiliares.

5.2.8 EVALUACIÓN Y COMPARACIÓN DE LOS CLASIFICADORES DIFUSOS.

Para la validación de la clasificación difusa de las imágenes SPOT VEGETATION, se creó una retícula de 1 Km², de acuerdo a los renglones y columnas de la imagen SPOT VGT, por lo que esta malla correspondió exactamente a los límites de cada píxel VGT. Esta malla se aplicó a la imagen ETM, calculando el porcentaje dentro de cada celda de cada clase como se muestra en la figura 9. La misma malla se usó para obtener los valores difusos de cada una de las imágenes de probabilidad arrojadas por cada uno de los clasificadores.

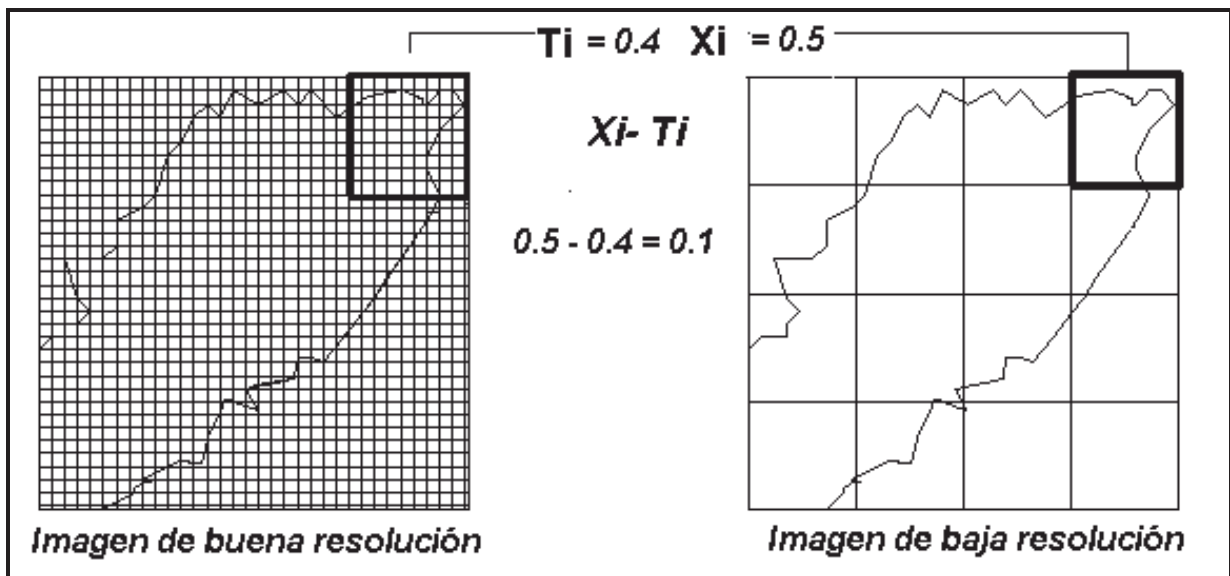


Fig.9. Comparación de la proporción (T_i) contra el valor difuso del píxel correspondiente (X_i)

Para evaluar el desempeño de los clasificadores difusos al estimar las proporciones dentro del píxel, se desarrollaron varias pruebas estadísticas las cuales se describen a continuación.

A. Cálculo del error medio cuadrático (RMS error)

Con los valores de porcentaje obtenidos de la clasificación de la imagen ETM y los valores difusos de la clasificación de la imagen SPOT VGT se construyeron tablas donde se relacionó cada valor difuso de un píxel con su proporción correspondiente. Previo al cálculo del error medio cuadrático se eliminaron de la tabla los valores con porcentaje de nube. De las tablas filtradas se obtuvo el Error Medio Cuadrático (EMC o RMS por sus siglas en inglés) para cada uno de los píxeles y cada una de las categorías para los tres clasificadores.

El error medio cuadrático se expresa como:

$$RMS = \sqrt{\frac{\sum_i (x_i - t_i)^2}{n}}$$

donde:

x_i es el valor difuso de pertenencia a una categoría, en un píxel VGT

t_i es la proporción real de los píxeles comprendidos dentro de una categoría

n es el número de datos a ser evaluados.

Se compararon los resultados de fiabilidad expresados como el RMS error para cada categoría, anotando los mejores resultados para cada clase y mayor número de clases correctamente clasificadas. Con esto podemos saber que clasificador es mejor en general, obteniendo una fiabilidad mayor, así como su capacidad de discriminación.

B Cálculo del error medio absoluto (MAE).

Con el objetivo de comparar los valores de error con otros resultados obtenidos en la bibliografía, se calculó también el error medio absoluto (MAE por sus siglas en inglés). Esta medida es el promedio de la suma total del valor absoluto de cada una de las diferencias entre el valor estimado y el verdadero.

Éste se expresa matemáticamente como:

$$MAE = \frac{1}{N_{pix}} \sum_{p=1}^{N_{pix}} \sum_{c=1}^{N_{clase}} |est_{p,k} - ver_{p,k}|$$

donde:

est es el valor difuso de la categoría estimado en la clasificación de la imagen SPOT

ver es la proporción de verdad obtenida de la clasificación de la imagen de referencia

Npix es el número de píxeles

Nclas es el número de clases.

Los rangos varían desde 0, donde habría una coincidencia perfecta, hasta 2, que sería el peor caso.

C. Distribución espacial del error

Con el objetivo de observar la distribución espacial del error, así como ubicar las áreas donde existe sobrestimación o subestimación de las proporciones, se calculó la diferencia entre el mapa de proporciones y el de valores difusos obtenidos para cada categoría.

D. Cálculo del coeficiente de correlación

La correlación mide la relación entre los valores de dos o más variables. En este caso nos interesa ver la correlación que existe entre las proporciones verdaderas (derivadas de la clasificación de Landsat) y los valores estimados (valores difusos de la clasificación de la imagen SPOT VGT).

El tipo de correlación utilizado fue una prueba linear bivariada de Pearson. Este coeficiente nos informa del grado de relación entre dos variables (decimos que ambas variables están correlacionadas). Si la relación es lineal perfecta, r será 1 ó -1. El coeficiente r será positivo si la relación es positiva (al aumentar x aumenta y), y r será negativo en el caso contrario (si al aumentar x , disminuye y). En general, valores (absolutos) de $r > 0,80$ se consideran altos, aunque esto depende del número de parejas de datos con las que hemos realizado el cálculo y del nivel de seguridad con el que queramos extraer nuestras conclusiones. Como indicación, para 11 parejas de datos, y si admitimos un 5% de posibilidades de equivocarnos, con $r > 0.553$ ya podemos decir que ambas series de datos no son independientes (parece que tienen algún tipo de relación). Si tuviéramos 50 parejas de datos, nos bastaría $r > 0.273$ para sacar la misma conclusión (siempre considerando el valor absoluto de r). Si nos ponemos más estrictos, y queremos sacar la conclusión de que las dos series no son independientes con un 99% de seguridad (sólo un 1% de posibilidad de error), con 11 parejas necesitamos que $r > 0.684$ y con 50 parejas $r > 0.354$ (San Román 2006).

VI. RESULTADOS Y DISCUSIÓN

6.1. CORRECCIÓN GEOMÉTRICA.

El metadato de la imagen reporta un error medio cuadrático de 0.75 con un registro de 40 puntos, mientras que la verificación de la georreferencia de la imagen ETM+ de 2000, mediante la coincidencia de 60 puntos, dio como resultado un error medio cuadrático de 31.38m, esto se debe a que para efectuar la verificación se utilizaron puntos diferentes a los elegidos para registrar la imagen, siendo una evaluación más “severa”.

En el caso de la imagen SPOT VGT se observó que los desfases no alcanzaron un píxel tanto en los límites de costa como en cuerpos de agua continentales y límites de ciudades por lo cual se asume que no existen errores graves atribuidos a la falta de coincidencia de los puntos en la comparación en ambas imágenes.

6.2 CAMPOS DE ENTRENAMIENTO.

Se marcaron 220 campos de entrenamiento, en 40 categorías, que corresponden a 17 clases, esto por la variación de las características espectrales dentro de una misma clase.

En la imagen SPOT VGT, se consideraron 3 subtipos de agua, ya que visualmente presentaron patrones distintos en el continente, en la plataforma continental y en alta mar. De igual manera, la selva mediana subperennifolia se dividió en tres subtipos. En total se marcaron 104 campos de entrenamiento en 12 subclases reclasificadas a las 6 categorías finales.

La matriz de confusión que se presenta a continuación muestra el cruce de los píxeles de los campos de entrenamiento (columnas), contra los píxeles clasificados mediante el método de máxima verosimilitud, de la imagen SPOT VGT (renglones). Se muestra mediante la suma de la diagonal entre el número total, que el **97%** de los píxeles muestreados se clasifican correctamente. En el cuadro 5 vemos los errores de comisión en renglones y los de omisión en columnas.

Cuadro 5. Matriz de error entre campos de entrenamiento e imagen clasificada.

MAPA C- ENTRE	AGRO	SMSP	SMSP2	SMSP3	SMSC	MANGLE	HIDRO	NUBE	AGUA	AGUA2	AGUA3	TOTAL	F PR
AGRO	237	0	0	7	0	0	1	0	0	0	0	245	97%
SMSP	0	136	0	2	0	0	0	0	0	0	0	138	99%
SMSP2	0	0	154	0	0	0	0	0	0	0	0	154	100%
SMSP3	8	1	0	69	3	0	0	0	0	0	0	81	85%
SMSC	0	0	3	5	130	0	0	0	0	0	0	138	94%
MANGLE	0	0	0	0	0	31	5	0	0	0	0	36	86%
HIDRO	1	0	0	0	0	0	86	0	0	0	0	87	99%
NUBE	0	0	0	0	0	0	0	156	0	0	0	156	100%
AGUA	0	0	0	0	0	0	0	0	114	0	0	114	100%
AGUA2	0	0	0	0	0	0	0	0	0	168	0	168	100%
AGUA3	0	0	0	0	0	0	0	0	6	4	27	37	73%
TOTAL	246	137	157	83	133	31	92	156	120	172	27	1354	
F US	96%	99%	98%	83%	98%	100%	94%	100%	95%	98%	100%		96%

C-ENTRE.: campos de entrenamiento, F PR.: Fiabilidad del productor F-US Fiabilidad del usuario
 AGRO.: agropecuario, SMSP.: selva mediana subperennifolia, SMSC.: selva mediana subcaducifolia,
 HIDRO.: vegetación hidrófila.

Se observa en la matriz que, de un total de 50,244 píxeles que tiene la imagen SPOT VGT se muestrearon 1354 píxeles, que representan el 2.97% de la imagen. De los píxeles muestreados 46 (el 3.4 %), presentaron incongruencia al clasificarse, sin embargo, 11 de estos se clasificaron dentro de alguna subcategoría de la misma clase (10 en el caso del agua y 1 de selva mediana subperennifolia), por lo que representan resultados aceptables.

6.3 ANÁLISIS DE SEPARABILIDAD DE FIRMAS

6.3.1. Resultados para la imagen SPOT VGT

El coeficiente de separabilidad en el caso de las firmas generadas con los campos de la imagen SPOT VGT utilizando todas las bandas, fue óptimo para la mayoría de las comparaciones pareadas, con un valor de 2000, que es el valor máximo del índice de divergencia transformada.

En el cuadro 6 presentado a continuación aparecen solo las categorías cuyos coeficientes de separabilidad promedio fueron inferiores a 2000, en las comparaciones pareadas entre las diferentes clases. Tomando en cuenta que el máximo es de 2000 de acuerdo al índice de divergencia transformada (TD), así como los rangos propuestos en la metodología, en general tenemos una muy buena separabilidad. El único valor considerado como regular es el de la comparación entre la selva mediana subperennifolia (subtipo 3), con la selva mediana subcaducifolia; sin embargo al aumentar los campos de entrenamiento en ambas categorías se presentó mayor confusión, menos congruencia y menos separabilidad, por lo cuál se continuó el procedimiento con los campos originales.

Cuadro 6. Coeficiente Separabilidad promedio de firmas de la imagen SPOT VGT.

CLASE 1	CLASE 2	SEPARABILIDAD (INDICE TD)
SBSP3	AGRO	1989
AGRO	SMSC	1998
AGRO	HIDRO	1977
SMSP	SMSC	1990
SMSP2	SMSC	1956
SMSP3	SMSC	1821
	PROMEDIO	1992

6.3.2 Resultados para la imagen Landsat ETM+

El análisis de separabilidad se aplicó también para la imagen de referencia (ETM+). En la siguiente tabla se puede apreciar que al aumentar el número de bandas se mejora la separabilidad, aunque la diferencia de los valores entre 5 y 6 bandas es casi nula, tal como se muestra en la fig. 10.

Seis bandas es un número bastante aceptable para los procesos de clasificación, por lo que todas se usaron en la clasificación, contando con un resultado de separabilidad promedio de las clases de TD=1958, como se muestra en el cuadro 7. Este valor se considera como buena separabilidad.

Cuadro 7. Valores de separabilidad de las bandas de la imagen de referencia

NUMERO DE BANDAS	MEJOR COMBINACIÓN	SEPARABILIDAD (ÍNDICE DE TD)
1	3	1526
2	3-4	1808
3	3-4-5	1899
4	3-4-5-6	1933
5	2-3-4-5-6	1950
6	TODAS	1958




Fig.10. Separabilidad (Divergencia Trasformada) de las firmas de los campos de entrenamiento del mapa de referencia de acuerdo al número de bandas utilizadas

Con el objetivo de analizar visualmente y de corroborar los resultados del índice de la divergencia transformada, se hizo una comparación cualitativa de las firmas que resultaron con valores por debajo del máximo de separabilidad. Se obtuvieron las siguientes gráficas de la comparación pareada de las firmas de clases con confusión (las cajas muestran los valores mínimo y máximo de cada firma espectral).

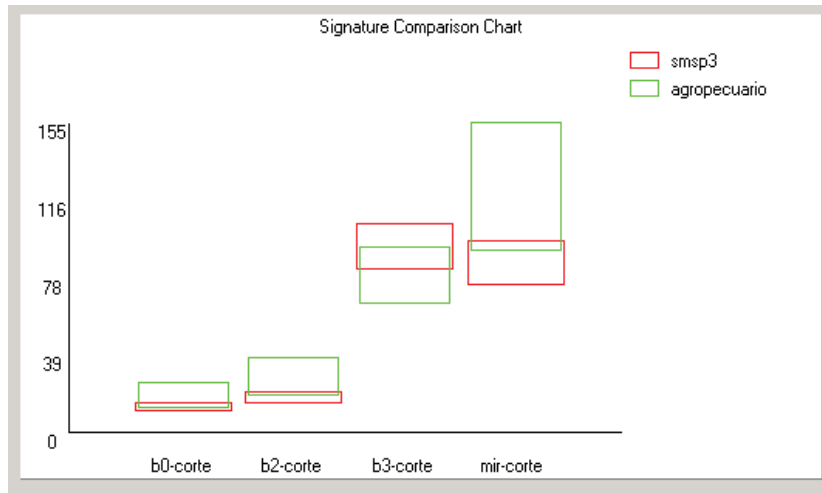


Fig.11. Comparación de firmas de selva mediana subperennifolia Vs. agropecuario.

En la figura 11 se observa que hay un traslape de las firmas espectrales, entre las clases de selva mediana subperennifolia (subtipo 3) y agropecuario. La media fue distinta en todas las bandas, y en ninguna banda coincide de manera exacta el mínimo y el máximo; de cualquier modo, no se separan por completo en ninguna de las cuatro bandas.




Fig. 12. Comparación de firmas de agropecuario Vs. selva mediana subcaducifolia

En la figura 12 se puede observar que las firmas espectrales de la agricultura y de la selva mediana subcaducifolia presentan un traslape en la banda 0. En la banda MIR hay un traslape y en la banda tres coincide el límite máximo de la selva con el mínimo del agropecuario; sin embargo se separan completamente en la banda 3.

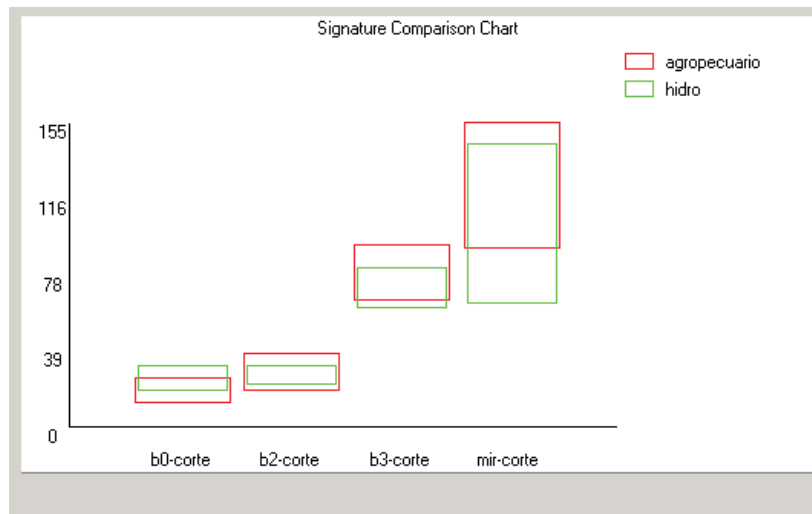


Fig.13. Comparación de firmas de agropecuario vs. vegetación hidrófila

En la figura 13 se observa que la clase agropecuario se traslapa con la vegetación hidrófila en todas las bandas; la media es distinta en las bandas 0, 3 y MIR, pero coincide en la banda 2.

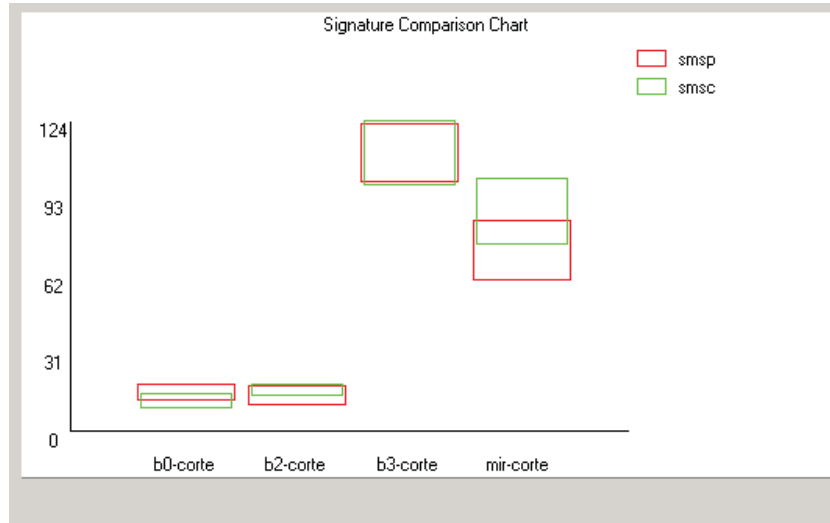


Fig. 14. Comparación de firmas de selva mediana subperennifolia Vs. selva mediana subcaducifolia

En la figura 14 observamos que las firmas de las selvas mediana subperennifolia y subcaducifolia coinciden casi totalmente en la banda 3, y presentan una alta similitud en las bandas 1 y 2.

En general podemos decir que la categoría denominada como “agropecuario” es la que se presta más a confusión con las diferentes categorías, debido que esta clase presenta una firma espectral multimodal y abarca un rango amplio de valores espectrales.

Aún cuando los valores de separabilidad son buenos, debe tenerse en cuenta que este cálculo se hace para las firmas espectrales generadas con campos que se eligieron por ser homogéneos, con una pertenencia casi absoluta para cada una de las clases (píxeles puros); los píxeles mezclados no presentan esta separabilidad, así que los resultados deben tomarse con esta precaución.

6.4 CLASIFICACIÓN Y EVALUACIÓN DE LA IMAGEN DE REFERENCIA

La imagen de referencia, clasificada con datos auxiliares representados por imágenes de probabilidad reclasificada a las 6 clases de interés, se muestra en la figura 15.

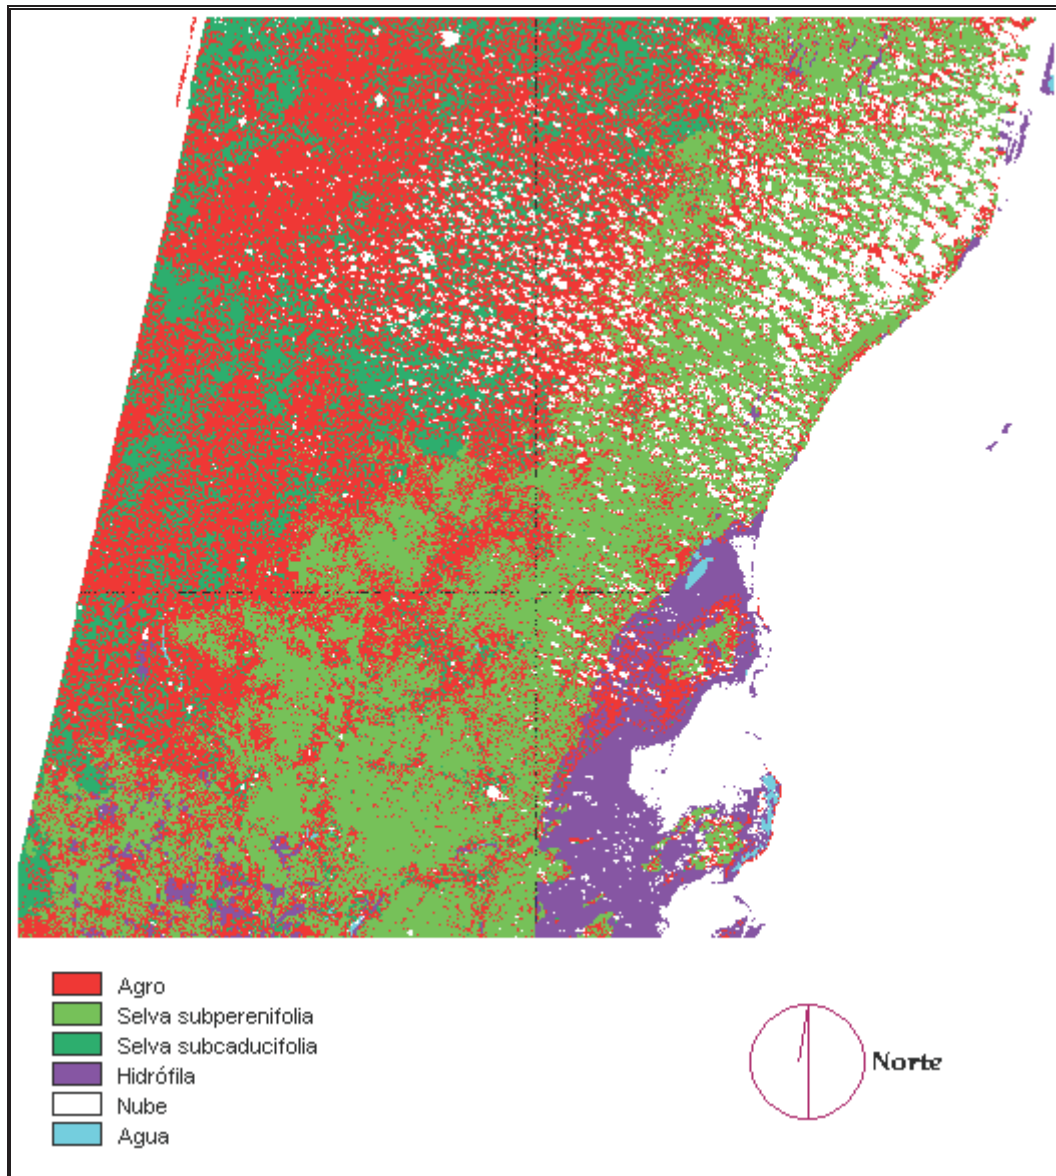


Fig. 15 Clasificación de la imagen de referencia (Landsat ETM) con valores a priori, reclasificada a 6 categorías.

Con los valores obtenidos de la interpretación de las fotos aéreas, que representaron la verdad, y los obtenidos del mapa de máxima verosimilitud, se generó la matriz de confusión presentada en el cuadro 8. Esta tabla es la evaluación tomando en cuenta sólo la categoría de mayor porcentaje, por lo que la llamamos matriz “dura”, con una suma de la diagonal de 136 de los 169 totales. Los valores de las fotos aéreas se presentan en líneas y los del mapa en columnas

Cuadro 8. Matriz “dura” de fiabilidad de la imagen Landsat ETM

MAPA \ SITIO-VER	AGUA	HIDRO	AGRO	SBMSP	SMSC	TOTAL	F-PR
AGUA	10	2				12	83%
HIDRÓFILA	3	34		1		38	89%
AGRO			16	8	2	26	61%
SBMSP	3	8	2	68		81	84%
SMSC			1	3	8	12	67%
TOTAL GENERAL	16	44	19	80	10	169	
F US	62%	77%	84%	85%	80%		80%

SITIO VER.: Sitios de verificación

A esta matriz se le aplicó la corrección de Card (1982), de acuerdo a las proporciones de superficie por categoría, mostradas en el cuadro 9, obtenidas mediante el cálculo de estadísticas del mapa.

Cuadro 9. Porcentaje por clase en el área de estudio

Cobertura	Superficie km ²	Porcentaje
AGRO	15,841	36.67%
AGUA	78	0.18%
HIDRO	1,687	3.90%
SMSC	6,616	15.31%
SBMSP	18,981	43.93%
TOTAL	43,203	100.00%

De acuerdo a estos valores, la clase con mayor superficie y por tanto con mayor peso es la selva baja y mediana subperennifolia, seguida por el agropecuario, que juntos representan casi el 70% de la superficie total del área de estudio. La clase con menos superficie está representada por los cuerpos de agua continentales.

Cuadro 10. Matriz “dura” de fiabilidad de la imagen Landsat ETM aplicando el método de ponderación propuesto por Card (1982).

MAPA \ S-VER	AGUA	HIDRO	AGRO	SBMSP	SMSC	TOTAL	FIABILIDAD Productor
AGUA	0.009	0.006				0.015	60%
HIDRÓFILA	0.003	0.100		0.002		0.105	95%
AGRO			0.265	0.017	0.075	0.356	74%
SBMSP	0.003	0.024	0.033	0.143		0.202	70%
SMSC			0.016	0.006	0.298	0.321	92%
TOTAL	0.014	0.130	0.314	0.168	0.373	1	
FIABILIDAD	62%	77%	84%	85%	80%		82%

Al aplicar esta corrección vemos que debido que el error de las categorías de mayor superficie es menor, la fiabilidad global aumenta un 2%.

Cuadro 11. Matriz “difusa” de fiabilidad de la imagen Landsat ETM

MAPA \ S-VER	AGUA	HIDRO	AGRO	SMSC	SMSP	TOTAL	F-PR
AGUA	13	1				14	93%
HIDRÓFILA	2	42				44	96%
AGRO		1	18		6	25	72%
SMSC				10	2	12	83%
SMSP	1		1		60	62	97%
TOTAL	16	44	19	10	68	157	
F-US	81%	95%	95%	100%	88%		91%

De igual manera se aplicó la corrección de Card (1982). En la matriz obtenida, la fiabilidad global aumenta un 2% con respecto a la matriz sin ponderar y un 11% con respecto a la matriz “dura”.

Cuadro 12. Matriz de fiabilidad “difusa” e la imagen Landsat ETM aplicando el método de ponderación propuesto por Card (1982).

MAPA \ S-VER	AGUA	HIDRÓFILA	AGRO	SMSC	SMSP	TOTAL	F-PR
AGUA	0.012	0.003	0.000	0.000	0.000	0.015	80%
HIDRO	0.002	0.124	0.000	0.000	0.000	0.126	99%
AGRO	0.000	0.003	0.298	0.000	0.033	0.334	89%
SMSC	0.000	0.000	0.000	0.168	0.011	0.179	94%
SMSP	0.001	0.000	0.017	0.000	0.329	0.347	95%
TOTAL GENERAL	0.015	0.130	0.314	0.168	0.373	1.000	
F-US	81%	95%	95%	100%	88%		93%

Como podemos observar es que ambos métodos, el tradicional o “duro” y la consideración difusa, nos dan un rango de fiabilidad. El primer enfoque es muy rígido al calificar el mapa pudiendo subestimar la confiabilidad del mapa clasificado, mientras que el segundo puede llegar a ser demasiado “flexible”.

Podemos ver que en general, las clases tienen una fiabilidad suficientemente buena para ser tomadas como referencia al comparar los valores difusos del análisis de clasificación suave.

6.5 CLASIFICACIÓN Y EVALUACION DE LA FIABILIDAD DE LA IMAGEN SPOT VGT

De la clasificación de máxima verosimilitud de la imagen SPOT VGT se obtuvo el mapa mostrado en la figura 16, el cuál se comparó con la imagen de referencia (Landsat ETM).

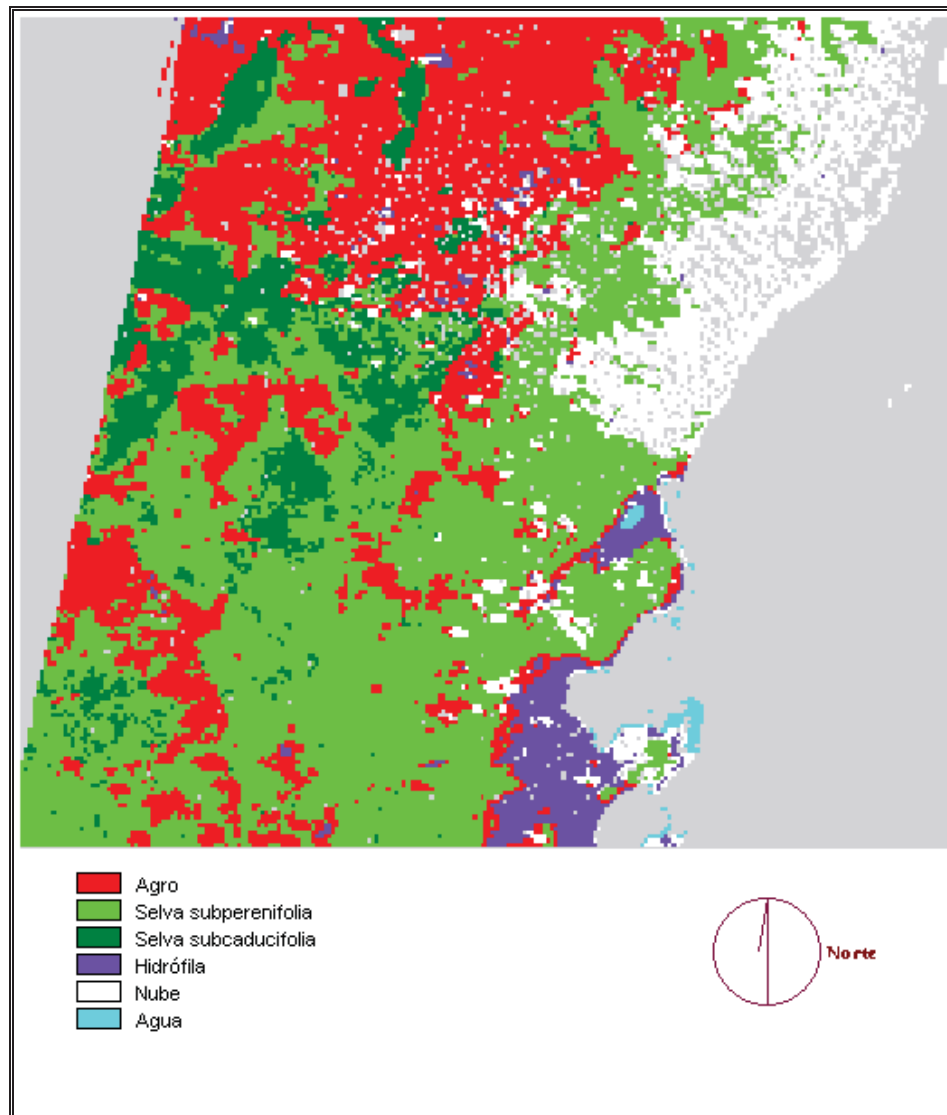


Fig. 16. Imagen SPOT VGT clasificada mediante el método de máxima verosimilitud

De la evaluación de la fiabilidad, resultado de la comparación de cada píxel de la imagen SPOT VGT clasificada mediante el algoritmo de máxima verosimilitud y los porcentajes de mayoría en cada kilómetro cuadrado de la imagen de menor resolución (Landsat ETM), se obtuvieron los datos de fiabilidad para cada categoría mostrados en el cuadro 13.

Cuadro 13. Matriz de fiabilidad de la clasificación de máxima verosimilitud del producto SPOT VGT.

SPOT ETM	AGRO	SMSP	SMSC	HIDRO	AGUA	Total	F-PR
AGRO	168	3419	350	181	1	4119	4.08%
SMSP	108	13207	48	91	0	13454	98.16%
SMSC	28	1226	3	3	0	1260	0.24%
HIDRO	3	109	5	1043	2	1162	89.76%
AGUA	0	0	0	102	16	118	13.56%
Total	307	17961	406	1420	19	20113	
F-US	54.72%	73.53%	0.74%	73.45%	84.21%		71.78%

La categoría con mayor confiabilidad fue la selva mediana subperennifolia, esto puede atribuirse a que es la categoría de mayor área, además de que presenta una superficie más bien continua.

La selva mediana subcaducifolia presenta los peores resultados de fiabilidad; esto puede deberse a que se marcaron pocos campos de entrenamiento y éstos fueron de tamaño pequeño al ser difícil de localizar áreas homogéneas en la imagen. Estos resultados son de esperarse ya que aún en campo es difícil decidir si se trata de selva mediana subcaducifolia o subperennifolia ya que en esta zona el porcentaje es cercano al 50% de cada una.

La vegetación hidrófila presentó confusión con el agua, lo que puede deberse a que son categorías de superficie pequeña con un gran número de píxeles mezclados en los bordes de los cuerpos de agua.

Los peores resultados se dan para la agricultura, con un gran número de píxeles clasificados como selva mediana subperennifolia, lo que puede darse por píxeles mezclados que se ven “obligados” a clasificarse por su mayor parecido a una sola clase. En general la selva tendrá mayor oportunidad de “ganar” píxeles por ocupar mayor superficie, sobretodo cuando se localizan entre los límites de una categoría y otra. La confusión entre la selva subcaducifolia y la agricultura puede deberse a su similitud espectral, difícil de distinguir aun en imágenes de menor resolución.

6.6 CLASIFICACION DIFUSA

A continuación se presentan las imágenes difusas obtenidas por cada uno de los clasificadores para cada categoría, así como las verdaderas proporciones derivadas de la imagen ETM para cada una de las categorías. Las tonalidades del gris varían desde el blanco, que representa respectivamente el 100% de pertenencia o de proporción de la categoría en la imagen, hasta el negro que representa el 0%.

Las proporciones del agropecuario, presentadas en la figura 16, es una de las categorías de mayor superficie en la imagen. Podemos ver que los resultados del clasificador basado en la teoría de Bayes tienden a sobreestimar las proporciones; por el contrario, Dempster Shapher tiende a subestimarlas. El resultado que parece más acertado, por lo menos de manera visual, es el basado en la distancia.

A. Agropecuario

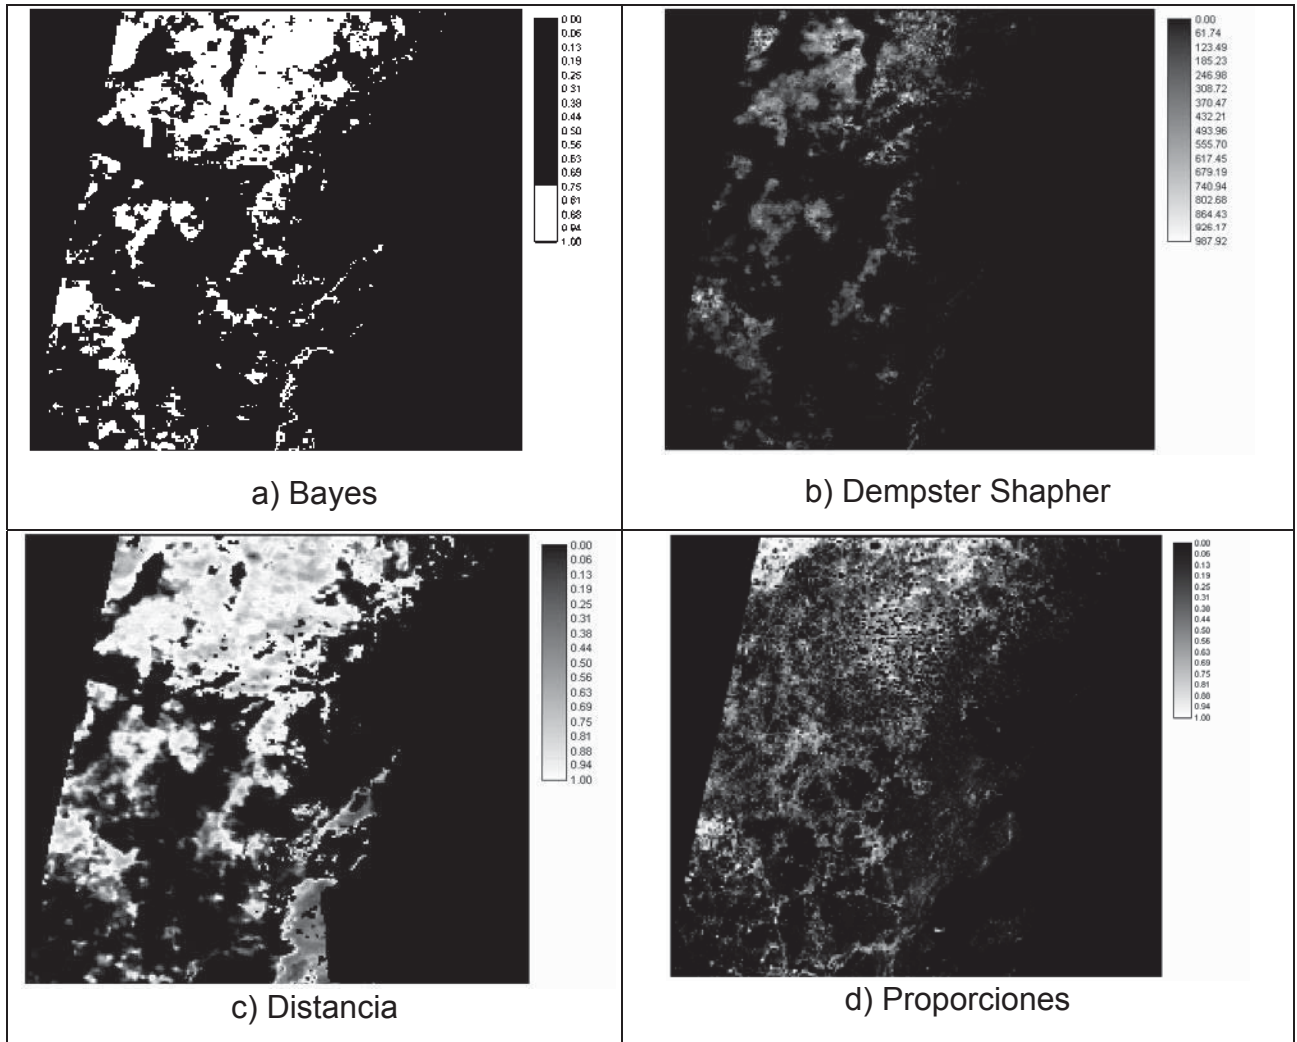


Fig. 16 Valores difusos de la categoría agropecuario en a) la teoría de Bayes, b) la teoría de Dempster Shapher c) distancia y d) proporciones en la imagen de referencia.

b) Vegetación hidrófila

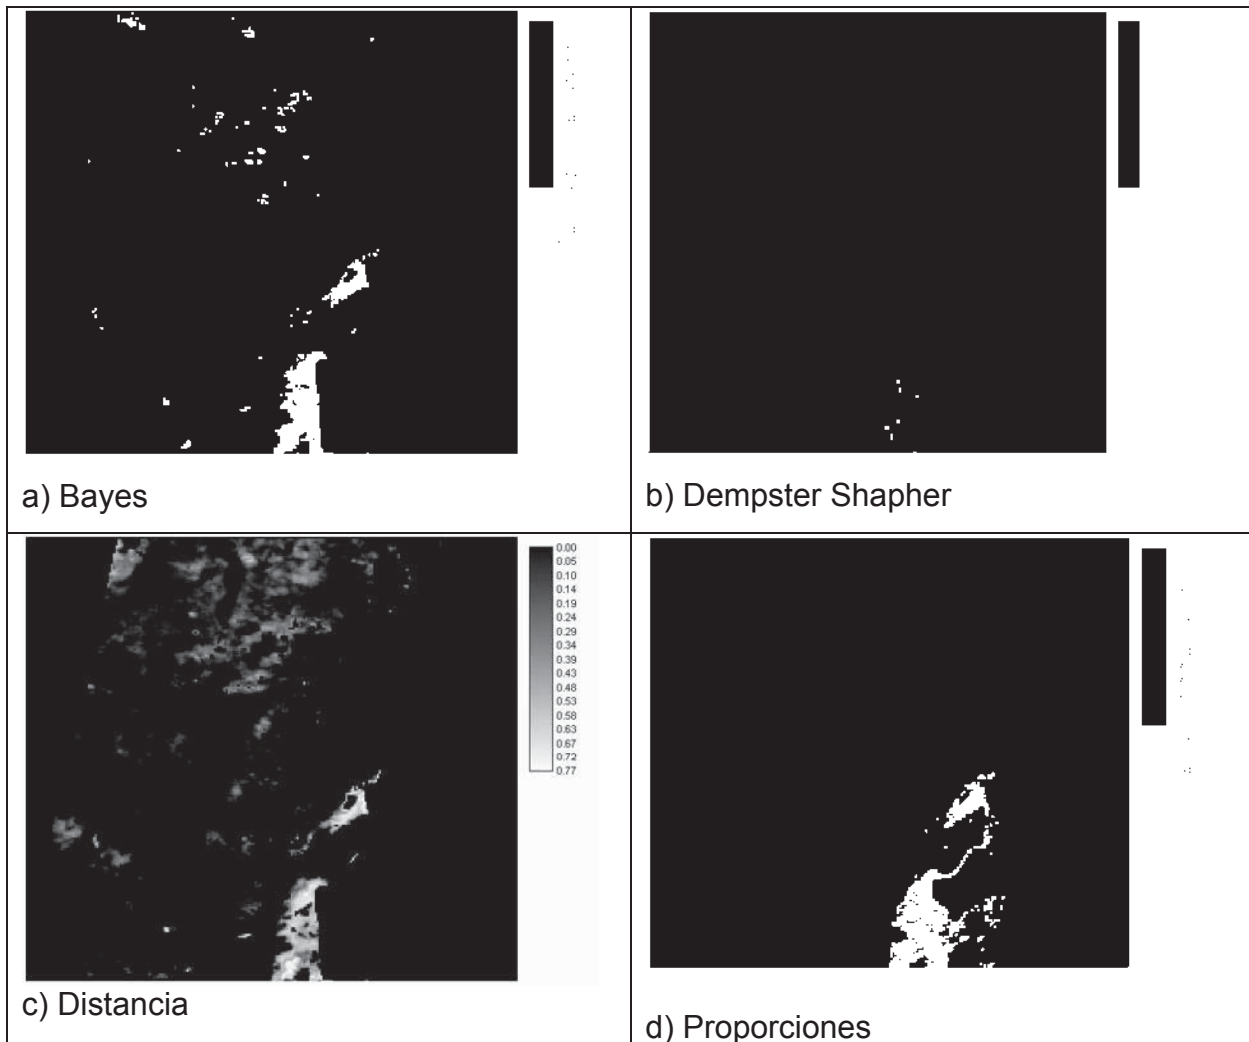


Fig. 17 Valores difusos de la categoría vegetación hidrófila en a) la teoría de Bayes, b) la teoría de Dempster Shapher c) distancia y d) proporciones en la imagen de referencia.

En la figura 17, se observa que la proporción derivada del clasificador basado en la teoría de Bayes es acertada en la región donde se encuentra realmente, pero marca vegetación hidrófila en la parte norte de la imagen donde no existe. El clasificador de Dempster Shapher subestima mucho esta categoría y el basado en la distancia marca valores de proporción en regiones donde no se encuentra aunque con valores bajos, pero también subestima en la región donde sí se encuentra respecto a las verdaderas proporciones.

B. Selva mediana subcaducifolia

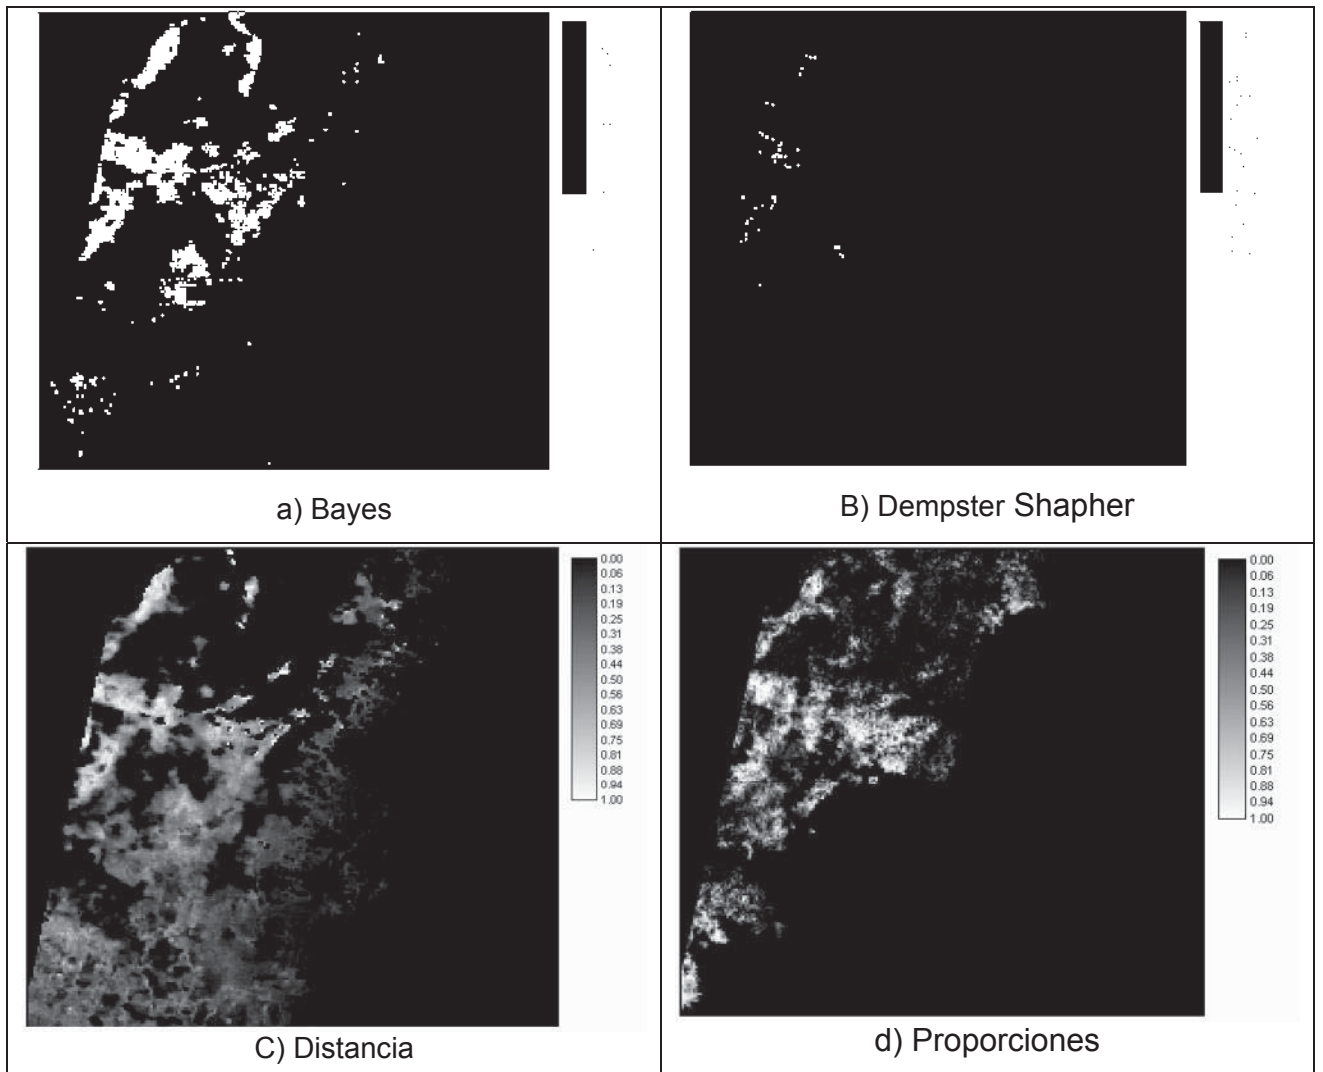


Fig. 18 Valores difusos de la categoría selva mediana subperennifolia en a) la teoría de Bayes, b) la teoría de Dempster Shapher c) distancia y d) proporciones en la imagen de referencia.

La selva mediana subcaducifolia sigue el mismo patrón descrito para la categoría anterior, como se muestra en la figura 18. La clasificación basada en la teoría de Bayes parece la que más coincide con el área correcta, pero se sobreestiman los valores de proporción, en Dempster Shapher estima proporciones solo en los píxeles con valores cercanos a la media y en el método basado en la distancia sobreestima el área de distribución, aunque con valores pequeños de proporción en estas áreas.

c) SELVA BAJA Y MEDIANA SUBPERENNIFOLIA

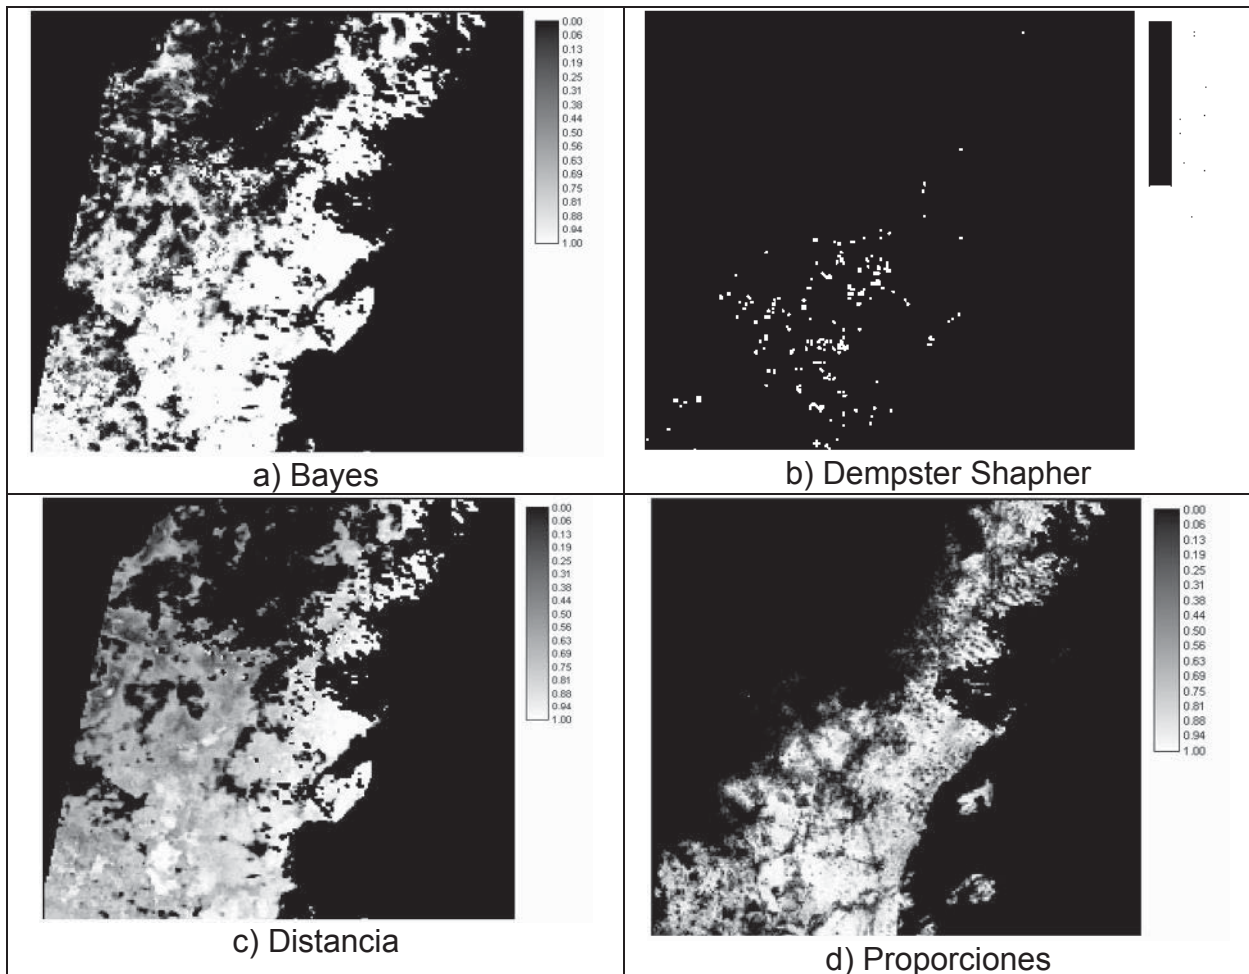


Fig. 19 Valores difusos de la categoría selva mediana subcaducifolia en a) la teoría de Bayes, b) la teoría de Dempster Shapher c) distancia y d) proporciones en la imagen de referencia.

En la figura 19, vemos una región al norte de la imagen donde los tres clasificadores fallan al detectar las proporciones de la selva mediana subperennifolia; en el resto de la imagen siguen el mismo patrón descrito anteriormente.

6.7 EVALUACIÓN Y COMPARACIÓN DE LOS CLASIFICADORES DIFUSOS

6.7.1 Cálculo del error medio cuadrático

El error medio cuadrático (RMS) para cada categoría en cada uno de los clasificadores se muestra en el cuadro 14; se destacan en negritas los errores más bajos.

Cuadro 14. Error obtenido para cada categoría en cada uno de los clasificadores evaluados.

RMS	BAYES	DS	DISTANCIA
AGRO	37.00%	26.00%	37.00%
AGUA	3.00%	2.00%	13.00%
HIDRO	14.00%	19.00%	15.00%
SMSC	39.00%	37.00%	31.00%
SMSP	22.00%	18.00%	18.00%
PROMEDIO	23.00%	20.40%	22.80%

RMS.: Error medio cuadrático, DS.: Dempster Shapher.

El resultado del cálculo del RMS ERROR nos muestra que al calcular los valores de error en todos los píxeles de la imagen, comparados con los valores de referencia, el clasificador basado en la teoría de Bayes es el que permitió obtener los mejores resultados al clasificar la vegetación hidrófila. El clasificador basado en la teoría de Dempster Shapher obtuvo los valores de error más pequeños para la categoría de agropecuario, así como para el agua y la selva mediana subperennifolia. En esta última, el mismo resultado se obtuvo para el clasificador de la distancia, siendo éste el que presenta el mayor número de categorías mejor clasificadas. Por último, el clasificador basado en la distancia obtuvo mejores resultados al obtener el error más bajo en la selva mediana subcaducifolia.

Vemos que los rangos de error varían en el clasificador de la distancia de 13% al 37%, poco más de lo obtenido por Atkinson et al. (1996) (de 13% a 23%) con ésta misma técnica en imágenes AVHRR en cuatro categorías, el error que Atkinson obtuvo puede deberse a que las categorías a discriminar en su estudio no presentan una similitud espectral comparable a las categorías a discriminar en este estudio.

En el caso del estudio realizado por Haglund (2000), los promedios que obtuvo fue, en el caso del clasificador basado en la teoría de Bayes 36%, en el basado en la teoría de Dempster Shapher de 44% y en el basado en la distancia 37%. Comparando con sus resultados obtuvimos 13% menos de error en el primero, 24% en el segundo y 14% en el tercero. Si bien Haglund (2000) consideró tres clases más, las imágenes con las que trabajó son de mucha menor resolución (150 m contra las SPOT VGT de un kilómetro).

Como vemos en esta comparación los resultados obtenidos del error medio cuadrático se encuentran dentro de lo esperado al analizar estudios similares publicados.

6.7.2 Cálculo del Error medio Absoluto

De manera adicional se calculó el error medio absoluto con el objetivo de comparar los resultados obtenidos con los publicados en la literatura.

Cuadro 15. Error medio absoluto obtenido para cada categoría en cada uno de los clasificadores evaluados.

	BAYES	DS	DISTANCIA
AGRO	0.25	0.17	0.26
AGUA	0.00	0.00	0.03
HIDRO	0.02	0.04	0.05
SMSC	0.23	0.21	0.20
SMSP	0.09	0.07	0.10
PROMEDIO	0.25	0.17	0.26

Comparando los resultados obtenidos con los obtenidos por Swinnen (2000) con el mismo tipo de imágenes para tres categorías vemos que mediante el uso de redes neuronales obtiene un error medio cuadrático promedio de 0.38, por lo que los resultados obtenidos en este estudio son mejores al obtener valores hasta 0.21 menores en el caso del clasificador basado en la distancia que representaría 11% de mejoría ya que los valores del MAE varían en un rango de 0 a 200%.

6.7.3 Distribución espacial del error

Para visualizar la distribución espacial del error se hicieron mapas en los que se restó al valor de verdad los valores difusos obtenidos por cada uno de los clasificadores, de esta manera aparecen en blanco y en negro los errores del 100% (respectivamente sub y sobre evaluación de la proporción por parte del clasificador) y en gris las regiones donde el error resultó ser menor.

A. Agropecuario

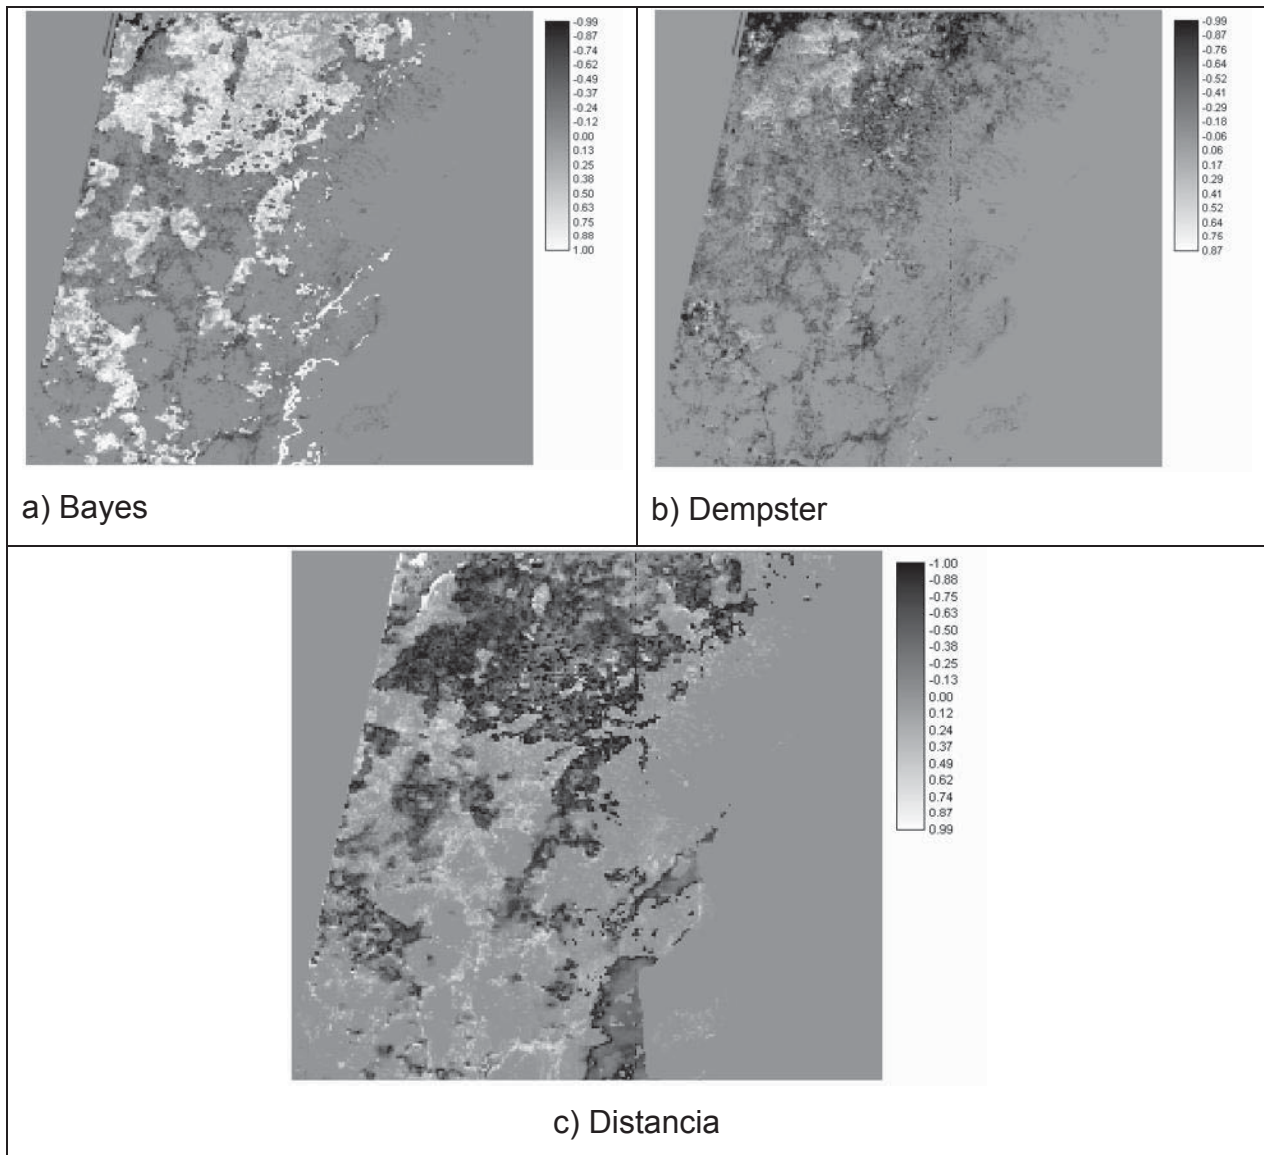


Fig.20 Distribución del error en la estimación de la proporción de la categoría agropecuario para a) la teoría de Bayes, b) la teoría de Dempster Shapher y c) Distancia

B. Vegetación Hidrófila

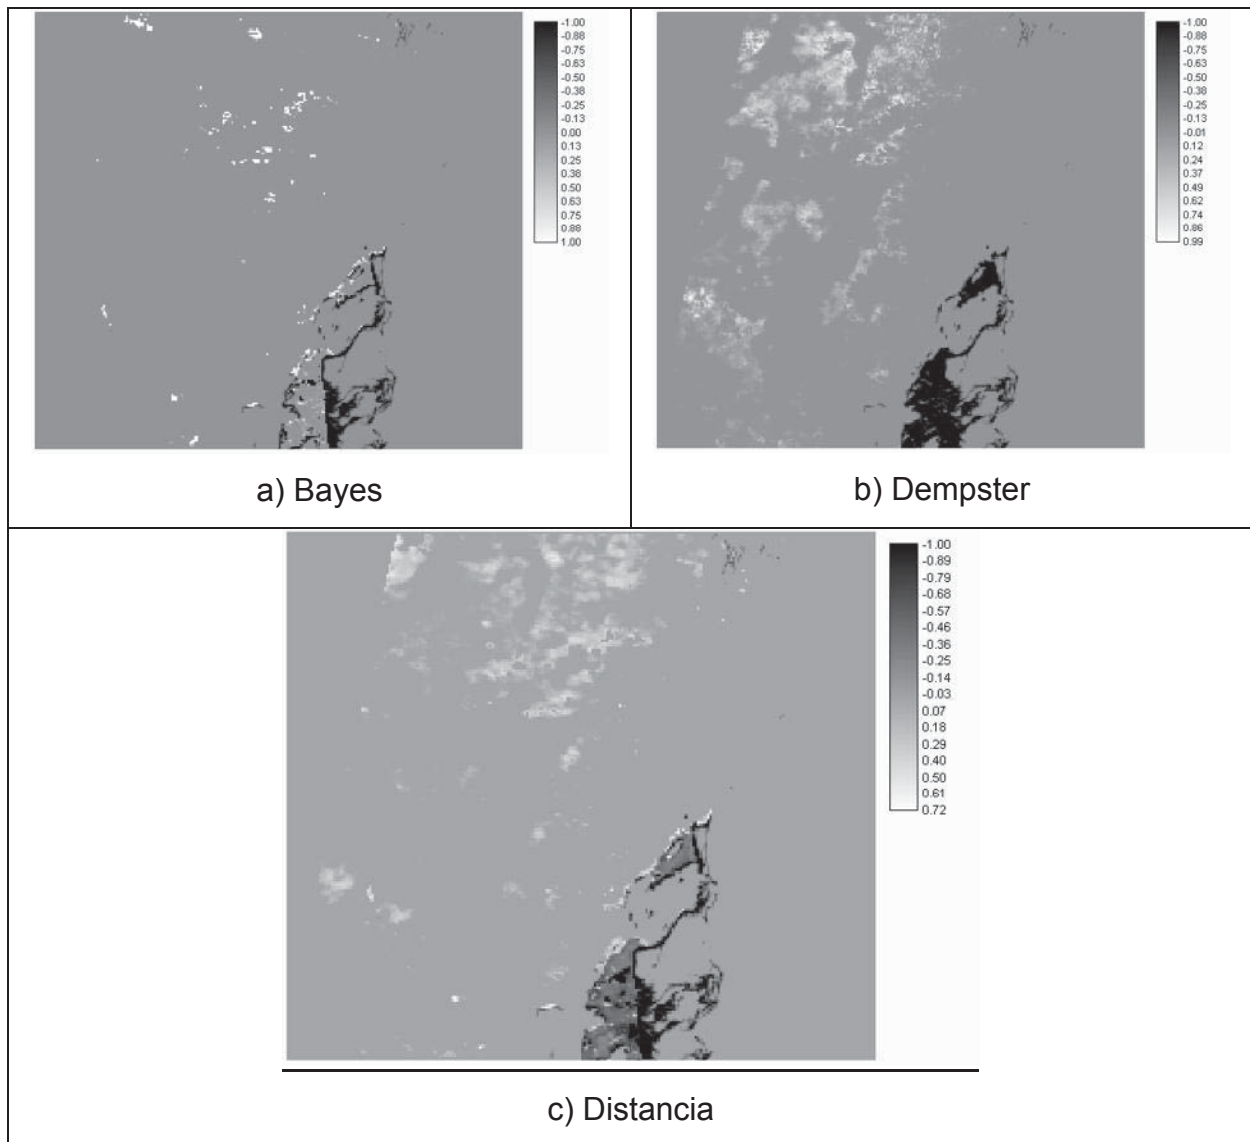


Fig. 21 Distribución del error en la estimación de la proporción de la categoría vegetación hidrófila para a) la teoría de Bayes, b) la teoría de Dempster Shapher y c) Distancia

C. Selva mediana subcaducifolia.

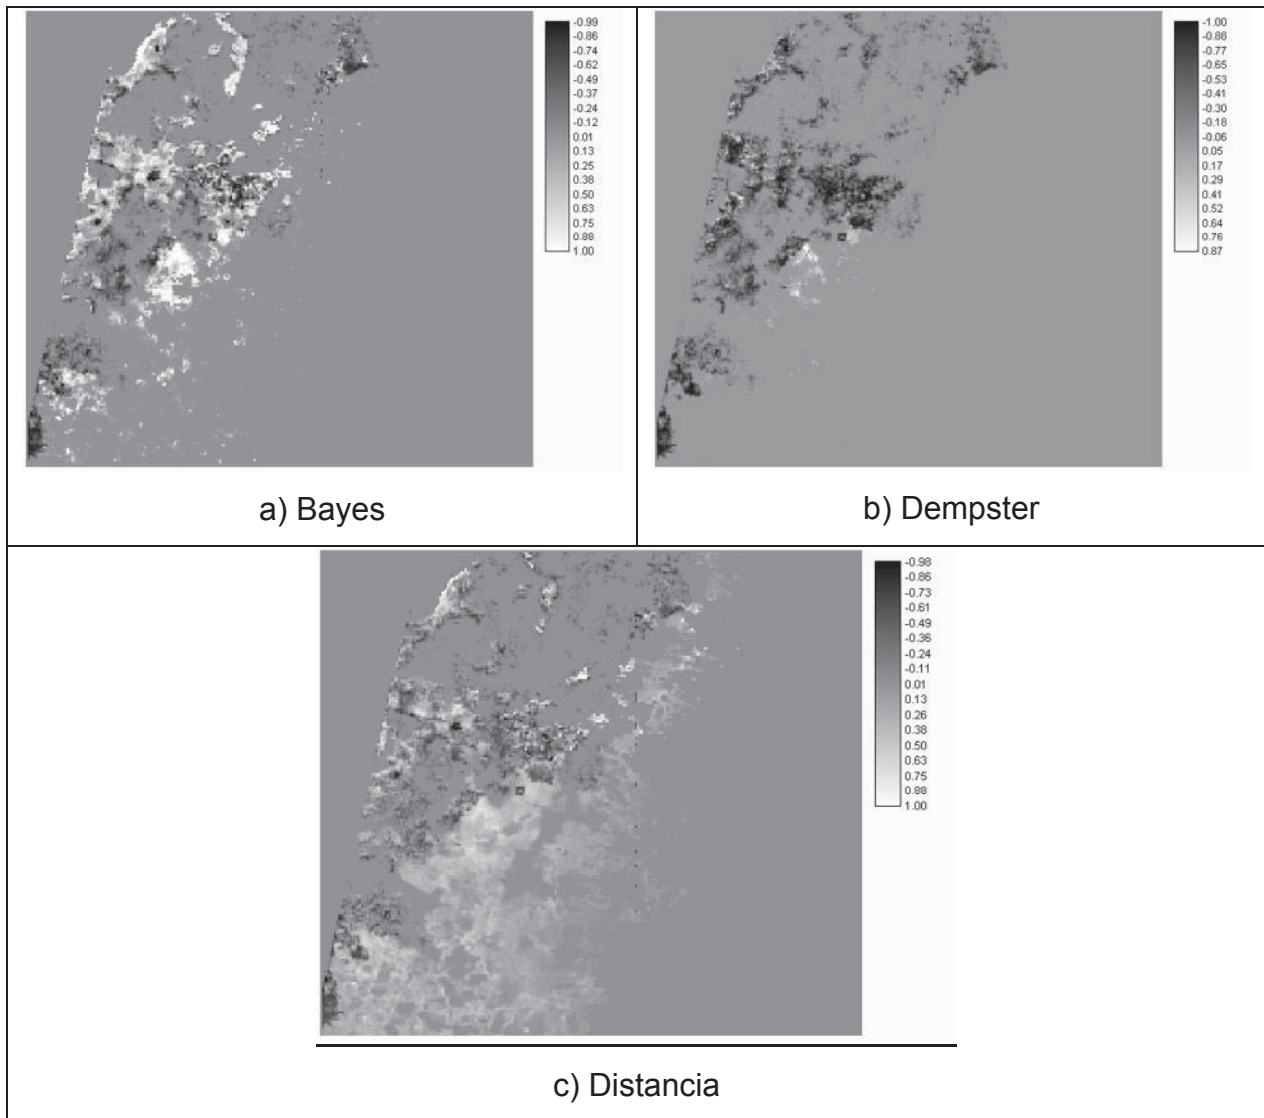


Fig. 22 Distribución del error en la estimación de la proporción de la categoría selva mediana subcaducifolia para a) la teoría de Bayes, b) la teoría de Dempster Shapher y c) Distancia

D. Selva mediana subperennifolia

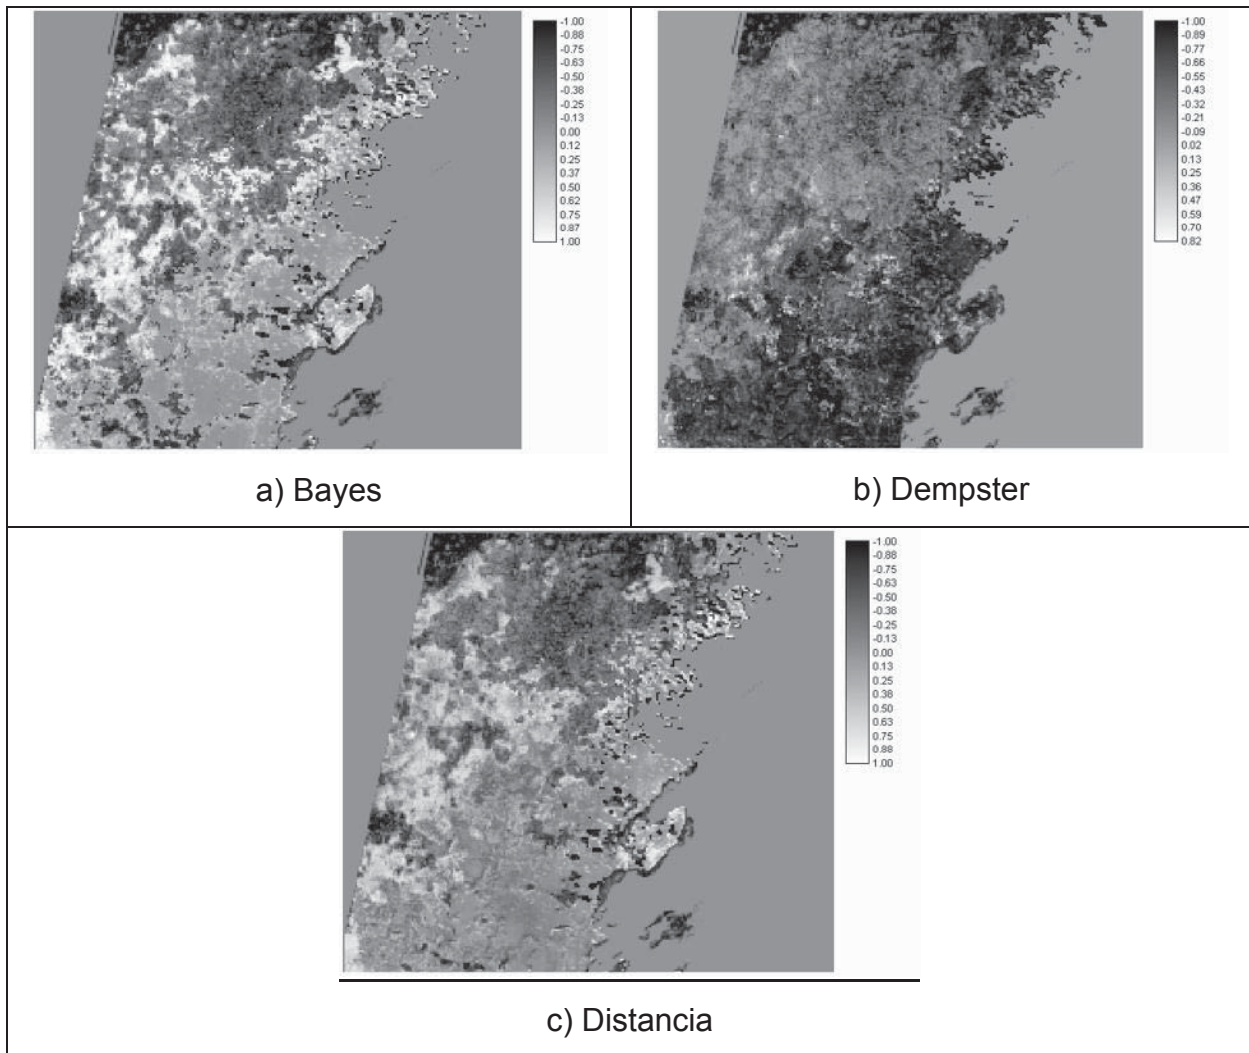


Fig. 23 Distribución del error en la estimación de la proporción de la categoría selva mediana subperennifolia para a) la teoría de Bayes, b) la teoría de Dempster Shapher y c) Distancia

La información que distinguimos en las gráficas son los píxeles subestimados (en blanco) y los sobreestimados (en negro).

Coincidiendo con el trabajo de Haglund (op.cit.) vemos que el clasificador basado en la teoría de Dempster Shapher no marca valores de proporción en aquellos píxeles que se encuentran lejos de la media.

Los peores resultados se obtienen para la agricultura que es una clase con una firma espectral amplia y multimodal, esto también se ha visto en otros trabajos publicados como el mismo de Haglund (op cit.) que encontró los mayores errores para clases heterogéneas. Esto es de esperarse ya que al trabajar con métodos paramétricos existe el supuesto de homogeneidad que es difícil de cumplir en muchos casos de las coberturas del suelo.

Las categorías pequeñas presentan menor error por la gran cantidad de ceros (los clasificadores operan bien en 100% y 0% de pertenencia) aun cuando son éstas las que se ven mas afectadas por los errores de posición geométrica por mínimos que sean.

6.7.3 Cálculo del coeficiente de correlación

Para evaluar la obtención de información a nivel subpíxel, se procedió a hacer el cálculo del coeficiente de correlación entre los valores difusos estimados y las proporciones correspondientes.

Cuadro 16. Coeficientes de correlación obtenidos para cada categoría en cada uno de los clasificadores evaluados.

CLASE	Teoría de Bayes	Teoría de Dempster	Basado en la Distancia
AGRO	0.517(**)	0.314(**)	0.492(**)
AGUA	0.118(*)	0.058	0.082
HIDRO	0.724(**)	0.497(**)	0.595(**)
SMSC	0.672(**)	0.420(**)	0.675(**)
SMSP	0.547(**)	0.390(**)	0.558(**)
Promedio	0.516	0.336	0.480

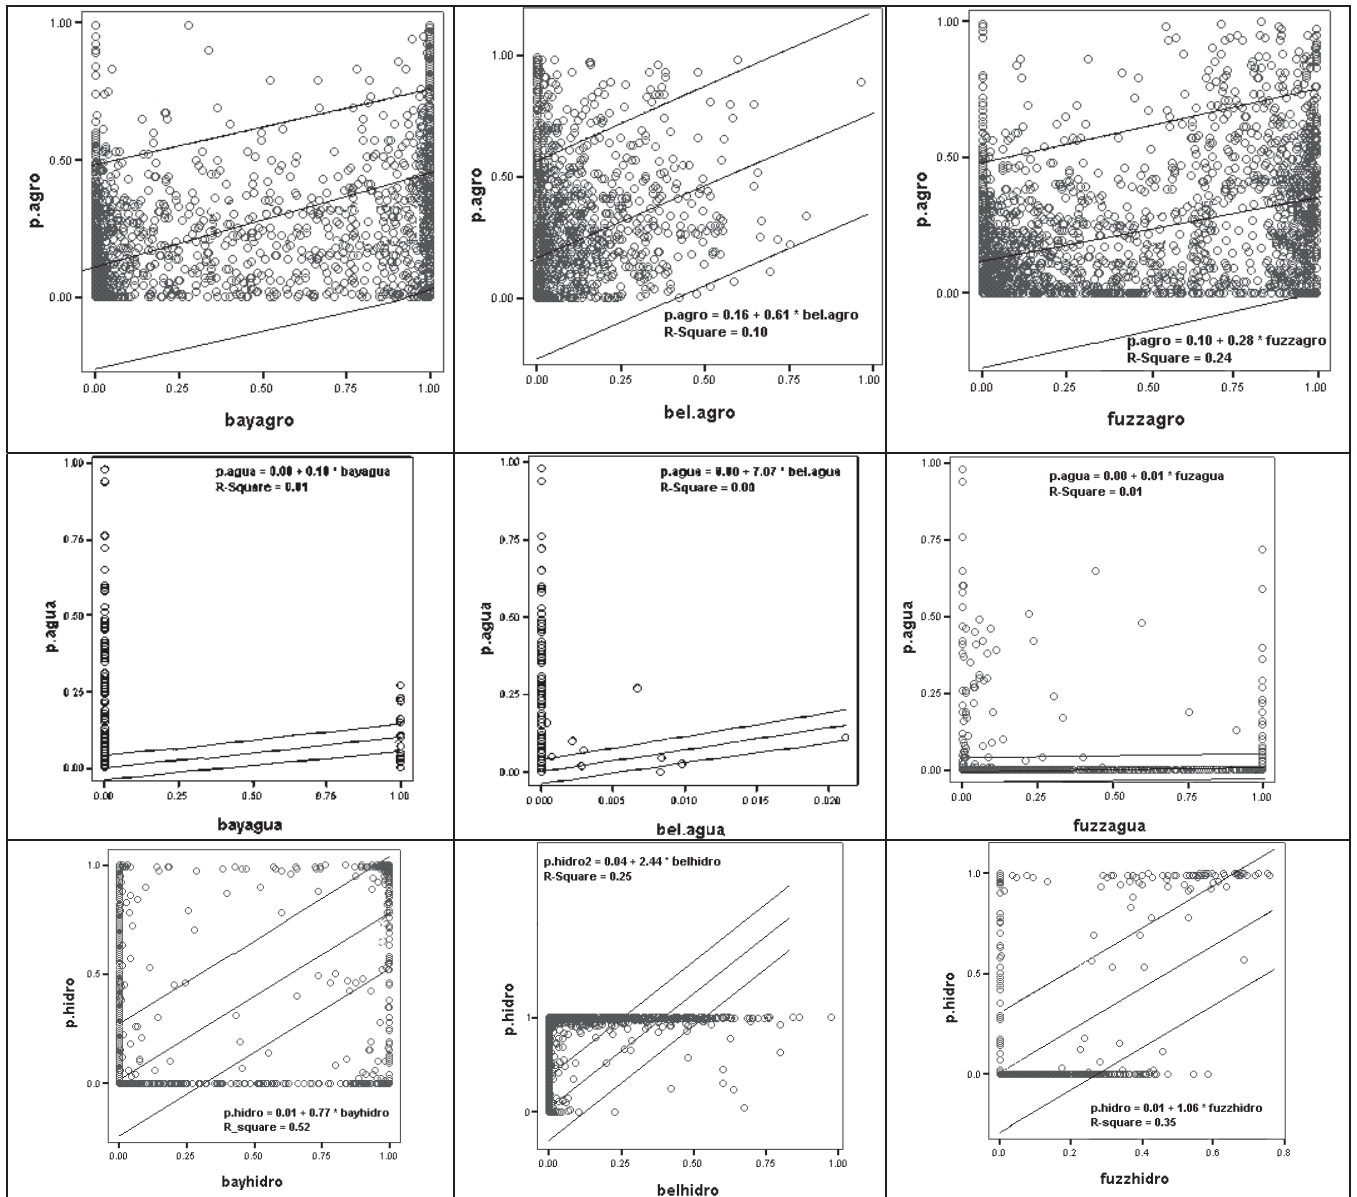
(*) Valor significativo para $p = 0.01$, (**) Valor significativo con 0.05.

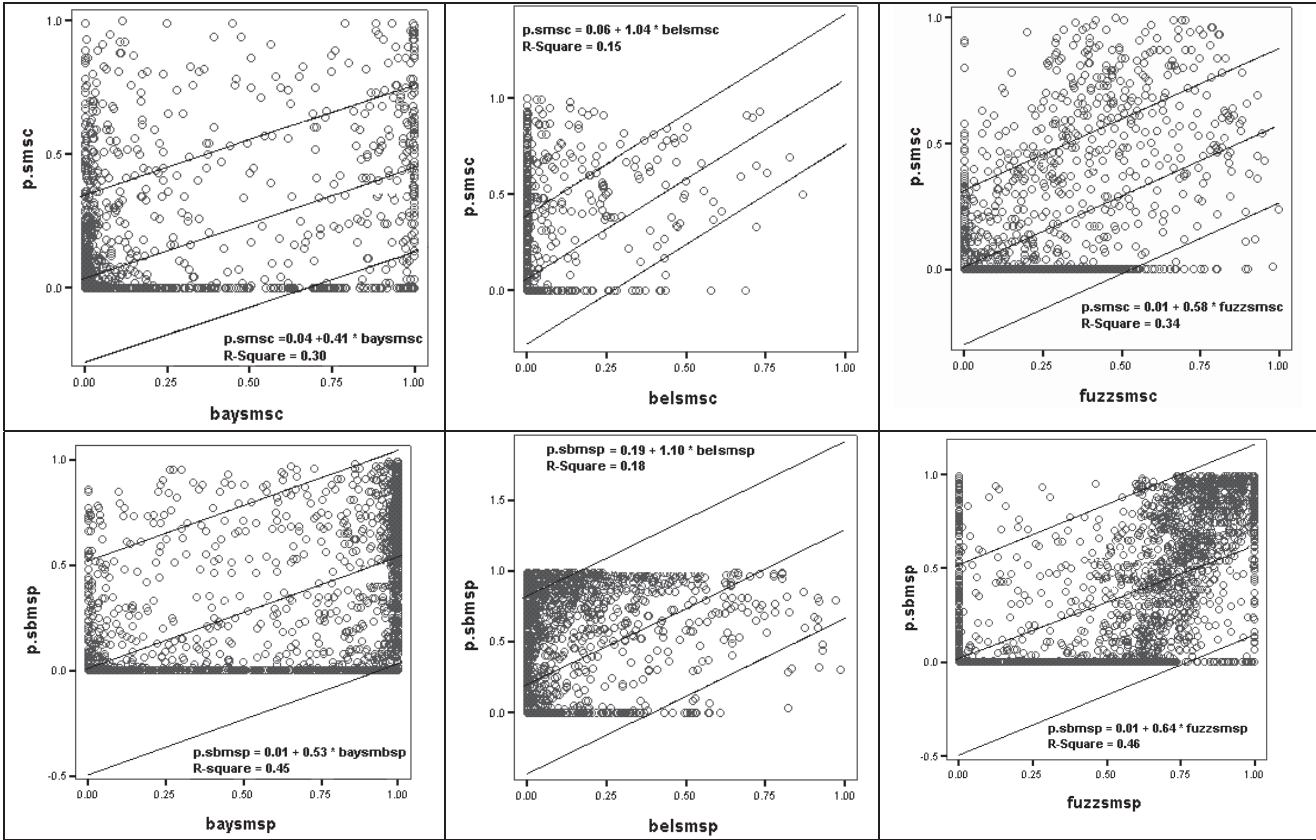
En el cuadro 16 podemos ver como cambia la perspectiva sobre la confianza de cada clasificador, el basado en la distancia, en este caso obtuvo una mejor correlación para las categorías de selva mediana subcaducifolia, y la selva mediana subperennifolia.

Comparando los resultados con los obtenidos por Frizzelle et al. (2001), vemos que en el caso del clasificador basado en la teoría de Bayes, el obtiene un rango de -0.02 a 0.46 en el mejor de los casos mientras que en el caso de este estudio, obtenemos un rango de 0.118 a 0.724, valores muy superiores a los de éste autor.

Aún cuando los resultados parecen por demás satisfactorios en las diferentes comparaciones con estudios publicados, los diferentes enfoques de evaluación dan resultados que parecen contradictorios, y al ver las gráficas de correlación en la figura 24 se observa que los datos no se distribuyen a lo largo de la línea de tendencia, así como también que la misma no se encuentra a 45 grados. Otra observación importante es que los límites de confianza se encuentran alejados de la media, por lo que recomendar su empleo en estudios posteriores o aún más tomar decisiones con base en estos resultados sin tomar en cuenta esta información puede resultar riesgoso.

Fig. 24 Gráficas de correlación entre los valores difusos (X) y sus respectivas proporciones (Y).





6.8 IMÁGENES CLASIFICADAS CON ALGORITMOS DIFUSOS Y DATOS AUXILIARES

De la clasificación con datos auxiliares se obtienen los resultados de error medio cuadrático y error medio absoluto presentados en el anexo 4, inciso A Y B, a partir de éstos datos se calculó la diferencia respecto a los resultados obtenidos sin la aplicación de datos auxiliares obteniendo los valores que se presentan en la tabla 16 y 17 respectivamente. Podemos ver que el error se reduce más en el clasificador de la distancia para la categoría de agua, vegetación hidrófila y selva mediana subcaducifolia; en el caso del clasificador basado en la teoría de Bayes para la categoría de vegetación hidrófila y selva mediana subperennifolia.

En el caso de la categoría agropecuario, no existe disminución del error ya que no tuvo ninguna restricción sobre su distribución mediante los datos auxiliares utilizados.

Cuadro 17. Reducción del error medio cuadrático aplicando las probabilidades a priori

	Bayes	DS	Distancia
AGRO	0.00%	0.00%	0.00%
AGUA	0.00%	0.00%	10.10%
HIDRO	6.00%	1.00%	0.00%
SBMSP	9.00%	0.00%	7.00%
SMSC	3.00%	0.00%	6.00%
PROM	3.60%	0.20%	4.62%

Cuadro 18. Reducción del error medio absoluto aplicando las probabilidades a priori

	Bayes	DS	Distancia
AGRO	0.00%	1.00%	0.00%
AGUA	0.00%	0.00%	2.84%
HIDRO	1.50%	0.30%	1.20%
SBMSP	6.00%	0.00%	8.00%
SMSC	2.00%	0.00%	5.00%
PROM	1.90%	0.26%	3.41%

Además de la estimación del error, se calculó también la correlación entre las proporciones y los valores difusos obtenidos con los datos auxiliares observando un aumento de esta como se muestra en el siguiente cuadro.

Cuadro 19. Aumento de la correlación de mediante el uso de datos auxiliares.

	Bayes	DS	Distancia
AGRO	1.70%	1.50%	5.90%
AGUA	5.00%	0.00%	18.40%
HIDRO	18.70%	4.30%	15.10%
SBMSP	11.00%	4.20%	11.70%
SMSC	21.00%	6.30%	21.00%
PROM	11.48%	3.26%	14.42%

Como se observa en todas las pruebas de validación, el método que mejora más mediante el uso de los datos auxiliares representados por las imágenes de probabilidad a priori es el basado en la distancia, esto es lo esperado ya que como se muestra en la distribución espacial del error este clasificador tiende a estimar proporciones en píxeles fuera de los límites de las categorías. En cambio para el clasificador basado en la teoría de Dempster Shapher no hubo mucha diferencia ya que este más bien estima valores de proporción en los píxeles que se encuentran hacia el centro de los límites

En la figura 25 se presenta un ejemplo que muestra precisamente este comportamiento de los datos en la categoría de selva mediana subcaducifolia.

Para ver las diferencias de cada una de las categorías obtenidas con datos auxiliares se presentan en el anexo 7.1 las imágenes de probabilidad, en el anexo 7.2, las imágenes de error correspondientes, en el anexo 7.3 las gráficas de correlación y en el anexo 7.4 los resultados obtenidos de error y correlación.

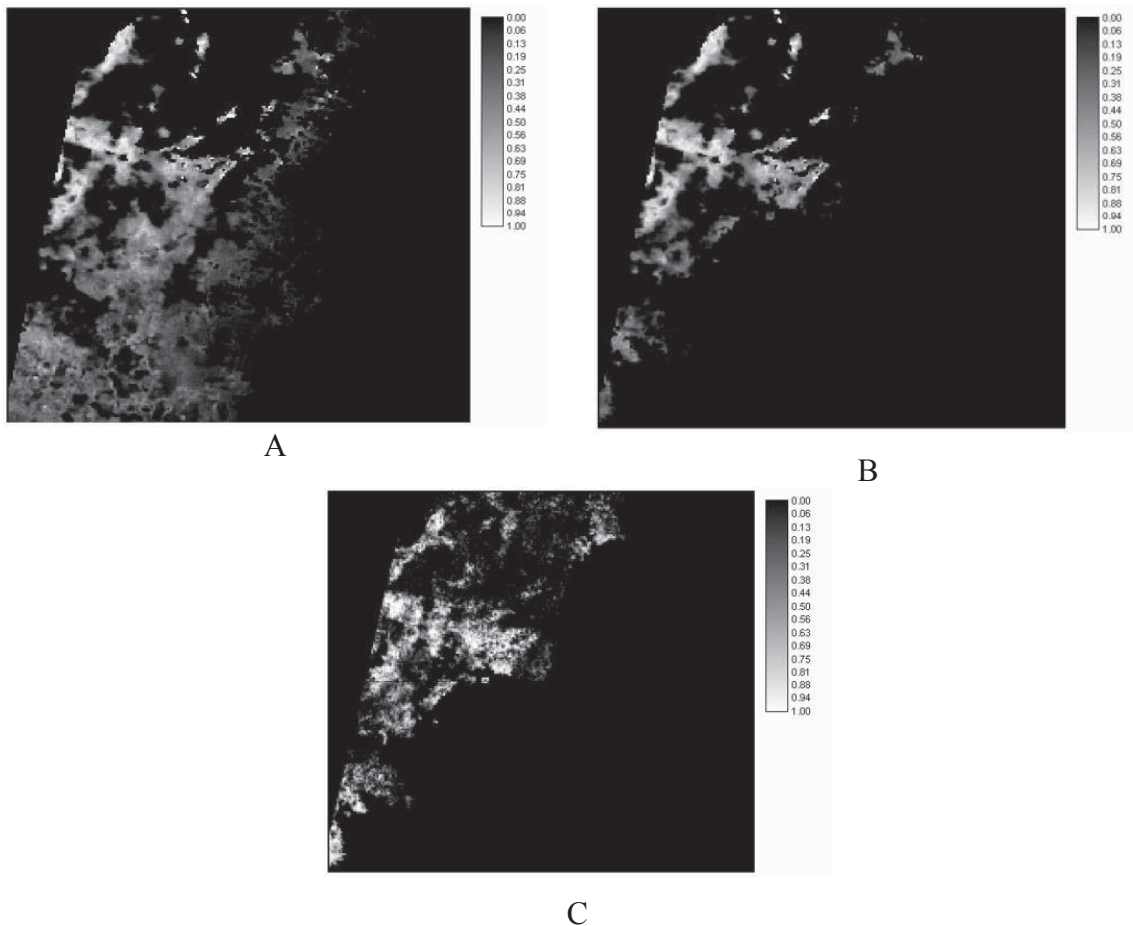


Fig. 25 Valores difusos obtenidos en la categoría selva mediana subcaducifolia en A) Distancia sin datos auxiliares B) Verdaderas proporciones y C) Distancia con datos auxiliares.

Es cuestionable que puedan preverse las proporciones reales de una cobertura en el terreno mediante los valores difusos obtenidos. Por un lado, los resultados del error indican que la fiabilidad es buena y la correlación es alta. Sin embargo, el comportamiento observado de los datos en las gráficas de dispersión contradice esta visión optimista, aún más si tomamos en cuenta el fundamento estadístico de la prueba de correlación, el cuál advierte que el hecho de que dos variables estén correlacionadas no necesariamente indica que son concordantes.

Las pruebas de correlación son ampliamente usadas en diferentes ramas de la ciencia, para evaluar la concordancia entre variables continuas, siendo en muchas ocasiones, incorrecto ya que un valor obtenido puede producir sistemáticamente el triple del valor real, en cuyo caso ambos valores estarían perfectamente correlacionados ($r=1$) pero no son concordantes en absoluto. http://www.hrc.es/bioest/errores_8.html

Un procedimiento, gráfico, alternativo propuesto por Bland et al (1986) es presentar las diferencias contra la media. Esto se ilustra en la figura 25 con la categoría de vegetación hidrófila clasificada mediante el método basado en la teoría de Bayes y datos auxiliares, que es la que presenta la correlación más alta (0.911). Observamos que los valores difusos y las proporciones no son tan concordantes como indica el valor obtenido de correlación. Mientras que los valores de proporción pequeños tienden a subestimarse, los valores de proporción grandes se sobreestiman sistemáticamente.

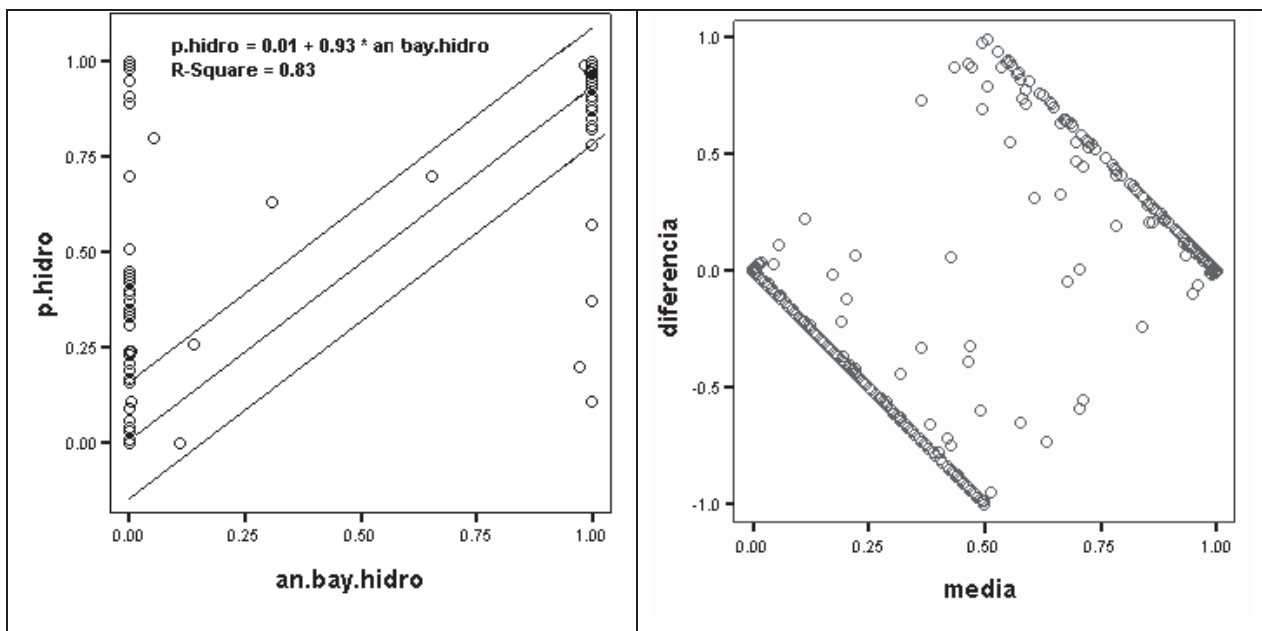


Fig. 25 Comparación de la grafica de correlación con la grafica de concordancia basada en el método propuesto por Bland et al. (1986).

VII. CONCLUSIONES.

El objetivo de este estudio fue evaluar si es posible inferir las proporciones reales de una cobertura en el terreno a través de un análisis difuso en imágenes de baja resolución, empleando algunas de las metodologías más utilizadas en la literatura en casos similares, que son básicamente el cálculo del error medio cuadrático y cálculo de la correlación. A partir de los resultados obtenidos podemos concluir lo siguiente:

Respecto a los resultados de evaluación de los clasificadores vemos que;

1. Las categorías que presentaron mayor error no cumplen con los supuestos paramétricos.
2. La heterogeneidad del área de estudio representada tanto por las diferencias dentro de la misma categoría, los estadios intermedios así como la distribución de estos en parches pequeños dificulta la clasificación aún en escalas menores.
3. Tanto el error medio cuadrático como la correlación presentan mejoras cuando se usan datos auxiliares en forma de imágenes de probabilidad. La disminución promedio del error varía de 0.20% a 4.60% y la correlación promedio tiene un aumento de 0.033 a 0.144, siendo en ambos casos el clasificador más beneficiado mediante la implementación de esta metodología el basado en la distancia espectral.
4. Los resultados del error arrojados por el análisis difuso varían de acuerdo al clasificador utilizado y en cada clase, el que parece obtener los menores resultados de error es el clasificador basado en la teoría de Dempster Shaper con el menor error para tres de las cinco categorías, mientras que el que obtiene las correlaciones más altas es el basado en la teoría de Bayes, con los mejores resultados también para tres de las cinco categorías.

Respecto a los métodos de validación podemos decir que;

1. Los resultados obtenidos mediante el cálculo de la correlación no son los más idóneos para medir el desempeño de los clasificadores difusos, en su lugar se propone el uso del coeficiente de concordancia propuesto por Blend et al, (1986), ya que ha mostrado ser mas objetivo en otras ramas de la ciencia en la comparación de dos variables continuas.
2. La representación visual de los datos representa la falta de concordancia entre los datos difusos y los de verdad, por lo que no es posible inferir los valores reales a partir de los estimados.

Sobre el uso de este tipo de imágenes para medir el grado de deforestación dentro de un píxel, reduciendo el número de clases a dos, vemos que tampoco es posible, esto basado en que;

1. Esta categoría es la que presenta los mayores errores.
2. El patrón de deforestación en nuestro país es desagregado y con polígonos pequeños, por lo que, para que esta actividad se viera representada en un píxel tendría que tener una extensión mayor a medio píxel, es decir más de medio kilómetro cuadrado.

A pesar de que para este ejercicio los resultados obtenidos no son alentadores, esto no significa que el método no pueda funcionar en otro tipo de áreas menos complejas, con imágenes de mayor resolución espacial o con el empleo de otras técnicas. Es importante seguir en la búsqueda de elementos que nos permitan tener datos actualizados sobre la distribución y estado actual de nuestros recursos naturales, y que estos sean accesibles y expeditos ya que de este tipo de información dependen muchas de las decisiones que sobre su manejo y conservación sean propuestas.

VI. BIBLIOGRAFIA.

- ✎ Atkinson M., J Cutler, H Lewis.1997. **Mapping sub-pixel proportional land cover with AVHRR imagery.** International Journal of Remote Sensing. Vol. 18, No. 4, 917- 935.
- ✎ Bland M., D. Altman 1986. **Statistical methods for assessing agreement between two methods of clinical measurement.** Lancet No. 347, Pp. 307-310
- ✎ Blonda. P., G. Pasquariello, S. Losito, A. Mori, F. Posa, D. Ragno.1991. **An experiment for the interpretation of multitemporal remotely sensed images based on a fuzzy logic approach.** International Journal of Remote Sensing. Vol. 12, No. 3, Pp. 463-476.
- ✎ Boschetti, L. Flasse, S. Trigg S. Jacques A. Dixmude. 2001 **A Multitemporal Change-Detection Algorithm For The Monitoring Of Burnt Areas With Spot-VEGETATION Data.** Proceedings of Multitemp Conference. Natural Resources Institute. University Of Greenwich.Pp8.
- ✎ Brito J., J. Cardoso, M. Lameiras, E. Shimabukuro. 2005. **A land cover map for the Brazilian Legal Amazon using SPOT-4 VEGETATION data and machine learning algorithms.** Anais XII Simpósio Brasileiro de Sensoriamento Remoto. Goiânia, Brasil, INPE. Pp. 457-464.
- ✎ Burrough, P.A. 1986. **Principles of geographical information systems for land resources assessment.** Claredon Press. Oxford. Pp. 193.
- ✎ Card, DH. 1982. **Using map category marginal frequencies to improve estimates of thematic map accuracy.** Photogrammetric Engineering & Remote Sensing. Vol. 48 No.3 Pp. 431-439.

- ✎ Chargoy C. 1999. **La selva agrícola tropical: un ejemplo en el sur de Quintana Roo, México.** Red, Gestión de Recursos Naturales, segunda época. No. 14. Pp. 22-29.
- ✎ Chuvieco E. 2002. **Teledetección Ambiental: La observación de la Tierra desde el Espacio.** Ariel Ciencia. Barcelona España. Pp. 586.
- ✎ Díaz Gallegos, J.R., J .F. Mas, A. Velázquez, G. Bocco, y R. Castro. 2002. **Uso de suelo y transformación de selvas y bosques del sur de México en las últimas tres décadas.** Resúmenes del congreso de la unión Geofísica Mexicana. Sociedad Latinoamericana de Percepción Remota y Sistemas de Información Espacial. México. Puerto Vallarta Jal. Pp.354
- ✎ Eastman. J. 2003. **Idrisi Kilimanjaro Tutorial.** versión 14.0 Clark labs. Clark University. Worcester. MA. USA. Pp.270.
- ✎ Equihua. M. 1991. **Análisis de la vegetación empleando la teoría de conjuntos difusos como base conceptual.** Acta Botánica Mexicana. No.15 Pp. 1-16.
- ✎ Frizzelle B., A. Moody. 2001. **Mapping continuous distributions of land cover: A comparison of maximum likelihood estimation and artificial neural networks.** Photogrammetric Engineering & Remote Sensing. Vol. 67 No. 6 Pp. 693-705.
- ✎ Foody, G.M. 1998. **Sharpening fuzzy classification output to refine the representation of sub-pixel land cover distribution.** International Journal of Remote Sensing. No.13 Pp. 2593-2599

- ✎ Haglund A. 2000. **Towards soft classification of satellite data. A case study based upon Resurs MSU-SK satellite data and land cover classification within the Baltic Sea Region.** Master of science project In Geoinformatics. Royal Institute of technology. Department of geodesy and Photogrammetry.
- ✎ Hootsmans. R. 1996. **Fuzzy Sets and Series Analysis for visual Decision Support in Spatial Data Exploration.** Editorial Board. Utrecht. Amsterdam. 168 Pp.
- ✎ Lundberg, U., G. Ekman. 1973. **Subjective geographic distance: A multidimensional comparison.** Psychometrika. No. 38, 113-121.
- ✎ Lu D., E. Morana, M. Batistella. 2003 **Linear mixture model applied to Amazonian VEGETATION classification.** Remote Sensing of Environment. No. 87 Pp 456–469
- ✎ Mas J. F., J. R. Díaz-Gallegos, A. Pérez-Vega. 2003. **Evaluación de la confiabilidad temática de mapas o de imágenes clasificadas: una revisión.** Investigaciones geográficas. Boletín del Instituto de Geografía, UNAM, No. 51, Pp 53-72.
- ✎ Mas J. F, A. Velázquez, J. R. Díaz-Gallegos, R. Mayorga, C. Alcántara, R. Castro y T. Fernández. 2002. **Monitoreo de los cambios de cobertura en México.** Memorias del II seminario latinoamericano de Geografía Física, Maracaibo, Venezuela, 24-27 de julio.
- ✎ Maussel P., J. Kramber, J. Lee. 1990 **Optimum band selection for supervised classification of multispectral data.** Photogrammetric Engineering & Remote Sensing Vol. 56 No. 1 Pp. 55-60.

- ✎ Oki, K. T. M. Uenishi, K. Omasa. 2004 **Accuracy of land cover area estimated from coarse spatial resolution images using an unmixing method.** International Journal of Remote Sensing. Vol. 25, No. 9, Pp1673–1683.
- ✎ Palacio-Prieto J., J. López-García, G Bocco, M Palma, A Velásquez, I. Trejo-Vázquez, J.F Mas. A Peralta, F Takaki-Takaki, J Prado-Molina, A. Victoria, A. Rodríguez-Aguilar, L Luna-González, R Mayorga-Saucedo, G. Gómez-Rodríguez. **La condición actual de los recursos forestales en México: resultados del Inventario Forestal Nacional 2000.** Investigaciones Geográficas, Boletín del Instituto de Geografía, UNAM No. 43, 2000, pp. 183-203
- ✎ Primack R., D Bray, H. Galletti e I. Ponciano. 1999. **La selva maya. Conservación y desarrollo.** Siglo XXI Editores, México, 475 pp.
- ✎ Shimabukuro E., J. Smith. 1991. **The least squares mixing models to generate fraction images derived from remotely sensed data.** IEEE Transaction of Geoscience and Remote Sensing. Vol 29 No 1. Pp 16-20.
- ✎ Swain P. y C King. 1973 **Two effective feature selection criteria for multispectral remote sensing.** LARS Technical note 042673. Washington D.C. Pp 6.
- ✎ Swain P. y S. Davis 1978. **Remote sensing, the quantitative approach.** Mc Graw Hill. 396. New York.
- ✎ Tso B. y P. Mather 2001. **Classification methods for remotely sensed data.** Taylor and Francis. Londres.

- ✎ Verhoeve, J., R. De Wulf. 2000. **Sub-pixel mapping of Sahelian wetlands using multitemporal SPOT VEGETATION images**. 28th International Symposium on Remote Sensing of Environment. Information for Sustainable Development Pp. 14–19.
- ✎ Woodcock C. y S. Gopal. 2000. **Accuracy assessment and area estimates using fuzzy sets**. International Journal of geographical Information Science. Vol. 14 No. 2 Pp. 153-172.
- ✎ Zadeh. L. 1965. **Fuzzy sets**. Journal of Information and Control No. 8 Pp. 338-353
- ✎ Thakkar P. 2004 **Mixed Pixel Analysis**. Tesis de maestría en sistemas de información geográfica. Escuela de ciencias sociales. Universidad de Texas. Pp.25.

DIRECCIONES ELECTRÓNICAS

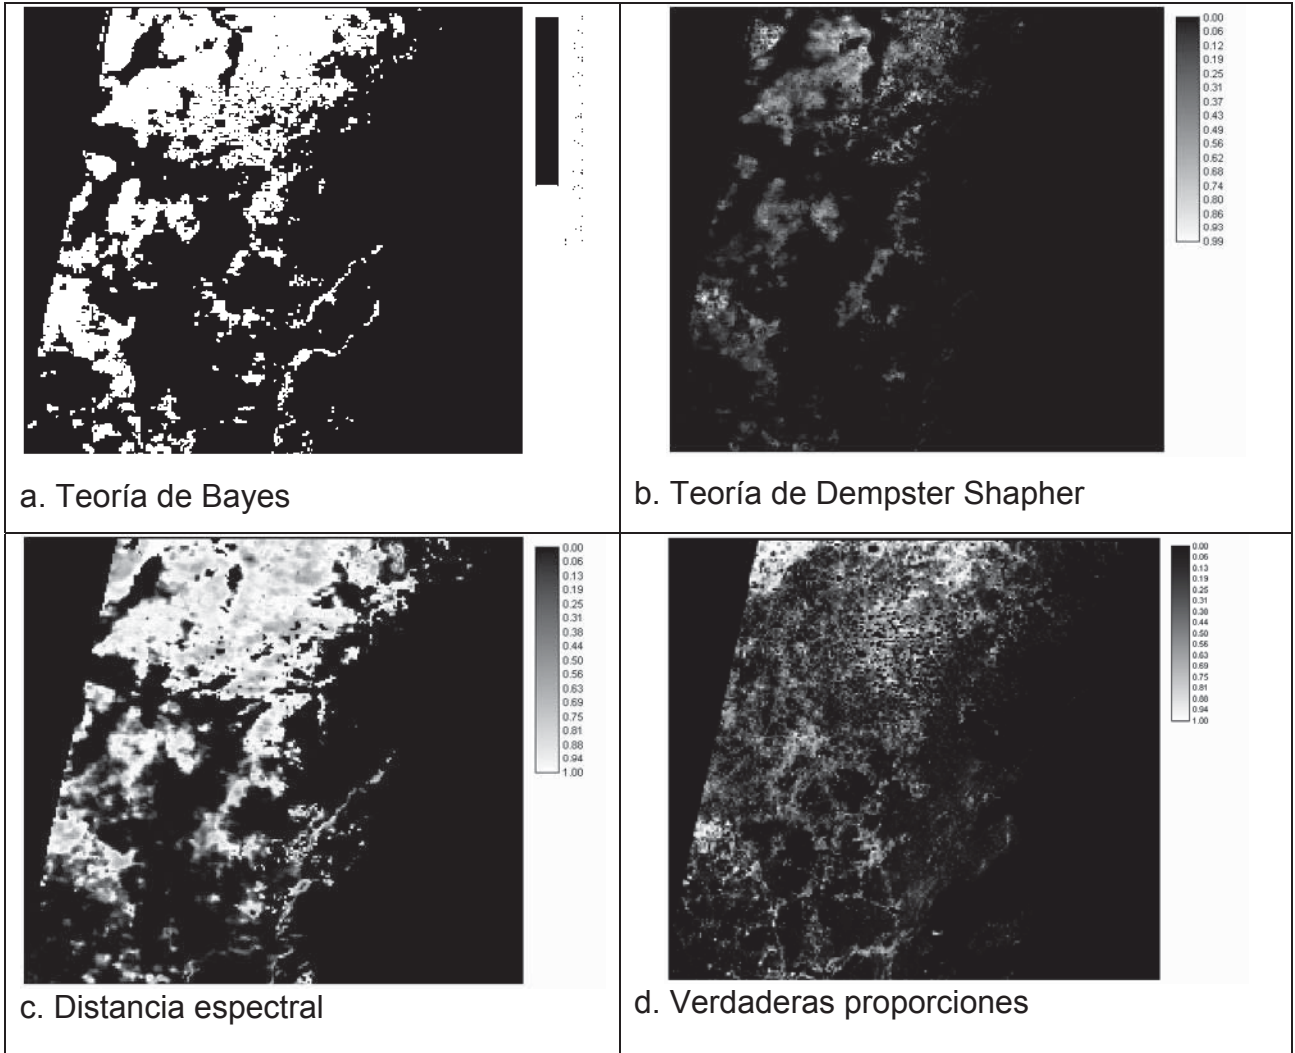
- ✎ <http://www.conabio.org.mx>
- ✎ <http://web.usal.es/javisan/hidroF>. J. San Román
- ✎ <http://www.pcigeomatics.com/cgi-bin/pcihlp/>
- ✎ http://www.hrc.es/bioest/errores_8.html
- ✎ <http://VEGETATION.cnes.fr/userguide/userguide.htm>

ARTICULOS EN LINEA

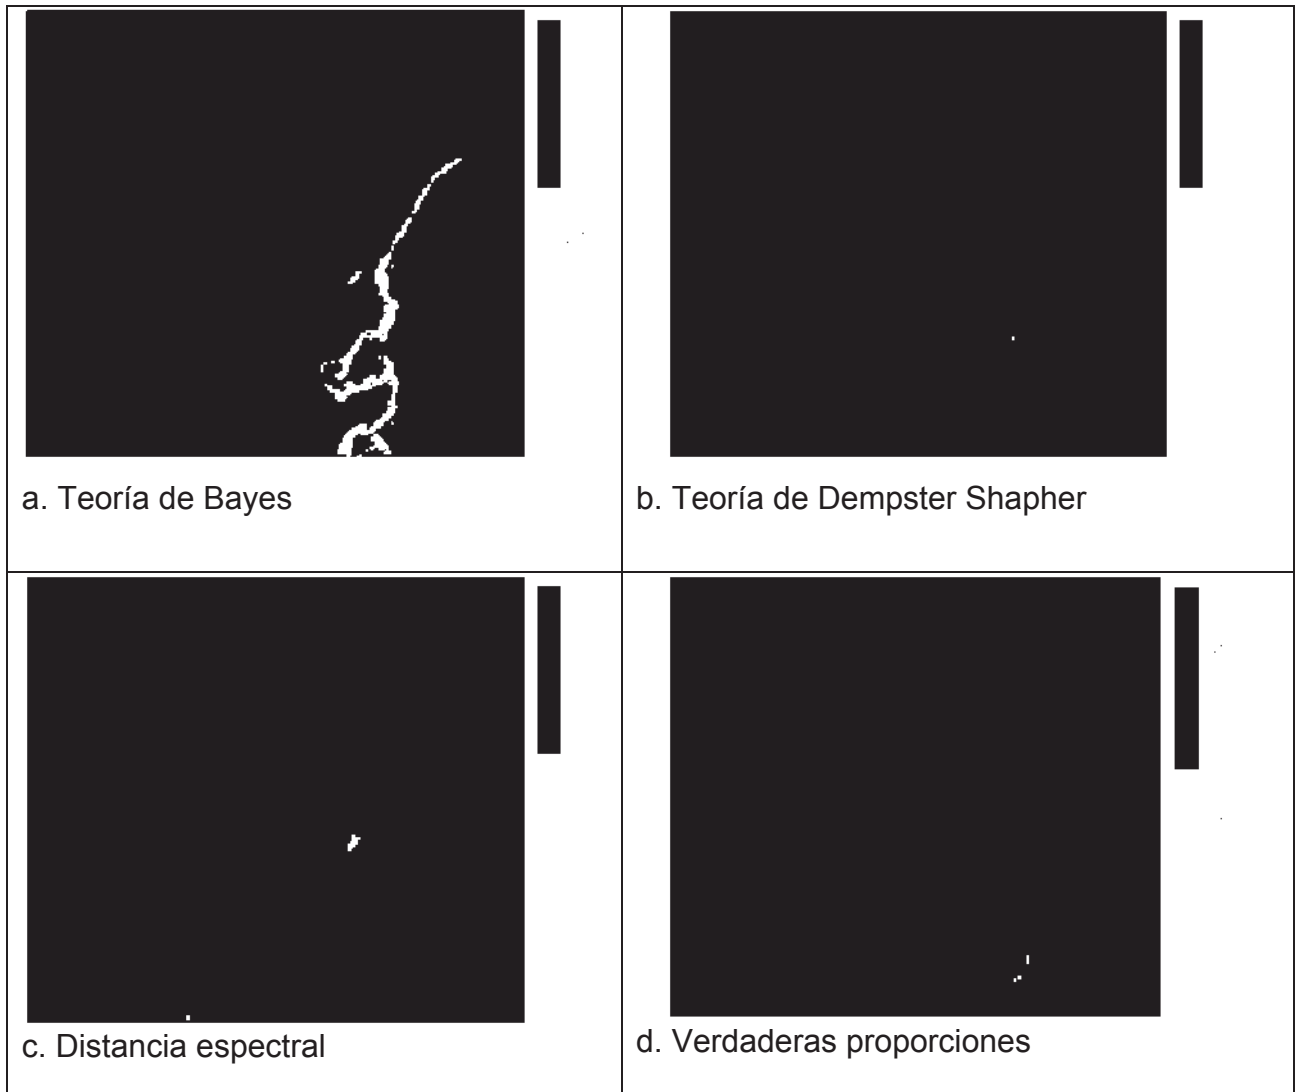
- ✎ Chiappy C, L Gama. 2004. Modificaciones y fragmentación de los geocomplejos tropicales de la península de Yucatán. www.ujat.mx/publicaciones/ciencia. Número Especial I Pp. 17-25.
- ✎ Bartholomé (CCR/SAI), 1997 (<http://www-project.cst.cnes.fr:8050/>).
- ✎ Swinnen E, H Erens, L. Gil 2000 Sub-pixel land-cover classification with SPOT-VEGETATION imagery Bruselas Bélgica. [Http://www.geosuccess.net/.../documents/subpíxel](http://www.geosuccess.net/.../documents/subpíxel).

7.1. PROPORCIONES OBTENIDAS DE LAS DIFERENTES CATEGORÍAS MEDIANTE EL USO DE CLASIFICADORES DIFUSOS Y DATOS AUXILIARES.

A. Agropecuario



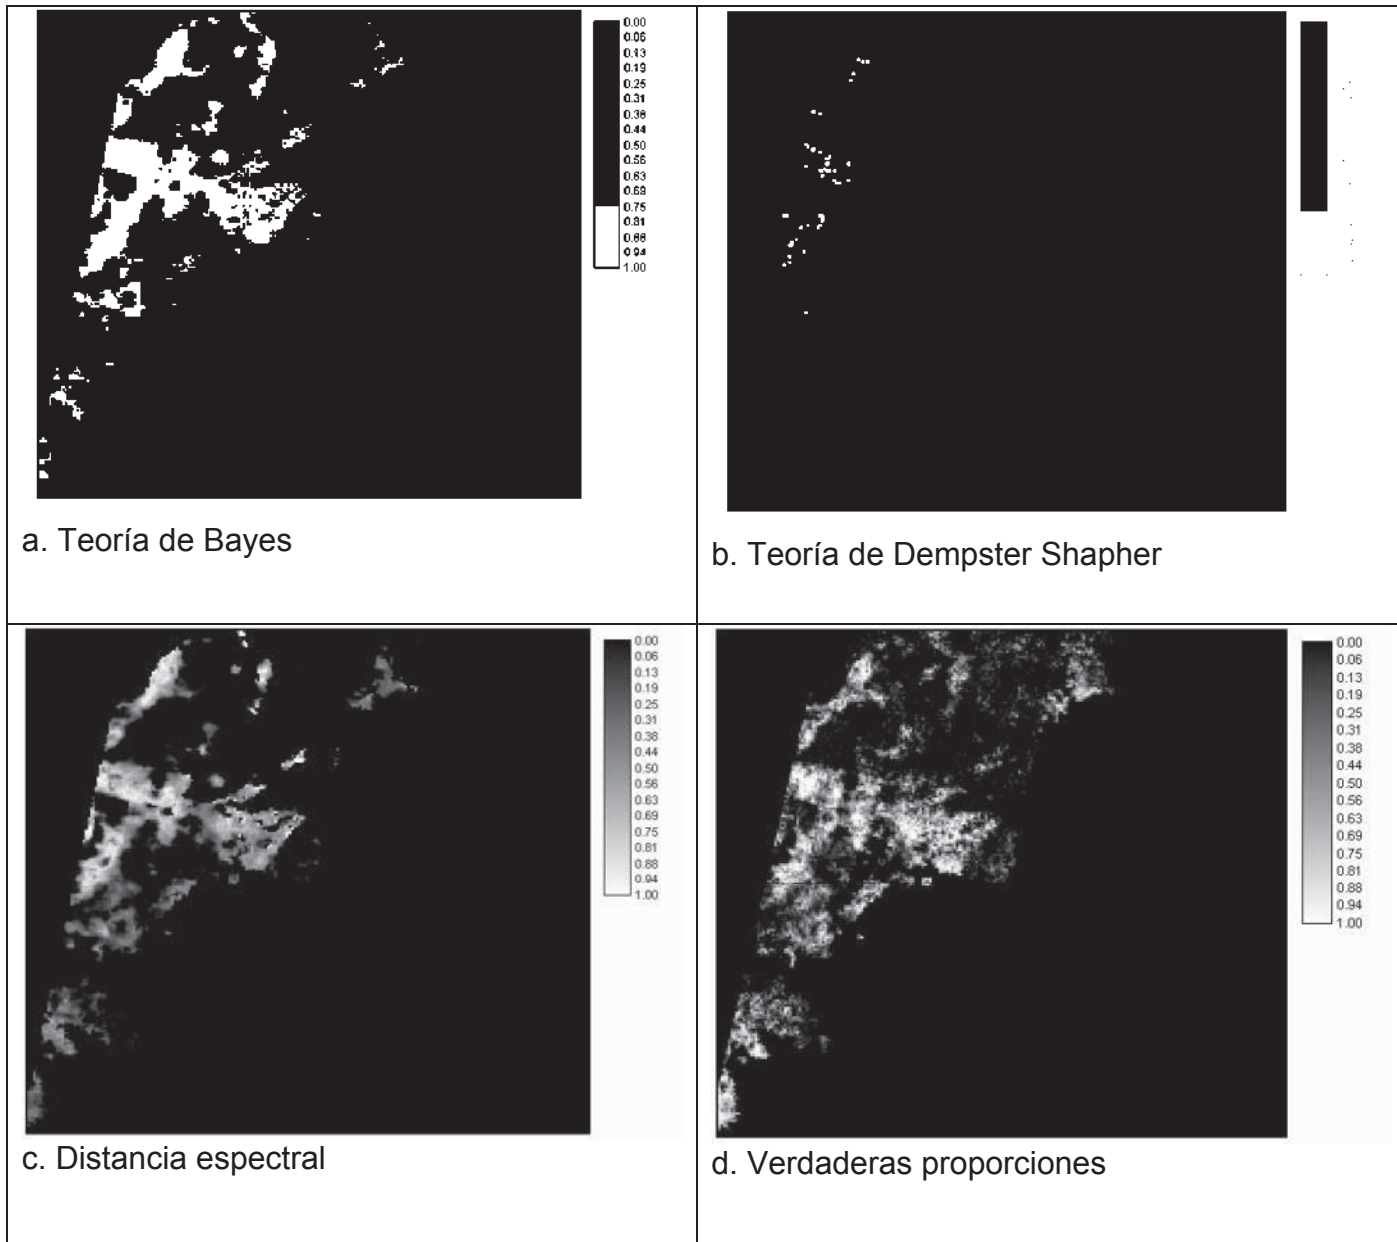
B. Agua



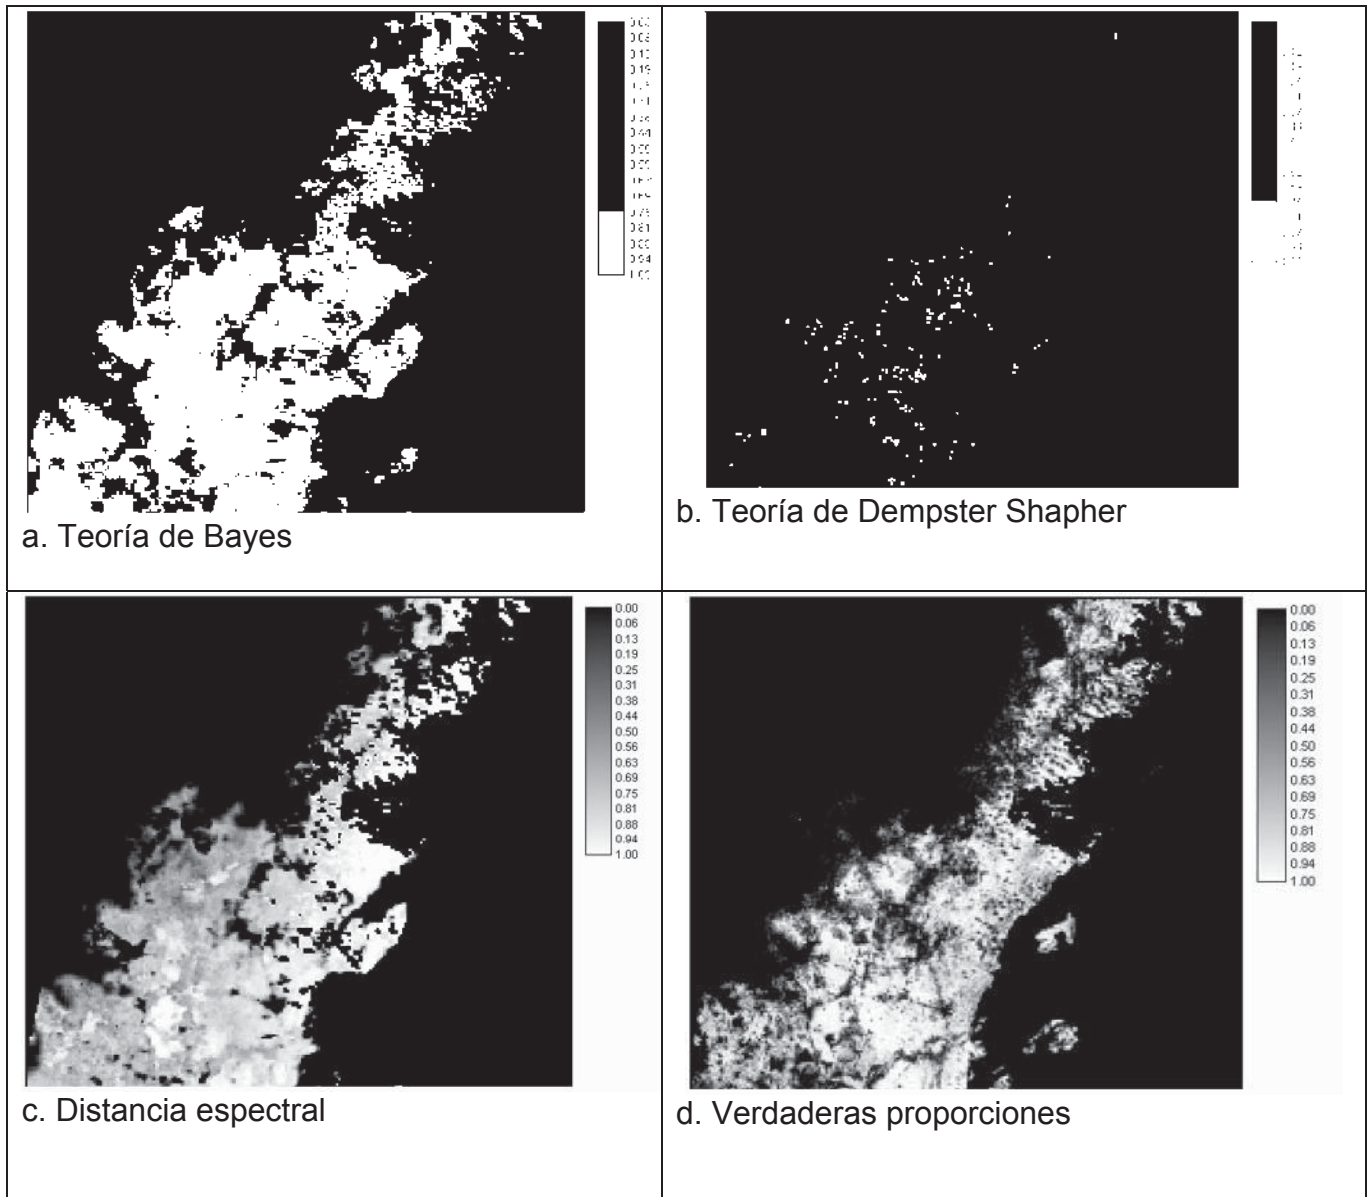
C. Vegetación hidrófila



D. Selva mediana subcaducifolia

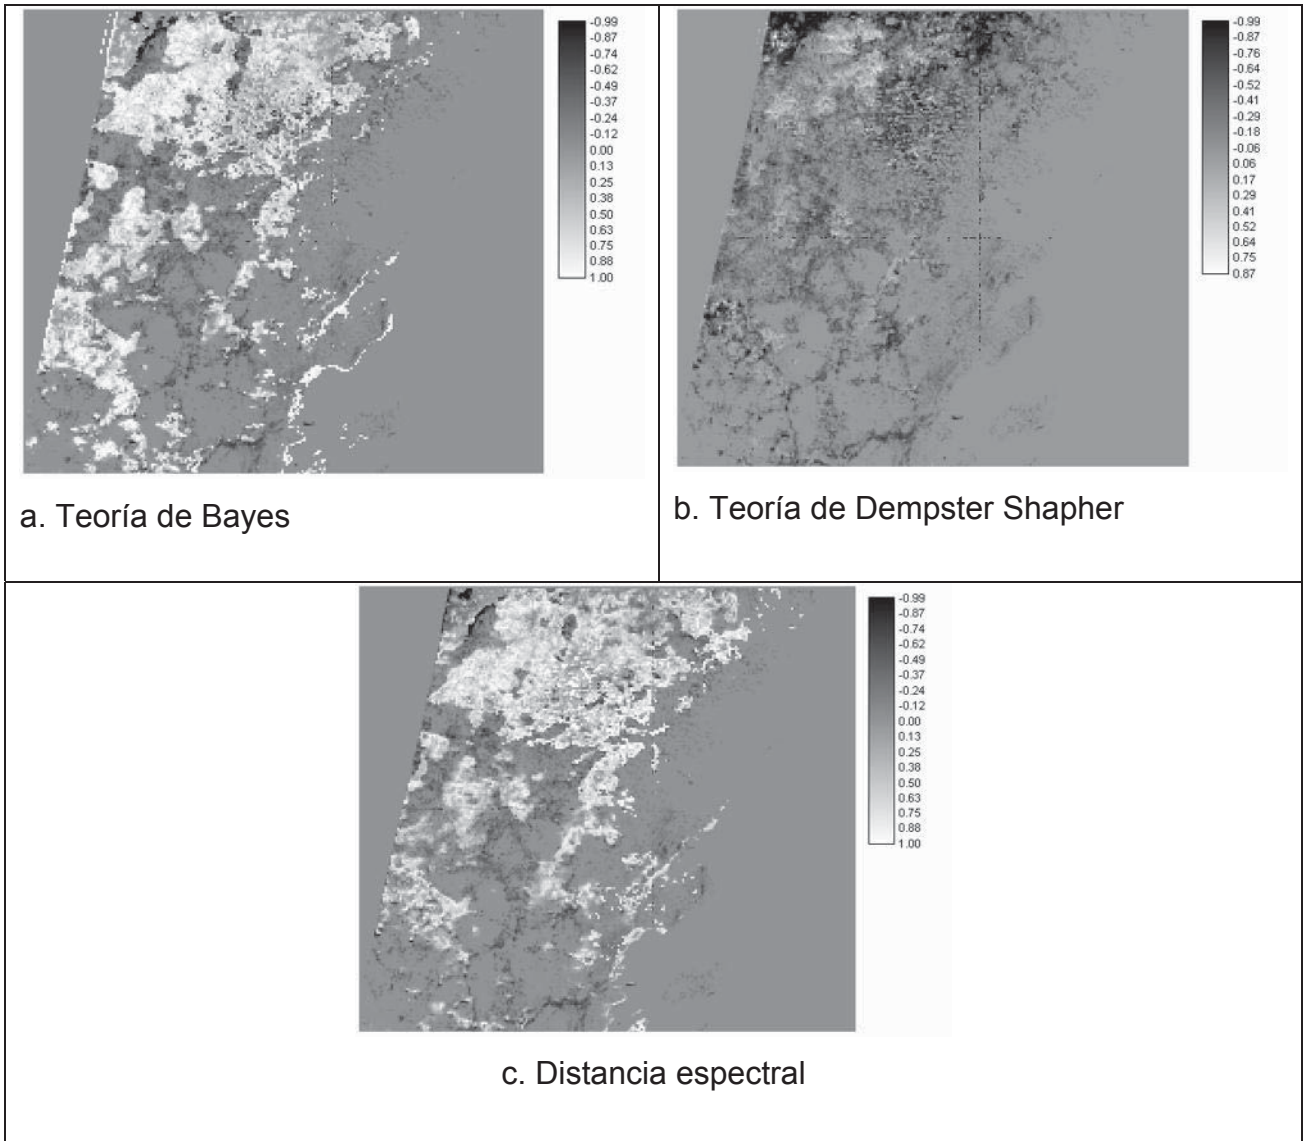


E. Selva baja y mediana subperennifolia

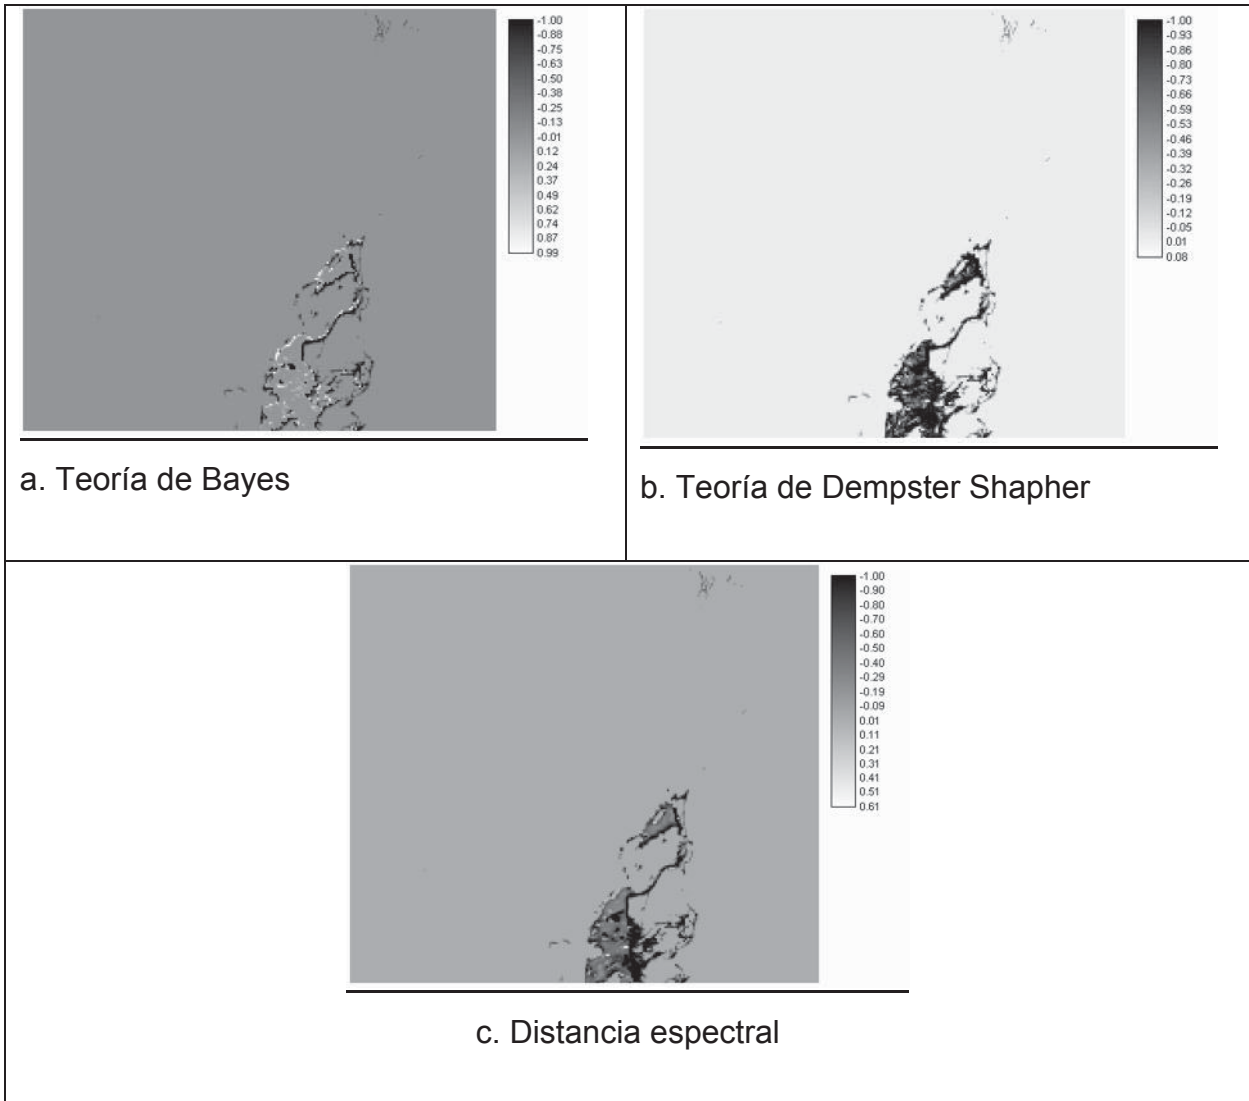


7.2. DISTRIBUCIÓN ESPACIAL DEL ERROR DE LOS MAPAS DIFUSOS CON DATOS AUXILIARES.

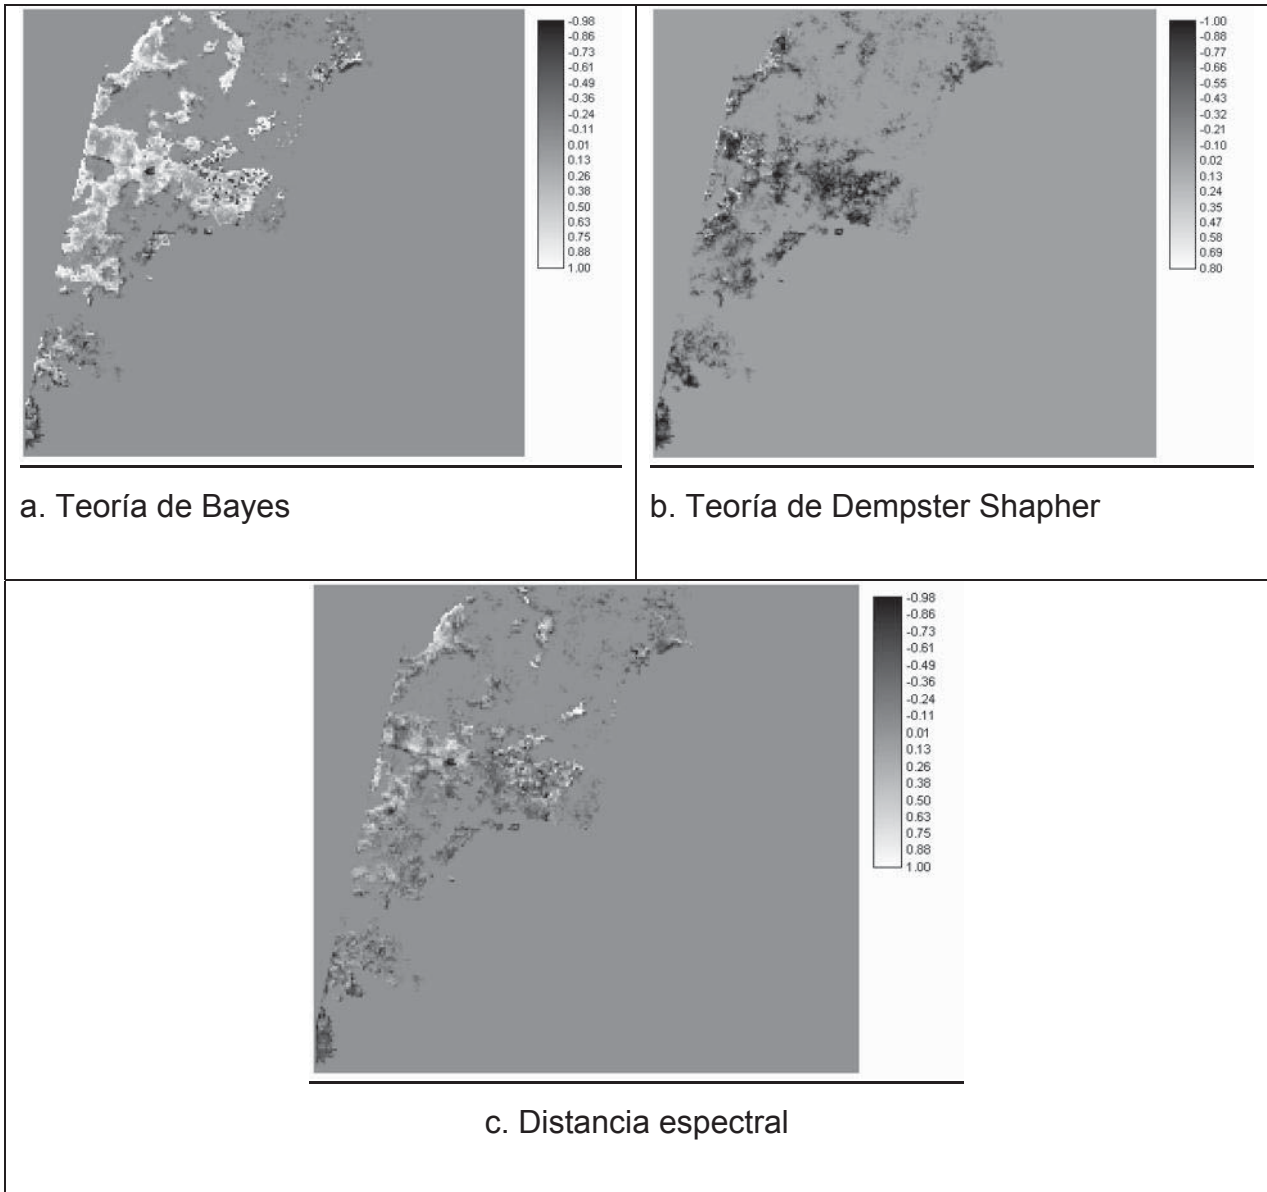
a) Agropecuario



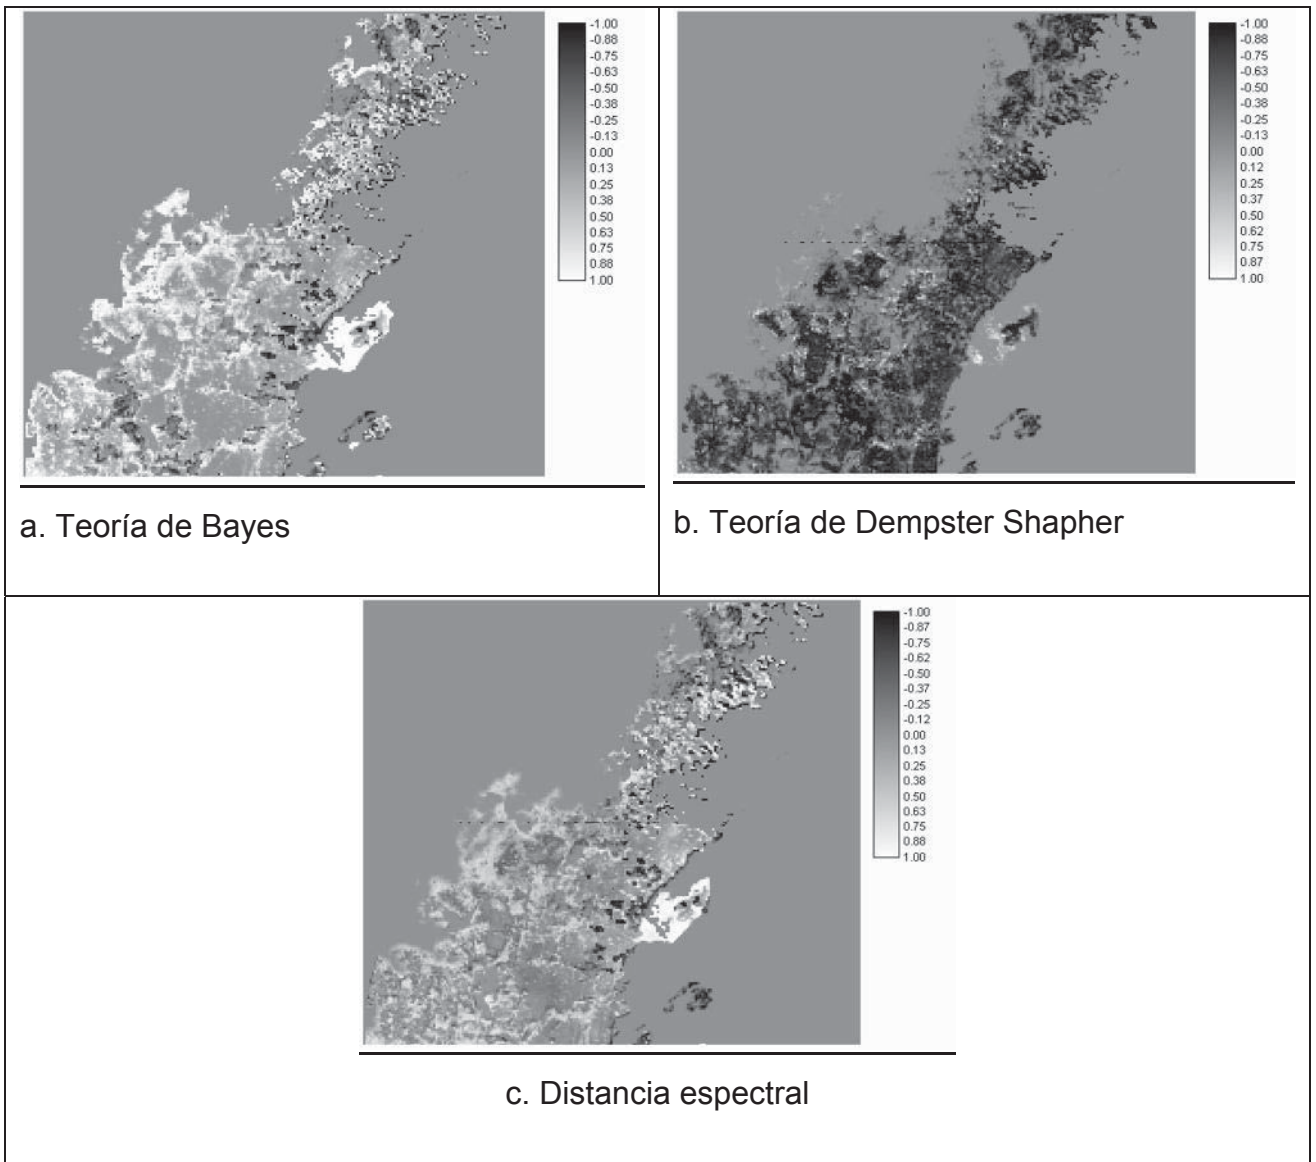
b) Vegetación Hidrófila




C) Selva mediana subcaducifolia

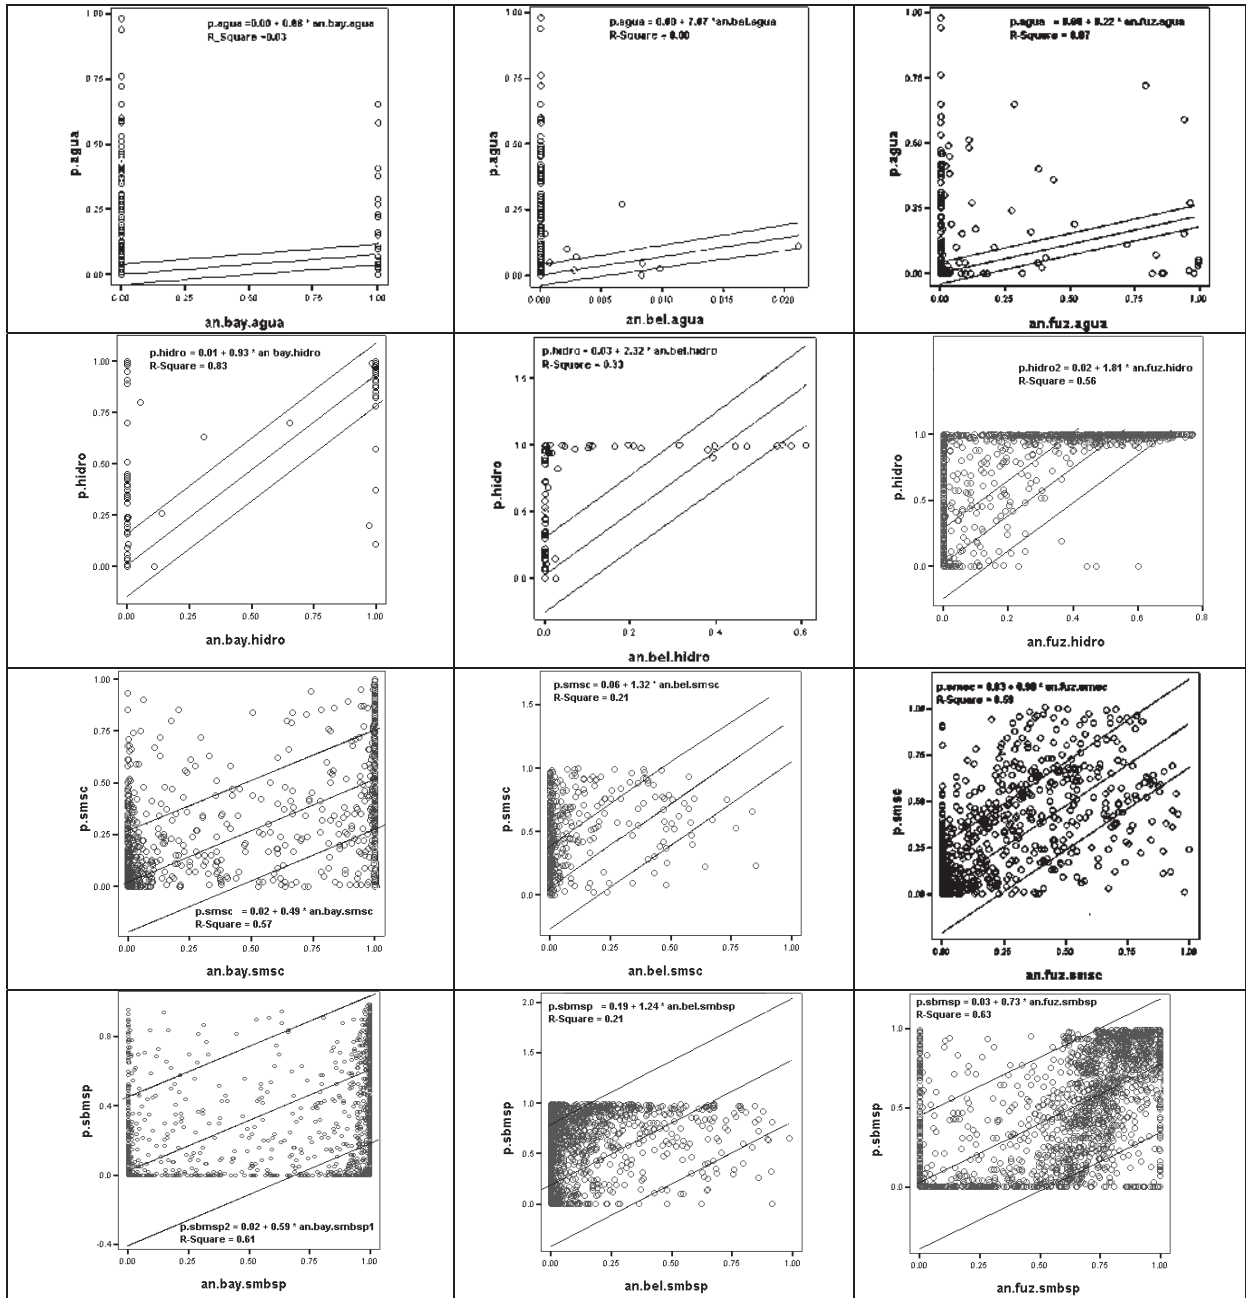


D) Selva mediana subperennifolia



7.3. GRÁFICAS DE DISPERSIÓN, DE LAS PROPORCIONES DE CADA PÍXEL (EJE Y) EN FUNCIÓN DE SU VALOR FUZZY (EJE X).





7.4. RESULTADOS DE ERROR Y CORRELACIÓN OBTENIDOS A PARTIR DE DE LOS DATOS OBTENIDOS MEDIANTE LA CLASIFICACIÓN DIFUSA CON DATOS AUXILIARES.

A. Valores de error medio cuadrático obtenidos en cada categoría por los tres clasificadores difusos mediante el uso de datos auxiliares.

	Bayes	DS	Distancia
AGRO	0.37	0.26	0.37
AGUA	0.03	0.02	0.03
HIDRO	0.08	0.18	0.15
SBMSP	0.3	0.37	0.24
SMSC	0.19	0.18	0.12
PROM	0.194	0.2	0.182

B. Resultados del error medio absoluto obtenido en cada categoría en cada uno de los clasificadores difusos mediante el uso de datos auxiliares.

	Bayes	DS	Distancia
AGRO	0.25	0.16	0.26
AGUA	0.001	0	0.002
HIDRO	0.009	0.04	0.035
SBMSP	0.17	0.21	0.12
SMSC	0.07	0.07	0.05
PROM	0.1	0.1	0.093

C. Coeficiente de correlación obtenidos para cada categoría en cada uno de los clasificadores difusos mediante el uso de datos auxiliares.

	Bayes	DS	Distancia
AGRO	0.534(**)	0.33(**)	0.55(**)
AGUA	0.168(*)	0.06	0.266(*)
HIDRO	0.911(**)	0.54(**)	0.746(**)
SBMSP	0.782(**)	0.46(**)	0.792(**)
SMSC	0.757(**)	0.45(**)	0.768(**)
PROM	0.63(**)	0.37(**)	0.624(**)