

# **Tesis Doctoral**

## **RAZONAMIENTO EVIDENCIAL DINAMICO**

**Un Método de Clasificación aplicado al  
Análisis de Imágenes Hiperespectrales**

**Cecilia Verónica Sanz**



**Universidad Nacional  
de La Plata  
Facultad de Ciencias Exactas**

LA PLATA

ARGENTINA

2002

## Resumen

Esta tesis tiene como objetivo la investigación de técnicas de clasificación para imágenes digitales, en particular para aquellas obtenidas con sensores remotos.

El avance tecnológico permite en la actualidad obtener imágenes hiperespectrales (muestreos continuos de intervalos anchos del espectro), con un volumen de información considerablemente mayor comparado con el que se ha tenido hasta el momento con las imágenes multispectrales. Esto ha llevado a los investigadores a buscar nuevas técnicas de manejo y clasificación que permitan explotar adecuadamente los datos disponibles.

El principal objetivo de esta investigación es encontrar un método de clasificación que de la posibilidad de trabajar con patrones N-dimensionales, y permita integrar información de diferente naturaleza. En este caso particular, se utiliza la información provista por las imágenes hiperespectrales y los datos auxiliares que se tienen sobre el área de estudio en cuestión para la clasificación. En la aplicación planteada en esta tesis, a la información espacial comúnmente utilizada, se le agregan datos de origen espectral.

*El aporte consiste en la presentación de una variación del método conocido como razonamiento evidencial, y a la que referiremos como **Razonamiento Evidencial Dinámico (RED)**. El método RED permite el entrenamiento del clasificador mediante aprendizaje supervisado incorporando nueva evidencia para la clasificación. A su vez establece una regla de decisión diferente, basada en las medidas de plausibilidad, y soporte, pero que también tiene en cuenta la cantidad de fuentes que aportan evidencia. Se considera la incertidumbre asociada a los datos y se analiza si se debe optar por asignar el objeto a la clase con mayor soporte dentro del marco de discernimiento o se debe rechazar dicha asignación por falta de evidencia o por ambigüedad.*

*Se evalúa su comportamiento en **imágenes hiperespectrales de áreas cultivadas** en la región de Nebraska (USA), distinguiendo entre diferentes tipos de cultivos para una etapa específica de su evolución (etapa de crecimiento, media estación). La elección del área de estudio fue definida por la disponibilidad de datos, ya que el Dr. Jordan (Director de Tesis) ha estado en contacto con los integrantes del proyecto “Verde” en USA.*

*Se compara el comportamiento de RED respecto del de los clasificadores convencionales. Por otra parte, se presenta un análisis de diferentes alternativas de decisión evaluándolas respecto de la utilizada por RED. El clasificador propuesto permite mejorar los resultados obtenidos en la clasificación, obteniéndose una precisión promedio de alrededor de un 90% sobre el conjunto de muestras de test.*

**Palabras claves:** *sensado remoto, reconocimiento de patrones, técnicas de clasificación, razonamiento evidencial, procesamiento de imágenes, imágenes hiperespectrales, análisis de cultivos.*

# ***Indice General***

	<b><i>Páginas</i></b>
<b>Agradecimientos</b>	i
<b>Resumen</b>	ii
<b>1. Introducción</b>	
1.1. Conceptos introductorios	1
1.2. Objetivos de la tesis	2
1.3. Importancia de la presente investigación	3
1.4. Conocimientos de base	4
1.4.1. Imagen digital	4
1.4.2. Imágenes multiespectrales e hiperespectrales	4
1.5. Conceptos principales de la clasificación de imágenes	5
1.6. Estado del arte en la clasificación de imágenes	6
1.7. Organización de la tesis	7
1.8. Conclusiones del capítulo	8
<b>2. Conocimiento de base</b>	
2.1. Definición de Sensado remoto	10
2.2. Radiación electromagnética	12
2.3. Concepto de longitud de onda y frecuencia	12
2.4. Espectro electromagnético	13

2.5. Imágenes multiespectrales e hiperespectrales. Ejemplos.	15
2.6. Reflexión, absorción y transmisión	17
2.7. Sensado remoto y aplicaciones que involucran vegetación	19
2.8. Importancia de las medidas de textura	21
2.9. Conclusiones del capítulo	23
<b>3. Presentación del problema de aplicación</b>	
3.1. Descripción	24
3.2. Material de trabajo	26
3.3. Mapa del área de estudio	29
3.4. Metodología propuesta	30
3.5. Conclusiones del capítulo	33
<b>4. Clasificación y reconocimiento de patrones. Estado del arte en clasificación en el área de sensado remoto</b>	
4.1. Definiciones y conceptos	34
4.2. Clasificación supervisada vs. no supervisada	38
4.3. Clasificadores utilizados en el área de sensado remoto	39
4.4. Métodos basados en modelos biofísicos	59
4.5. Método de razonamiento evidencial	60

4.6. Matriz de confusión e indicador Khat	69
4.7. Conclusiones del capítulo	71
<b>5. Método propuesto: Razonamiento Evidencial Dinámico</b>	
5.1. Introducción	72
5.2. Descripción del método	73
5.3. Objetivos	81
5.4. Comparación teórica con los métodos convencionales	83
5.5. Conclusiones del capítulo	86
<b>6. Aplicación del razonamiento evidencial dinámico</b>	
6.1. Introducción	87
6.2. Resultados obtenidos	92
6.2.1. Análisis del proceso de aprendizaje	92
6.2.2. Evaluación del Clasificador y de su regla de decisión	99
6.2.2.1. Análisis de la precisión de RED para diferentes conjuntos de test	100
6.2.2.2. Análisis de la influencia de la regla de decisión propuesta por RED	102
6.2.2.3. Análisis comparativo de RED	106
6.3. Conclusiones del capítulo	111
<b>7. Conclusiones y líneas de investigación futuras</b>	112
<b>8. Referencias y bibliografía</b>	114

<b>Anexo A:</b> Breve reseña sobre la evolución de los sensores remotos	130
<b>Anexo B:</b> Presentación del desarrollo del algoritmo RED	136

# CAPITULO 1

## Introducción

### 1.1. Conceptos introductorios

Desde la antigüedad el hombre ha buscado clasificar a los seres y objetos de su alrededor, y de esta forma ha logrado grandes avances en el entendimiento y estudio de la naturaleza y del mundo en general. Por ejemplo, los seres vivos se dividieron en reinos, géneros, familias, especies, etc., de acuerdo a ciertas características que los hacen similares y otras que los distinguen. Se ha clasificado a los objetos según el material del que están formados, su función o algún otro criterio de interés.

Con el avance de la informática y la tecnología, se ha despertado la inquietud por lograr automatizar el proceso de clasificación. Así, hoy día encontramos sistemas que permiten distinguir frutas en una cinta transportadora, para su almacenamiento, o también controlar la calidad de las mismas para su desecho o conservación. En particular, la rama de la informática conocida como procesamiento de imágenes digitales ha tenido mucho que ver al respecto. Abarca distintas etapas que van desde la adquisición de los datos de entrada, pasando por el mejorado, segmentación, hasta el análisis, clasificación e interpretación de la imagen [Bax94][Gon92][Jai89].

Otra área que ha crecido en los últimos tiempos es la de sensado remoto o “remote sensing”, donde se puede encontrar una gran variedad de aplicaciones. Entre ellas, se mencionan la clasificación de bosques, y cultivos, según distintos criterios (por ejemplo en el caso de los cultivos se analiza el nivel de estrés)[www2][www3][www4]. También, se ha avanzado en el estudio de rocas, tipos de suelo, etc. Principalmente, se puede decir que las aplicaciones de sensado remoto contribuyen al monitoreo y control de los recursos de la superficie terrestre.

Clasificar e identificar posibles problemas que se presentan en alguna área geográfica en particular, es un objetivo no sólo de interés científico sino también gubernamental

que puede permitir evitar catástrofes como inundaciones, incendios, plagas, condiciones climatológicas adversas, etc.

## **1.2. Objetivos de la tesis**

El análisis automatizado de los datos sensados remotamente está caracterizado por volúmenes crecientes de datos, así como por la integración de información espectral y espacial. La habilidad para combinar información proveniente de diversas fuentes es un tema de investigación actual [www15].

Los clasificadores convencionales no fueron diseñados para procesar conjuntos de datos de alta dimensión, y muchos de ellos requieren que estos datos presenten una distribución estadística particular (como puede ser Gaussiana o normal), ya que se basan en modelos estadísticos paramétricos [Dud73][Ped93]. Sin embargo, las imágenes espectrales de alta resolución y muchos de los datos auxiliares no responden a esta hipótesis por lo que los algoritmos paramétricos suelen resultar inadecuados.

Entre los muchos métodos, que se aplican actualmente para la clasificación de este tipo de imágenes se encuentran los que utilizan redes neuronales, los que usan los conceptos de la lógica difusa, y los basados en la teoría matemática de la evidencia (Shafer, 1976), como el método de razonamiento evidencial propuesto en [Ped95a].

Esta tesis propone una modificación de la técnica de razonamiento evidencial, la cual se denomina **razonamiento evidencial dinámico** y se aplica para la clasificación de cultivos en imágenes **hiperespectrales** obtenidas por sensado remoto. La modificación planteada consiste en permitir la incorporación de nueva evidencia para el clasificador, con el objetivo de mejorar su precisión. En otras palabras, el método propuesto permite realizar un proceso de entrenamiento para el clasificador mediante aprendizaje supervisado, y de esta manera se incorpora nueva evidencia para las diferentes clases y fuentes con las que se trabaja.

Además presenta una nueva regla de decisión que busca elegir la opción más apropiada en la asignación de un objeto a una clase en dos situaciones: **a)** cuando la clase es la que tiene el mayor soporte, pero aún así la evidencia no es suficiente para asignarlo a la misma (por ejemplo la evidencia puede ser aportada sólo por una de las fuentes), **b)** cuando varias clases tienen soporte similar al máximo. Para ambos casos se probaron y analizaron distintas posibilidades de decisión.

Como métrica para la evaluación de la precisión del clasificador se utiliza el indicador Khat y la matriz de confusión [Lil94][Con83][Ros86].

En esta tesis, también se realiza una comparación teórica del método en cuestión con los clasificadores convencionales, muchos de los cuales, como ya se mencionó, no permiten un manejo y análisis adecuado de la cantidad de datos provistos por las imágenes hiperespectrales.

### **1.3. Importancia de la presente investigación**

Las imágenes hiperespectrales constituyen un nuevo desafío para los involucrados en el área de "remote sensing" y clasificación, y hasta el momento no han sido explotadas lo suficiente [Gat97][Jen96][www2]. Este tipo de imágenes, provee información detallada sobre los recursos de la superficie terrestre.

Poder tomar ventaja de esta información y de la disponible a partir de otras fuentes, depende de nuestra habilidad para encontrar métodos adecuados que permitan procesarla y obtener resultados que ayuden a la toma de decisiones y la detección temprana de problemas (ejemplo: falta de irrigación para áreas con cultivos).

Se busca a través del razonamiento evidencial dinámico proveer un método que sea capaz de utilizar la información disponible de cualquier naturaleza (ya sea espectral, espacial y/o temporal) y obtener los resultados esperados en la clasificación.

Se aplica el método para clasificar diferentes tipos de cultivos en su etapa de crecimiento en un área geográfica específica, utilizando imágenes hiperespectrales obtenidas con el sensor *Casi* [www17].

## 1.4. Conocimiento de base

### 1.4.1. Imagen digital [Bra94][Jai89][Lim90]

Una imagen digital puede definirse como una función discreta  $f(x, y) = z$ , donde  $x$  e  $y$  son las coordenadas espaciales (determinan la resolución espacial) y  $z$  es el valor que toma la imagen en esas coordenadas. Ese valor generalmente indica la intensidad de la luz, que es cuantificada para que se encuentre dentro de un rango de valores (comúnmente va de 0 a 255 debido a que se utilizan 8 bits para codificar los niveles de gris). Estas imágenes se conocen como imágenes en escala de grises.

También se puede definir una imagen digital como una matriz, de dimensión genérica  $N \times M$ . Cada par de coordenadas denota un elemento de la imagen que se conoce como **pixel (picture element)**. Cada pixel incorpora el nivel de luminosidad del punto correspondiente de la escena digital. A pesar de que el tamaño de una imagen digital varía de acuerdo a la aplicación, resulta ventajoso trabajar con matrices cuadradas cuya dimensión y cantidad de niveles de gris sean potencia de 2.

Una imagen digital color RGB consta de tres planos, uno para el rojo (RED), uno para el verde (GREEN), y otro para el azul (BLUE). Es decir, que en este caso se habla de una función  $f(x, y)$  que devuelve un vector de tres componentes, donde cada componente es el valor de intensidad correspondiente al plano en cuestión. Por ejemplo:  $f(10, 50) = [140, 200, 145]$ . Este vector indica que para las coordenadas (10, 50), el plano rojo toma un valor de intensidad de 140, el plano verde de 200 y el azul de 145.

### 1.4.2. Imágenes multispectrales e hiperspectrales [Gat97][www1]

La energía solar se transmite a la tierra en forma de ondas de luz, y es reflejada, absorbida o transmitida por los materiales de la superficie terrestre. La energía reflejada viaja e interactúa con la atmósfera, y luego es registrada por un sensor montado ya sea en un avión o un satélite. Este registro es cuantificado como un número digital, que se corrige y se almacena como un elemento de imagen o pixel. Todos los píxeles forman una imagen del área sensada.

Para convertir la imagen de la radiación de la superficie en reflectancia se requiere remover el efecto de la atmósfera a través de la calibración atmosférica. Se denomina **radiación** a la medida de la energía irradiada por el objeto, junto con la frecuencia de distribución de la radiación y por **reflectancia** al cociente entre la luz reflejada desde el destino y la luz incidente.

La tecnología de los 50' y 60' dio origen a instrumentos satelitales (serie Landsat) que miden solamente 7 grupos distintos de longitudes de onda o bandas. Las imágenes resultantes de este tipo de instrumentos se conocen como **multiespectrales**.

El concepto de imagen **hiperespectral** surge alrededor de 1980, primero con el "Airborne Imaging Spectrometer" y luego con el "Advance Visible and Infrared Imaging Spectrometer" (AVERIS). Estas imágenes tienen un tamaño bastante mayor y cubren un área mucho más pequeña, pero con una resolución más alta respecto de la de las multiespectrales (píxeles de 1m x 1m por ejemplo). Además, las bandas son más angostas. Esto da la información necesaria para la clasificación e identificación de materiales de la superficie terrestre que no podían distinguirse con las imágenes multiespectrales.

### **1.5. Conceptos principales de la clasificación de imágenes**

Clasificar involucra categorizar los píxeles de una imagen digital en clases o temas. Cuando se tienen imágenes multiespectrales o hiperespectrales, generalmente se toma el patrón espectral de cada píxel para la clasificación. Este patrón se refiere al conjunto de medidas de radiación obtenidas en varias bandas de longitud de onda para cada píxel.

El reconocimiento de patrones espacial involucra la categorización de píxeles de la imagen sobre la base de la relación espacial que guarda con los píxeles que lo rodean. Pueden considerarse aspectos como textura, proximidad, tamaño de rasgo, forma, direccionalidad, repetición, y contexto, y se intenta imitar el análisis humano [Li194].

El reconocimiento de patrones temporal usa el tiempo como una ayuda en la identificación de rasgos.

En esta tesis se trabaja en forma conjunta con la información espectral y espacial. Se sabe que uno puede mejorar el entendimiento de la imagen combinando ambos tipos de datos. Este análisis combinado puede considerarse como "Fusión de datos" (o "data fusion").

### **1.6. Estado del arte en la clasificación de imágenes**

En la actualidad, existen numerosos métodos de clasificación. El reconocimiento de patrones es una de las ramas involucradas en la clasificación de imágenes digitales.

Los métodos de clasificación pueden ser divididos en dos categorías: los supervisados y los no supervisados. Los primeros son aquellos en los que existe un control en el proceso de categorización, determinándose un conjunto de muestras representativas de las cuales se indica la clase a la que pertenecen. Los segundos son métodos, donde se agrupan los píxeles, sin intervención humana, de acuerdo a su similitud natural.

Entre los métodos de clasificación supervisada, los más utilizados en sensado remoto son los basados en relaciones estadísticas, como puede ser el clasificador de máxima verosimilitud, el de Bayes y el del paralelepípedo. También, se utilizan métodos basados en distancia mínima, por ejemplo euclidiana.

Respecto de los algoritmos de clasificación no supervisada, se usan principalmente los conocidos como k-medias y el ISODATA. Todos estos se analizarán en forma detallada en el capítulo 5.

Las redes neuronales han sido una novedad en los últimos años y se han estado empleando en numerosas aplicaciones. Entre sus principales ventajas, se menciona el hecho de no ser lineales, y de no requerir un modelo fenológico para describir la distribución de los datos, ya que pueden aprender a partir de muestras.

Otro enfoque utilizado es el del método de razonamiento evidencial que toma en cuenta la incertidumbre asociada a los datos y no requiere de una distribución estadística conocida a priori para trabajar, esto permite superar algunas de las dificultades encontradas en los distintos algoritmos basados en modelos estadísticos.

Para aplicaciones específicas de sensado remoto, se han empezado a utilizar técnicas donde la clasificación se basa en modelos biofísicos y se simulan los diferentes factores involucrados en la formación de la imagen. Por ejemplo, para el análisis de regiones donde hay vegetación presente, se usan los conocidos como índices de vegetación.

## **1.7. Organización de la tesis**

Este capítulo presenta una breve descripción de las imágenes multiespectrales e hiperespectrales. Se resumen los problemas encontrados para la clasificación de tales imágenes, y se plantean los objetivos del trabajo propuesto y su importancia. También se realiza una breve introducción al método propuesto: razonamiento evidencial dinámico.

El **capítulo 2**, “Conocimiento de base”, provee los conceptos generales de "remote sensing" como longitud de onda, frecuencia, y espectro electromagnético. Ejemplos de imágenes multiespectrales e hiperespectrales. Se introducen los aspectos relacionados con el "remote sensing" para aplicaciones que involucran vegetación. Se definen los índices de vegetación, en particular NDVI (“Normalized Difference Vegetation Index”). Se incluye una descripción de las métricas utilizadas para la evaluación de la precisión en la clasificación.

En el **capítulo 3**, “Presentación del problema de aplicación”, se describe la aplicación específica para la que se utiliza el método propuesto y la metodología utilizada. Se presenta el material de trabajo, tipo de imágenes, y métodos de adquisición de las mismas. También aquí se especifica el área geográfica a estudiar.

En el **capítulo 4**, “Clasificación y reconocimiento de patrones”, se definen los conceptos involucrados en la clasificación y reconocimiento de patrones (como la definición de lo que es un rasgo, un patrón y una clase). Se detalla la división de los métodos de clasificación en supervisados y no supervisados. Se presenta una descripción de los algoritmos más utilizados de ambos tipos de clasificación, entre ellos el clasificador de Máxima Verosimilitud, Bayes, K-medias e Isodata. Para estos últimos se dan una serie de ejemplos de acuerdo a estudios realizados. Se describe el razonamiento evidencial en particular.

En el **capítulo 5**, “Método propuesto: Razonamiento evidencial dinámico”, se introduce el razonamiento evidencial dinámico, indicando los objetivos a alcanzar. Se describe el funcionamiento del mismo. También se realiza una comparación teórica de este método respecto de los tradicionales.

En el **capítulo 6**, “Aplicación del razonamiento evidencial dinámico”, se detallan los resultados obtenidos a partir de la aplicación del razonamiento evidencial dinámico. Se evalúan los resultados utilizando la matriz de confusión y el indicador Khat y se analiza tanto el proceso de aprendizaje como la regla de decisión introducida. Se compara con distintas posibilidades para la regla de asignación.

En el **capítulo 7**, “Conclusiones y líneas de investigación futuras”, se dan algunas conclusiones, y líneas de trabajo futuras. Se detallan algunos comentarios finales y opiniones personales.

## **1.8. Conclusiones**

El análisis automático de los datos sensados remotamente se ve favorecido por los crecientes volúmenes de información y por lo costoso que resulta trabajar con datos reales de suelo. Los nuevos satélites y sensores permiten tener datos de alta resolución, lo cual incrementa la necesidad de encontrar buenos métodos para el análisis y procesamiento de esta información. Estas técnicas, requieren tener la capacidad de integración de datos espaciales y espectrales, y de cualquier otro tipo de dato auxiliar que resulte de interés.

Las imágenes hiperespectrales constituyen un avance en la tecnología de sensores remotos y un desafío para los investigadores.

Actualmente, una de las técnicas que se utiliza para la clasificación de estas imágenes es la de redes neuronales. Asimismo se utilizan clasificadores estadísticos como el de máxima verosimilitud, que no demuestran ser los más adecuados para el procesamiento de un número considerable de variables de entrada.

Se presenta un método de clasificación razonamiento evidencial dinámico, basado en el razonamiento evidencial, que arroja los resultados esperados para las imágenes hiperespectrales en una aplicación de clasificación de cultivos. ◆

## CAPITULO 2

### Conocimiento de base

Esta sección está dedicada a introducir los conocimientos básicos necesarios referidos a "remote sensing" que permitirán dar un contexto y mayor entendimiento al presente trabajo.

#### 2.1. Definición de Sensado Remoto

Entre las definiciones dadas a "remote sensing" se menciona y analiza la siguiente:

- Es la ciencia o arte de obtener información sobre un objeto, área o fenómeno a través del análisis de datos obtenidos por un *dispositivo que no tiene un contacto físico* con dicho objeto, área o fenómeno [Jen96][Sch97][www9][www16]

Si se detiene la atención en esta definición se encuentra que:

- a) Existe un objeto, área o fenómeno de interés a investigar
  - Generalmente, los científicos están interesados en estudiar fenómenos naturales y recursos de la superficie terrestre. Por ejemplo: fenómenos meteorológicos, cultivos, discriminación de zonas urbanas y rurales, etc.
- b) Se tiene un dispositivo que está a una distancia del objeto de interés y que permite obtener datos del mismo
  - Los dispositivos a los que se hace referencia se conocen como sensores que permiten capturar la relación espectral y espacial de los objetos y materiales observables a distancia. Existen diferentes tipos de sensores. En particular estamos interesados en aquellos que permiten registrar la radiación electromagnética.
- c) Se realiza un análisis de los datos para obtener información.

- El análisis de los datos obtenidos mediante el sensor involucra tareas de identificación y categorización de dichos datos en clases o tipos para extraer información sobre el objeto bajo investigación.

La definición anteriormente expresada se puede ilustrar con un proceso cotidiano y muy natural.



Figura 2.1 - Ejemplo de proceso de sensorado remoto

Algo físico (luz), es emanado desde la pantalla (fuente de radiación) que pasa a la distancia (por eso se dice que es remoto), hasta encontrar y ser capturado por un sensor que en este caso son los ojos. Luego se envía una señal a un procesador para realizar el análisis (nuestro cerebro). Los sentidos humanos permiten tomar conciencia del mundo exterior percibiendo una variedad de señales ya sea emitidas o reflejadas,

activa o pasivamente desde objetos que transmiten esta información en forma de ondas o pulsos (**Figura 2.1**).

Así se pueden reconocer, por ejemplo, formas, colores y posiciones relativas de los objetos exteriores y clases de materiales, por medio de muestreos de la luz visible que emana desde estos objetos. También nuestro oído puede captar los sonidos del medio, que se desplazan en la atmósfera en forma de ondas. Sin embargo, en la práctica no se piensa usualmente en nuestros sentidos corporales como sensores remotos en la forma en que el término es aplicado para el uso técnico.

La definición más formal de sensorado remoto que se ha expresado al comienzo, involucra técnicas que recolecten conocimiento pertinente a los ambientes por medio de la medición de campos de fuerza, radiación electromagnética, o energía acústica

usando cámaras, láseres, receptores de frecuencia de radio, sistemas de radar, dispositivos termales, sismógrafos, magnetómetros, etc.

*El sensado remoto involucra la detección y medición de los fotones de las diferentes energías que emanan de los materiales a distancia, por medio de los cuales se los puede identificar y categorizar en clase o tipo, sustancia y distribución espacial.*

## **2.2. Radiación electromagnética**

Normalmente los sensores remotos registran la radiación electromagnética (EMR) que viaja a una velocidad de  $3 \times 10^8$  metros/seg. desde la fuente, directamente a través del espacio o indirectamente por reflexión, al sensor [Ang97][www6].

La EMR representa un enlace de comunicación de alta velocidad entre el sensor y el fenómeno ubicado remotamente. Es una forma dinámica de energía que se pone de manifiesto por su interacción con la materia.

Los cambios en la cantidad y propiedades de la radiación electromagnética, cuando son detectados, son una valiosa fuente para la interpretación de importantes propiedades de la materia con la cual interactúa.

## **2.3. Concepto de longitud de onda y frecuencia**

La luz es una de las muchas formas de energía electromagnética, otros tipos de onda son las de radio, calor, rayos X, ultravioletas, etc. La energía electromagnética se describe como una onda sinusoidal armónica, que viaja a la velocidad de la luz (ver Ecuación 2.1). Las ondas obedecen a la ecuación general:

$$c = v\lambda \quad (\text{Ec 2.1})$$

Donde,

$\lambda$  es la **longitud de onda** o "**Wavelength**"

v es la **frecuencia** (Figura 2.2)

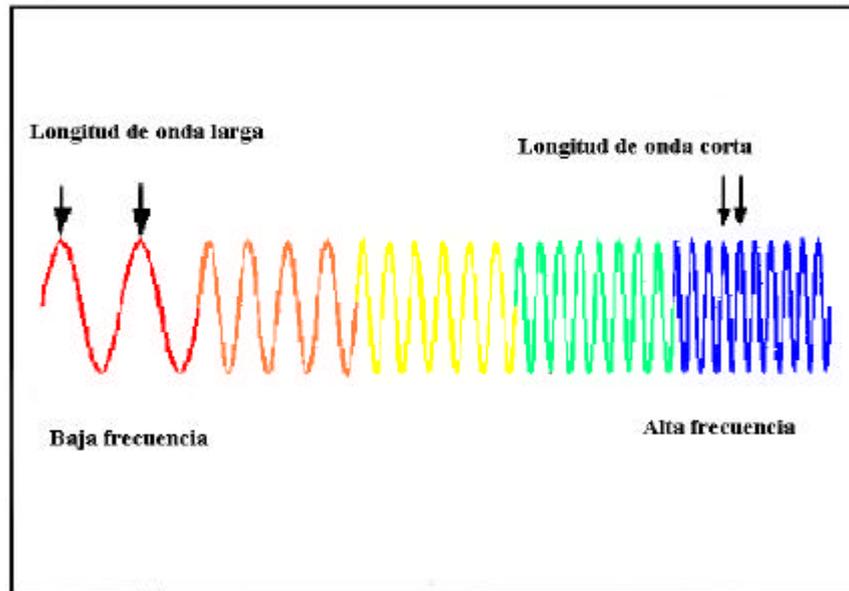


Figura 2.2 – Concepto de frecuencia y de longitud de onda

## 2.4. Espectro electromagnético

En "remote sensing", es común categorizar las ondas por la ubicación de su longitud de onda en el espectro electromagnético, que se mide en micrómetros ( $1 \times 10^{-6}$  metros) [Li194]. No hay una división exacta entre una región espectral nominal y la siguiente; las divisiones del espectro han crecido, principalmente debido a los diferentes métodos de sensado para cada tipo de radiación.

Cada uno de estos tipos de onda comprende un intervalo definido por una magnitud característica que puede ser la longitud de onda o la frecuencia. La sensibilidad espectral del ojo humano se extiende desde 0.4 micrómetros a los 0.7 micrómetros. A continuación se presentan algunas de las regiones o intervalos en que se dividió el espectro y que reciben nombres descriptivos:

Azul: 0.4 a 0.5  $\mu\text{m}$

Verde: 0.5 a 0.6  $\mu\text{m}$

Rojo: 0.6 a 0.7  $\mu\text{m}$

Ultravioleta (UV): la energía se adjunta a la terminación azul de la parte visible del espectro.

Existen tres categorías que se adjuntan a la parte final roja del espectro visible:

- Infrarrojo cercano (Near IR): 0.7 a 1.3  $\mu\text{m}$
- Infrarrojo medio: 1.3 a 3  $\mu\text{m}$
- Infrarrojo termal: después de 3  $\mu\text{m}$

Microonda: va de 1mm a 1 m (ondas mucho más largas que las anteriores)

La mayoría de los sistemas de sensado operan en una o varias de las porciones visibles, en el infrarrojo o microondas del espectro. Sólo la energía del infrarrojo termal está relacionada directamente con la sensación de calor.

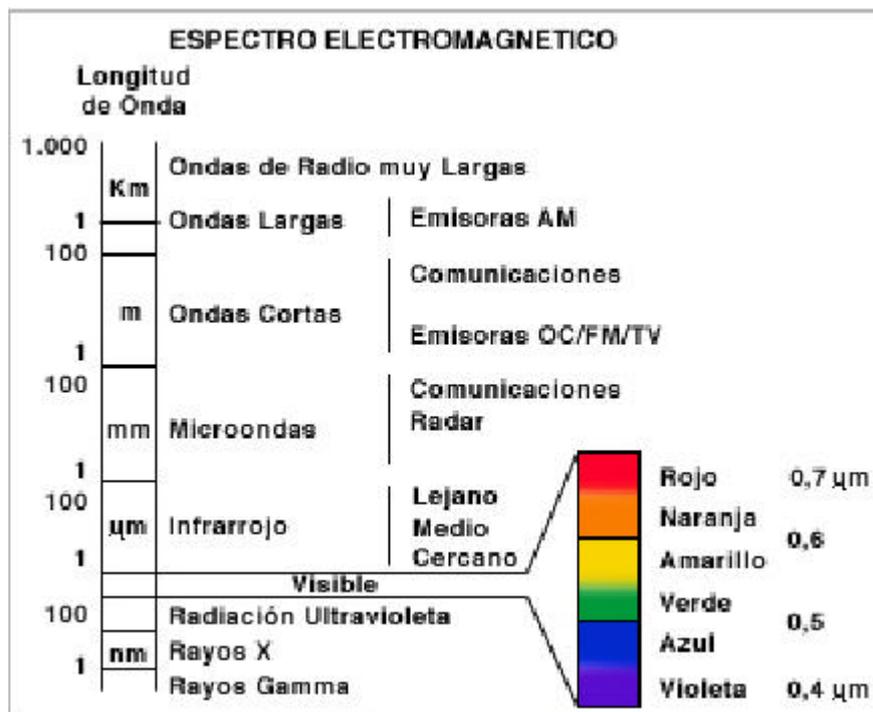


Figura 2.3 - Espectro electromagnético

## 2.5. Imágenes multiespectrales e hiperespectrales. Ejemplos.

Las imágenes multiespectrales son imágenes corregistradas de la Tierra en algunos colores discretos o bandas espectrales. Dichas bandas del espectro son anchas, y se obtienen en blanco y negro, en longitudes de onda precisas (usualmente entre 0.4 a 12.0 micrómetros). Las cámaras electrónicas pueden recolectar información solamente en blanco y negro, pero pueden obtener muchas imágenes al mismo tiempo en diferentes partes del espectro.

Si observamos la **Figura 2.3**, podemos ver regiones amplias que incluyen las longitudes de onda ultravioleta (0.3 - 0.4 micrómetros), visible (0.4 a 0.7 micrómetros), cercano-infrarrojo (0.7 a 1.3 micrómetros), el medio-infrarrojo (1.3 a 3 micrómetros), y el infrarrojo termal (a partir de 3 micrómetros). Estas son generalmente las bandas obtenidas por un escáner **multiespectral**. Los satélites Landsat introdujeron la tecnología multiespectral en los años 60', y transmiten los valores reflejados para 6 bandas con píxeles de 30 m, y 1 banda termal infrarroja donde los píxeles son de 100 x 100 metros.

Los sensores de imágenes espectrales continuaron mejorando en cuanto a resolución espacial y espectral (ver **Anexo A**). Actualmente, los sistemas **hiperespectrales** proveen de diez a cientos de bandas, lo que hace que estas imágenes sean usadas para una variedad de aplicaciones. Ejemplos de estos sensores son los Casi (desde 10 bandas), AVIRIS (210 bandas), etc. con resolución de muestras de suelo que varían desde 1m a 20m, dependiendo de la altitud de la plataforma desde la que se colectan los datos. El producto o salida de estos sensores es una pila de imágenes de la escena, adquirida en bandas continuas sobre un rango espectral, y se denomina a menudo como cubo de imagen. Estas imágenes son referidas como **hiperespectrales**, debido a su alta resolución espectral y a la gran cantidad de canales, en contraste con las imágenes obtenidas con sensores como el del Landsat TM, SPOT, Daedulas, etc., referidas históricamente como multiespectrales [Ust98][www1]. En las **Figuras 2.4 y 2.5**, se pueden observar las diferencias entre ambos tipos de imágenes.

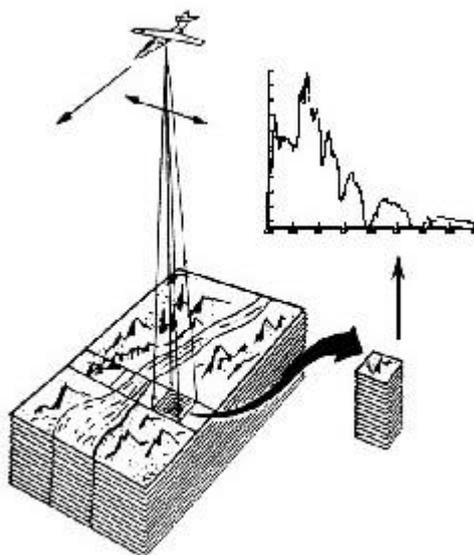


Figura 2.4 – Imagen Hiperespectral

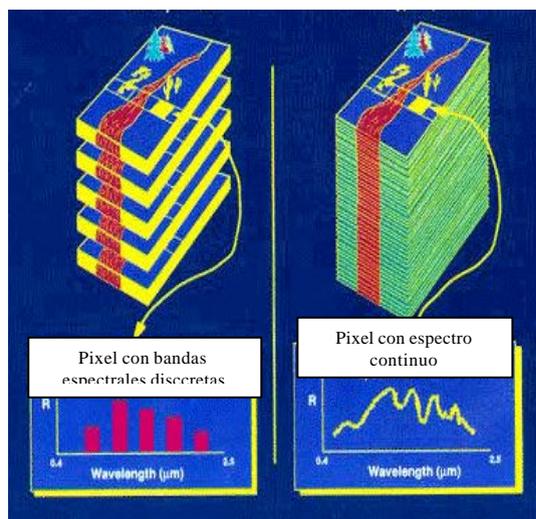


Figura 2.5 - Comparación entre imagen multispectral e hiperespectral [Ust98]

## **2.6. Reflexión, absorción y transmisión**

La fuente principal de excitación de energía usada para iluminar destinos naturales es el sol. Los rayos solares pasan a través de la atmósfera y una fracción de la energía al interactuar con los materiales de la superficie de la Tierra, es absorbida o reflejada, mientras que el resto es transmitida o refractada. Si el cuerpo con el que choca la luz es opaco, una parte de la energía es reflejada y el resto absorbida, si es transparente, una parte será absorbida y el resto atravesará el cuerpo transmitiéndose.

Entonces se pueden mencionar los siguientes tipos de interacción de la energía electromagnética con los materiales: **reflexión, absorción y transmisión o refracción** [Ang97][Fol96]. La cantidad de energía que es reflejada, transmitida o absorbida varía de acuerdo a la longitud de onda y el tipo de material. Esta propiedad de la materia es importante porque permite identificar y separar diferentes clases o sustancias por sus curvas espectrales. Dentro de la porción visible del espectro, estas variaciones resultan en el efecto visual que se conoce como *color*. Por ejemplo, se dice que un objeto es “azul” cuando refleja una alta cantidad de energía en la porción azul del espectro.

**Reflexión:** es el fenómeno que se produce cuando la luz choca contra la superficie de separación de dos medios de distinta densidad (ya sean gases como la atmósfera, líquidos como el agua o sólidos), la dirección en que sale la luz reflejada está determinada por el tipo de superficie. Si es una superficie brillante o pulida se produce la reflexión regular en que toda la luz sale en una única dirección. Si es mate y la luz sale desperdigada en todas las direcciones se llama reflexión difusa. Y por último, está el caso intermedio, reflexión mixta, en que predomina una dirección sobre las demás. Esto se da en superficies metálicas sin pulir, barnices, papel brillante, etc.

Las características de reflectancia de los rasgos de la superficie terrestre pueden ser cuantificados midiendo la porción de energía incidente que es reflejada. La medición se realiza como una función de la longitud de onda, llamada reflectancia espectral,  $\rho_{\lambda}$ .

$$r_{\lambda} = E_R(\lambda) / E_I(\lambda) \quad (\text{Ec 2.2})$$

donde,  $E_R(\lambda)$ : es la energía reflejada desde el objeto en la longitud de onda  $\lambda$

$E_I(\lambda)$ : es la energía incidente en el objeto en la longitud de onda  $\lambda$

$r_{\lambda}$  se expresa como porcentaje.

En principio, varios tipos de materiales de la superficie pueden ser reconocidos o distinguidos unos de otros por las diferencias en la reflectancia espectral.

**Refracción:** se produce cuando un rayo de luz es desviado de su trayectoria al atravesar una superficie de separación entre medios de diferentes densidades. Esto se debe a que la velocidad de la luz en cada uno de ellos es diferente.

**Transmisión:** se puede considerar una doble refracción. Si pensamos en un cristal, la luz sufre una primera refracción al pasar del aire al vidrio, sigue su camino y vuelve a refractarse al pasar del vidrio al aire. Si después de este proceso el rayo de luz no es desviado de su trayectoria se dice que es una transmisión regular como pasa en los vidrios transparentes. Si se difunde en todas direcciones tenemos la transmisión difusa como ocurre con los vidrios translúcidos. Y si predomina una dirección sobre las demás tenemos la mixta como ocurre en los vidrios orgánicos o en los cristales de superficie labrada.

**Absorción:** es un proceso muy ligado al color. El ojo humano sólo es sensible a las radiaciones de un pequeño intervalo del espectro electromagnético. Las componentes reflejadas son las que determinan el color que percibimos, el resto son absorbidas. Si refleja todas es blanco y si absorbe todas es negro.

Estrictamente, las medidas espectrales involucran interacciones entre las radiaciones de iluminación y las estructuras atómicas o moleculares de cualquier material.

## **2.7. Sensado remoto y aplicaciones que involucran vegetación**

La recolección de información precisa en el tiempo, sobre cultivos u otro tipo de recurso de la superficie terrestre es siempre importante. Sin embargo, suele resultar cara, consume mucho tiempo y a menudo es imposible, si se realiza utilizando técnicas “in situ”. Otra alternativa es realizar las mediciones, en base al análisis de las mediciones espectrales de sensado remoto.

La mayor parte de la investigación desarrollada en esta área involucra el análisis de los datos obtenidos con satélites (Landsat MSS y TM, SPOT HRV, etc.) y técnicas de procesamiento de imagen digital. El objetivo ha sido reducir las múltiples bandas de datos a un sólo número por pixel, que prediga o evalúe las características como biomas, productividad, índice de área con hojas (LAI: Leaf Area Index), y/o porcentaje de suelo cubierto con vegetación. Para ello se viene trabajando con varios algoritmos para extraer tal información a partir de los datos sensados remotamente, que se conocen como Índices de Vegetación [Lil94][Jen96][Pra98][www2]. Los índices de vegetación se basan en el tipo de interacción de los vegetales con la energía solar, la cual se explica a continuación.

La vegetación verde y sana se caracteriza por tener una curva de reflectancia espectral donde aparecen picos y valles. Los valles en la porción visible del espectro se deben a los pigmentos en las hojas de las plantas. Por ejemplo, la clorofila absorbe en gran medida la energía en las bandas de longitud de onda centradas alrededor de los 0.45 y los 0.67 micrómetros (azul y rojo visibles). Estos colores son absorbidos mientras que la parte visible concentrada en el verde es en parte reflejada (por eso la mayoría de la vegetación se caracteriza por el color de las hojas verdes). Si una planta está sujeta a alguna forma de “estrés”<sup>\*</sup> que interrumpe su normal desarrollo, es posible que decremente o cese su producción de clorofila. Esto provoca una menor absorción de la clorofila en las bandas azul y roja, y normalmente la reflectancia en

---

<sup>\*</sup> Proceso que afecta el normal desarrollo de una planta. Puede producirse por la presencia de alguna plaga, deficiencia de agua, enfermedad, etc.

la banda roja aumenta de tal manera que la planta se torna amarilla (combinación del rojo y verde).

Los picos se deben a la alta reflectancia entre los 0.7 y 1.3 micrómetros (infrarrojo cercano o Near IR) producidos por la interacción con las células mesofílicas\* de las hojas. La intensidad de esta reflectancia es comúnmente mayor que la de los materiales inorgánicos, de forma tal que la vegetación se describe como brillante en el infrarrojo cercano. Estas variaciones espectrales facilitan la detección, identificación y monitoreo precisos de la vegetación sobre la superficie terrestre.

Uno de los primeros índices de vegetación exitosos basados en radio de bandas fue desarrollado por Rouse, y computa la diferencia normalizada de los valores de brillo de la banda MSS7 y la MSS5. Se lo conoce como índice de vegetación de diferencia normalizada (NDVI). Deering agregó 0.5 al NDVI y le tomó la raíz cuadrada, produciendo el índice de vegetación transformado o TVI. Algoritmos similares usan MSS6 y MSS5:

$$NDVI6 = (MSS6-MSS5) / (MSS6+MSS5) \quad \text{(Ec 2.3 a)}$$

$$NDVI7 = (MSS7-MSS5) / (MSS7+MSS5) \quad \text{(Ec 2.3 b)}$$

$$TVI6 = SQRT(NDVI6+ 0.5) \quad \text{(Ec 2.3 c)}$$

$$TVI7 = SQRT(NDVI7+0.5) \quad \text{(Ec 2.3 d)}$$

Dado que muchos dispositivos de sensado remoto operan en las regiones del verde, rojo, y en el infrarrojo cercano del espectro, actúan como discriminadores de las variaciones en la radiación que mide tanto los efectos de la absorción como los de la reflectancia asociada con la vegetación.

Una de las aplicaciones más exitosas de las imágenes espaciales-espectrales es su habilidad para monitorear el estado de la producción de agricultura en el mundo. Esto incluye la capacidad de identificar y diferenciar entre los distintos tipos de cultivos (soja, cereales, arroz, etc.). Bajo circunstancias adecuadas, el “estrés” de los

---

\* Células que conforman los tejidos presentes entre la capa superior e inferior de la epidermis de la hoja, generalmente son las responsables de la fotosíntesis de la mayoría de las plantas.

cultivos (generalmente la deficiencia de la humedad) puede ser detectado y a veces tratada efectivamente antes que los propios trabajadores del campo se den cuenta del problema.

A la información espectral suele ser necesario agregar otros parámetros auxiliares como el tamaño y forma de los tipos de cultivos, superficie de las hojas individuales, la altura de la planta y el espaciado u otra geometría de las filas de plantaciones de los cultivos (arreglo normal de las legumbres, huertas de frutas, etc.). La etapa de crecimiento (grado de maduración) es otro factor, ya que durante su desarrollo la planta pasa por distintos estados en su tamaño, forma y color.

Todos estos factores combinados traen de pequeñas a grandes diferencias en señales espectrales para los distintos cultivos. Generalmente, las señales para diferentes cultivos en una región particular deben ser determinadas por muestras representativas en tiempos específicos.

## **2.8. Importancia de las medidas de textura**

Una característica importante de una imagen es su textura. Los rasgos de textura son muy usados para la segmentación de regiones [Har92][Jen96][Ped91][Wu98]. A pesar de esto, no existe un acuerdo universal y único sobre la definición de la textura de una imagen. Se puede decir que es una medida de la regularidad, suavidad, y aspereza de la imagen. Las técnicas de descripción de textura pueden ser agrupadas en 3 grandes clases: estadística, espectral y estructural.

Los descriptores estadísticos se basan en los histogramas de una región, sus extensiones y sus momentos; miden el contraste, la granularidad, y aspereza. Las técnicas espectrales están basadas en la función de autocorrelación de la región o en el poder de distribución en el dominio de la transformada de Fourier, para detectar la periodicidad de la textura. Finalmente, las técnicas estructuradas describen la textura usando primitivas de patrones acompañadas por reglas de localización. Sea  $f_k$ ,  $k= 1, \dots, N$ , los niveles de intensidad de la imagen. Los primeros cuatro momentos están dados por:

1. Media:

$$\mathbf{m} = \sum_{k=1}^N f_k p(f_k) \quad (\text{Ec 2.4})$$

2. Varianza:

$$\mathbf{s}^2 = \sum_{k=1}^N (f_k - \mathbf{m})^2 p(f_k) \quad (\text{Ec 2.5})$$

3. Simetría (“Skewness”):

$$\mathbf{m}_3 = \frac{1}{\mathbf{s}^3} \sum_{k=1}^N (f_k - \mathbf{m})^3 p(f_k) \quad (\text{Ec 2.6})$$

4. Curtosis:

$$\mathbf{m}_4 = \frac{1}{4} \sum_{k=1}^N (f_k - \mathbf{m})^4 p(f_k) - 3 \quad (\text{Ec 2.7})$$

Supongamos que el histograma se calcula en una región de la imagen, la media  $\mu$  da una estimación del nivel de intensidad promedio en esta región y la varianza  $\sigma^2$  es una medida de la dispersión de la intensidad de la región. La desigualdad (“skewness”) del histograma es una medida de la simetría del mismo que muestra el porcentaje de los píxeles de la región que favorecen las intensidades de ambos lados de la media. La curtosis es una medida de la cola del histograma, aquellos histogramas con colas largas corresponden a regiones con picos. La sustracción en la ecuación de la curtosis asegura que una distribución de Gauss esté normalizada a cero. La medida de rango de datos se refiere al rango de los valores entre el mínimo y el máximo dentro de una ventana. La gran ventaja de estos descriptores es su simplicidad computacional.

## **2.9. Conclusiones del capítulo**

Los materiales de la superficie terrestre interactúan con la radiación electromagnética, reflejando, absorbiendo o transmitiendo la energía incidente.

Los sensores ya sea que estén ubicados en satélites o en aviones, registran la energía reflejada en las diferentes bandas o longitudes de onda. Se genera así una imagen por cada banda sensada. Estas imágenes conforman lo que conocemos como imagen multiespectral. Cuando las bandas son tomadas en forma continua, son angostas, y abarcan un intervalo amplio del espectro se dice que la imagen es hiperespectral. Las imágenes hiperespectrales se destacan también por su resolución, encontrando píxeles de 1m x 1m.

Para el análisis de imágenes donde se presenta vegetación, se utilizan una serie de índices conocidos como índices de vegetación que permiten detectar el grado de estrés que poseen las plantas, entre otras cosas. ◆

## **CAPITULO 3**

### **Presentación del problema de aplicación**

#### **3.1. Descripción**

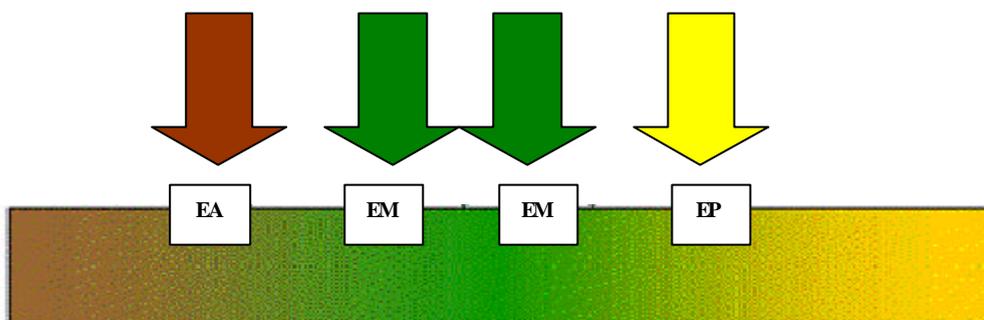
Para llevar a cabo los objetivos de esta tesis, la propuesta aquí planteada es la de realizar un trabajo sobre un área geográfica particular, para monitorear regiones cultivadas y distinguir entre distintas clases de cultivos. Esto es importante dado que permite estimar la cantidad de áreas sembradas con cada de tipo cultivo y se podría analizar la evolución de los mismos. Además, estas estadísticas son útiles a la hora de prever la producción que se obtendrá.

El presente proyecto está sustentado por la experiencia y trabajo realizado en una región de los Estados Unidos (Holdrege-Nebraska) por un grupo integrado por PRA (Photon Research Associates, Inc.), el cual cuenta con el apoyo de Kestrel Corporation, Positive Systems, Inc., NASA – Stennis Space Center, University of Nebraska (Lincoln), Center for Advanced Land Management Information Technologies (UNL/CALMIT) y AgTracks, Inc. Los mismos realizan un estudio del estrés de los cultivos propios de la región, mediante la adquisición de imágenes multiespectrales e hiperespectrales obtenidas realizando vuelos en aviones sobre la zona de interés (**Proyecto Verde**). Además trabajan con un conjunto de datos reales del suelo, entre los que se tienen medidas espectro-radiométricas, observaciones globales de agrónomos entrenados, datos meteorológicos, etc. [www4].

Esta región se caracteriza por su riqueza agrícola, en especial, por el crecimiento de cultivos tales como soja, maíz, sorgo, alfalfa y trigo.

En 1998, el grupo de PRA realizó un trabajo de investigación en Nebraska. Se tomó información sobre 29 campos (3600 acres), seleccionados por agrónomos de Agtracks y se realizó un experimento durante 11 días. Actualmente continúan

trabajando y analizando los campos de la región, realizando adquisiciones en 4 etapas de la evolución de los cultivos (**Figura 3.1**) [Pra98].



**Figura 3.1 -**  
EA- Estación Anterior (Principios de Mayo)  
EM- Estación Media (Junio/Julio) – (Fines de Julio/Agosto)  
EP- Estación Posterior (Mitad de Agosto)

## 3.2. Material de trabajo

Las imágenes que se utilizan en el presente trabajo y los datos reales de suelo forman parte del material obtenido en 1998 por este equipo.

Se trata de imágenes hiperespectrales obtenidas utilizando un sensor “Compact Airborne Spectrographic Imager” (*casi*) provisto por la empresa ITRES Research Limited [www17]. Se tienen tanto datos de 1m como de 2m recolectados por este sensor.

También se dispone de imágenes aéreas multiespectrales recolectadas con el sensor ADAR 5500, todas de resolución de 2m, con excepción de la imagen Mead231 que tiene resolución de 1 metro.

A continuación se resumen más específicamente las imágenes con las que se trabaja:

### Datos de *casi* HSI

Convención para el nombre: las dos primeras letras corresponden a la resolución de los datos de la imagen. Las siguientes se refieren al mes y día, seguidos del nombre del área de interés por la que se adquirió la imagen. La ‘g’ indica que el archivo de pixeles ha sido geocodificado.

Ej: 1m0809bug1g.pix = resolución de 1 m, 09 Agosto 1998.

*Estas imágenes son las que se utilizan para la clasificación y la evaluación de la “performance”.*

### Características de las imágenes:

Se dispone de cuatro (4) archivos geocorregidos *casi*, que fueron calibrados de modo espacial.

Día de adquisición: Agosto 09, 1998

Formato de los datos: 16 bits entero sin signo, formato PCI “Band Interleaved by Pixel” (BIP).

Sistema de Coordenadas: las imágenes fueron geocorregidas a coordenadas UTM\* (Universal Transversal Mercator) (zona14)

Tabla 3.1 a - Tabla de resumen

Nombre archivo *.pix	Dimensiones pixeles , líneas, bandas	Tamaño (Mb)	Hora (GMT)	Res (m)	Altitud (pies sobre el nivel del mar)
1m0809bug1g	2905x599x10	35	16:15	1 x 1	3340
1m0809bug2g	4420x613x10	54	16:20	1 x 1	3340
1m0809corng	598x4446x10	55	16:02	1 x 1	3340
1m0809rotg	3041x612x10	37	17:05	1 x 1	3340

b)

Coordenadas del vértice Noroeste, Zona 14 UTM		
Archivo *.pix	Este	Norte
1m0809bug1g	708651	4560072
1m0809bug2g	709104	4560026
1m0809corng	715536	4564841
1m0809rotg	712459	4560526

c)

Coordenadas del vértice sudeste, Zona 14 UTM		
Archivo *.pix	Este	Norte
1m0809bug1g	711556	4559473
1m0809bug2g	713524	4559413
1m0809corng	716134	4560395
1m0809rotg	715500	4559914

Tabla 3.2 -Conjunto de bandas espaciales *Casi* (PRA98.CCF)

1m0809bug1g.pix	[S 10PIC 2905P 599L]
1 [16U] 431.1nm /- 19.0nm (rows 268-287)	18-Aug-98
2 [16U] 463.5nm /- 12.6nm (rows 254-266)	18-Aug-98
3 [16U] 580.4nm /- 10.0nm (rows 193-202)	18-Aug-98
4 [16U] 610.6nm /- 8.1nm (rows 178-185)	18-Aug-98
5 [16U] 676.2nm /- 7.2nm (rows 144-150)	18-Aug-98
6 [16U] 695.2nm /- 7.2nm (rows 134-140)	18-Aug-98
7 [16U] 720.0nm /- 5.3nm (rows 122-126)	18-Aug-98
8 [16U] 760.2nm /- 5.3nm (rows 101-105)	18-Aug-98
9 [16U] 819.6nm /- 5.3nm (rows 70-74)	18-Aug-98
10 [16U] 951.0nm /- 6.3nm (rows 1-6)	18-Aug-98

\* Se refiere al istema “Universal Transversal Mercator”, el cual es básicamente un sistema de coordenadas de cuadrícula (coordenadas planas) que cubre todo el globo terrestre y que lo emplea generalmente el Ejército de los Estados Unidos y la Agencia Cartográfica de Defensa de ese país.

### **Datos ADAR5500 MSI**

Convención para los nombres: los nombres de los archivos son creados usando el identificador de PRA: Año, mes, día, línea de vuelo, y número de secuencia de la escena. Las imágenes fueron tomadas en una línea de vuelo este-oeste.

- Mead132 Mayo 12, 1998 (2m) Parcialmente oscurecida por una cobertura de nubes.
- Mead167 Junio 16, 1998 (2m) Tiene una línea de vuelo incorrecta centrada aproximadamente 1 milla al norte del borde de “Agricultural Research and Development Center” (ARDC)
- Mead170 Junio 19, 1998 (2m) Datos buenos.
- Mead177 Junio 26, 1998 (2m) Datos buenos.
- Mead201 Julio 20, 1998 (2m) Datos buenos
- Mead209 Julio 28, 1998 (1m) Un sólo cuadro
- Mead229 Agosto 17, 1998 (2m). Datos buenos
- Mead231 Agosto 19, 1998 (1m). Escenas que fueron disparadas manualmente a través del centro de ARDC continuando aproximadamente 3 millas más allá del borde este

*Las imágenes Mead mencionadas anteriormente fueron usadas como datos de referencia.*

### **ADAR System 5500, 4-B Multiespectrales**

- Basado en “Charged Couple Device” (CCD)
- Trabaja con bandas espectrales 450/540, 520/600, 610/690 y 780/1000 (aproximan las bandas 1, 2, 3, 4 del Landsat TM)
- Altitud de adquisición a 4800 por encima del nivel del suelo

- Resolución del pixel: 2 metros
- Arreglo de la escena de 200 x 680 píxeles
- Área de cobertura de la escena ~ 140 acres
- Distribución en formato de imagen ENVI
- Los datos auxiliares que se incluyen son latitud, longitud, altitud, día y hora de la imagen adquirida

### Medidas reales sobre suelo

Se cuenta con información obtenida para el mismo día de la toma de las imágenes, ésta fue utilizada para investigaciones de seguimiento de la evolución de los cultivos de maíz, entre otras cosas.

El primer objetivo de la recolección de datos espectro radiométricos fue verificar los espectros obtenidos con el “Hyperspectral imager”.

### 3.3. Mapa del área de estudio

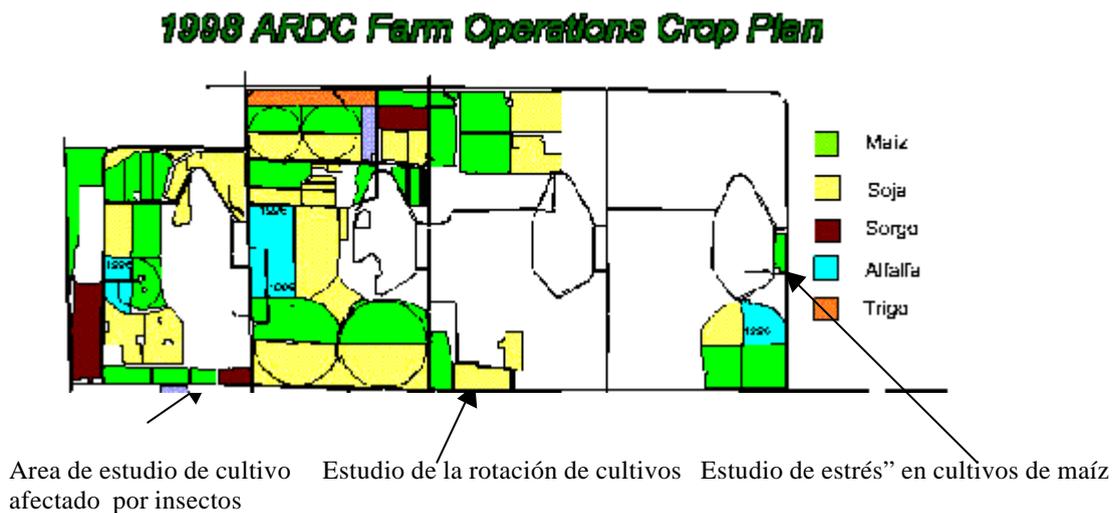


Figura 3.2 – Mapa del área de trabajo con referencia a los distintos estudios que se realizaron sobre la región

### 3.4. Metodología propuesta

Se evalúa el método de razonamiento evidencial dinámico, trabajando con 3 clases de cultivo: sorgo, soja, y maíz. Además se permite distinguir elementos que no corresponden a vegetación y aparecen en las imágenes, en este caso se identifican las rutas.

Se tiene información sobre qué partes de la imagen corresponden a estos cultivos, en base a estudios de campo realizados en la región y al conocimiento previo disponible (información de las organizaciones antes mencionadas).

Se debe destacar que los cultivos se encuentran en etapa de crecimiento para el mes de agosto (día de adquisición de los datos). Se muestra a continuación, en la **Figura 3.3**, una imagen con el estado del cultivo de maíz para la fecha:



Figura 3.3 - Imagen de Cultivo de Maíz - Agosto 9, 1998

El alto de las plantas es de 80 pulgadas y su etapa de desarrollo es de aproximadamente 24-28 días después de la maduración.

Dividimos el trabajo en tres etapas:

► **Etapa A: Entrenamiento**

En esta etapa se toman muestras representativas para cada clase con la que se trabaja (en este caso se trabajó con 15 muestras iniciales representativas por clase, según lo

sugiere la literatura que recomienda trabajar con una cantidad de muestras al menos igual a la cantidad de bandas de la imagen) [Jen96].

El entrenamiento se realiza de la siguiente manera: se marcan los píxeles pertenecientes a cada clase y se toma su firma espectral, utilizando esta firma se consideran como fuentes de información a las diferencias normalizadas entre pares de bandas consecutivas (es decir se tienen 9 fuentes que dan información relacionada a la firma espectral de la muestra). Para cada muestra también se calculan ciertos rasgos de textura. Estos son la media, el “skewness” (referido a la simetría), el rango y la desviación estándar, que también actuarán como fuentes de información (ver **capítulo 2 sección 8**). Para calcular estos valores indicativos de textura se trabaja con una ventana de 3x3. Las estadísticas seleccionadas son de primer orden, y dan una idea de la textura de la clase. La información espacial se obtiene para una sola banda (centrada en los 760nm).

Se hace el entrenamiento con las muestras de acuerdo al método en particular. Se establece además un conjunto de muestras de entrenamiento para utilizar en el proceso de aprendizaje. Esto se realiza marcando regiones rectangulares en la imagen y presentando al clasificador el grupo de muestras de entrenamiento que posee cada una de dichas regiones. Existe una región representativa por cada clase de entrada, y se trabajó con aproximadamente 7 regiones para cada clase, cada una de las cuales presenta un conjunto de muestras que son los píxeles que las componen. De esta forma, el clasificador evalúa de acuerdo al indicador Khat si es preciso modificar el conocimiento que se tiene hasta el momento o no. Esto se explicará más detalladamente en el **capítulo 5**.

#### ► *Etapa B: Clasificación*

Se realizaron pruebas posteriores al proceso de entrenamiento, trabajando con distintas reglas de decisión y comparando su respuesta respecto de la presentada por RED. También se probaron distintas alternativas para utilizar como fuentes de información para el método.

► ***Etapa C: Evaluación de resultados***

Se analizan los resultados por medio del indicador Khat y la matriz de confusión. Se comparan dichos resultados.

El software utilizado para llevar a cabo este trabajo es ENVI + IDL [www18], el mismo permitió desarrollar el clasificador propuesto. ENVI (the Environment for Visualizing Images) es un sistema de procesamiento de imágenes revolucionario. Fue diseñado para direccionar las necesidades específicas de los que utilizan datos de sensado remoto. Provee visualización de datos y análisis de imágenes de cualquier tamaño y tipo.

ENVI utiliza un formato de datos “raster” que consiste de un "archivo binario plano" y tiene asociada una cabecera ASCII. Este enfoque permite un uso flexible de casi cualquier formato de imagen, incluyendo aquellos que tienen la información de cabecera embebida. La cabecera da información sobre las dimensiones de la imagen, de la cabecera interna si la tiene, del formato de los datos y otra información pertinente.

Los datos “raster” se guardan en un flujo binario de bytes ya sea en formato: “band sequential” (BSQ), “band interleaved by pixel” (BIP), o “band interleaved by line” (BIL). En su forma más simple, los datos están en formato BSQ, con cada línea de datos seguida inmediatamente por la siguiente línea en la misma banda espectral. Este formato es óptimo para el acceso espacial (X, Y) de cualquier parte de una banda espectral simple. Las imágenes guardadas en formato BIP tienen el primer pixel para todas las bandas en orden secuencial, seguido del segundo pixel para todas las bandas, seguido por el tercer pixel para todas las bandas y así continuando. Esto provee una “performance” óptima para el acceso espectral (Z) de los datos de imagen. Las imágenes almacenadas en formato BIL tienen la primer línea de la primera banda seguida de la primer línea de la segunda banda, luego la primer línea de la tercer banda y así continuando. De esta forma, se tiene un compromiso en la “performance” entre procesamiento espacial y espectral [Jen96][www18].

### **3.5. Conclusiones del capítulo**

En este capítulo se presenta la aplicación práctica en la que se introduce el método propuesto. Se trata de un análisis de los cultivos de la región de Nebraska, ubicada en el sur de los Estados Unidos. Se utilizan imágenes hiperespectrales obtenidas con el sensor *CASI*, para el mes de agosto de 1998. Además se posee información auxiliar provista por agrónomos entrenados.

Se describen las imágenes y el material que se utiliza en la investigación, así como también la metodología propuesta para el trabajo. Se indican las fuentes de información que se emplean en la clasificación.

Este material tiene el fin de permitir realizar clasificaciones de distintas clases de cultivos para evaluar la ‘performance’ del razonamiento evidencial dinámico y destacar su conveniencia respecto de otros clasificadores. ◆

## CAPITULO 4

### Clasificación y reconocimiento de patrones. Estado del arte en “remote sensing”

#### 4.1. Definiciones y conceptos

Como ya se ha mencionado, con el incremento de la capacidad, la velocidad y las ventajas económicas de los dispositivos de procesamiento de señales, se ha visto un creciente esfuerzo por desarrollar sistemas sofisticados de tiempo real que emulen las habilidades humanas, entre ellas la visión, abarcando la identificación y clasificación de objetos (o seres) en grupos o categorías de acuerdo a sus similitudes o semejanzas.

El Reconocimiento de Patrones (Pattern recognition = PR) es el área de investigación que estudia la operación y el diseño de sistemas que reconocen patrones en los datos [Fuk90]. Las técnicas de PR se usan para clasificar automáticamente objetos y patrones y tomar decisiones [Sch92][Tou74].

El reconocimiento de patrones estadístico asume que la imagen puede contener uno o más objetos y que cada objeto pertenece a uno de varios tipos, categorías o clases de patrones.

Dada una imagen digital que contiene varios objetos, el proceso de reconocimiento de patrones consta de 3 etapas [Bax94][Cas96][Gon92][Jai89].

La primer etapa es llamada segmentación de la imagen, en donde los objetos de interés son aislados del resto de la imagen.

La segunda etapa, es la de extracción de rasgos, en donde los objetos son medidos. Una medida es un valor de alguna propiedad cuantificable del objeto. Un rasgo es una función de una o más medidas, computadas de tal forma que cuantifican algunas características importantes del objeto. Con estos rasgos se construye lo que se conoce como el vector de rasgos.

La tercera fase del reconocimiento de patrones es la clasificación. La idea básica es reconocer objetos utilizando rasgos. Existe un amplio conjunto de técnicas de clasificación. Todas las técnicas del reconocimiento de patrones asumen que  $N$  rasgos han sido detectados en imágenes, y que estos rasgos fueron normalizados de manera tal que pueden ser representados en el mismo espacio de medidas. Los rasgos para un objeto pueden ser representados en el espacio de rasgos  $N$ -dimensional.

La salida de este proceso es meramente una decisión sobre la clase a la que pertenece el objeto. Cada objeto es reconocido como perteneciente a un tipo particular y puede ser asignado a un conjunto de grupos preestablecidos (clases), que representan todos los tipos de objetos que se espera que existan en la imagen. Ocurre un error de clasificación si se realiza la asignación a una clase inapropiada, la probabilidad de que esto ocurra es un radio de error de clasificación.

### **Aplicaciones**

Visión de computadora

Análisis/clasificación de señales de radar o sensores

Reconocimiento de rostros.

Identificación de huellas dactilares

Reconocimiento e interpretación de voz

Diagnóstico médico

Reconocimiento de caracteres, etc.

### **Ejemplo del uso de la representación abstracta**

Consideremos un problema con dos clases:  $w_1$  y  $w_2$ , donde  $w_1$  corresponde a la clase de las “manzanas” y  $w_2$  corresponde a la clase de las “granadas de mano”. En el espacio de patrones hay algunas diferencias entre los patrones,  $p_i$ , resultantes de las manzanas, ya que no todas las manzanas tienen el mismo tamaño, forma, peso,

color, etc. Lo mismo pasa para la clase  $w_2$ . También algunas manzanas y granadas de mano comparten atributos similares (por ejemplo: masa, volumen, peso). Así, basándonos en nuestro sistema de PR sobre una medición que consiste de patrones armados con el peso es probable que:

- Clasifiquemos (mal) algunas manzanas y granadas de mano como lo mismo.
- Clasifiquemos (mal) o distingamos entre manzanas pesadas y livianas (igualmente para  $w_2$ )

Los enfoques de caja negra (implementados usando redes neuronales), requieren un buen sistema de entrenamiento y un conjunto de datos para entrenar.

### Estructura de un sistema de PR

Posible algoritmo de retroceso o interacción

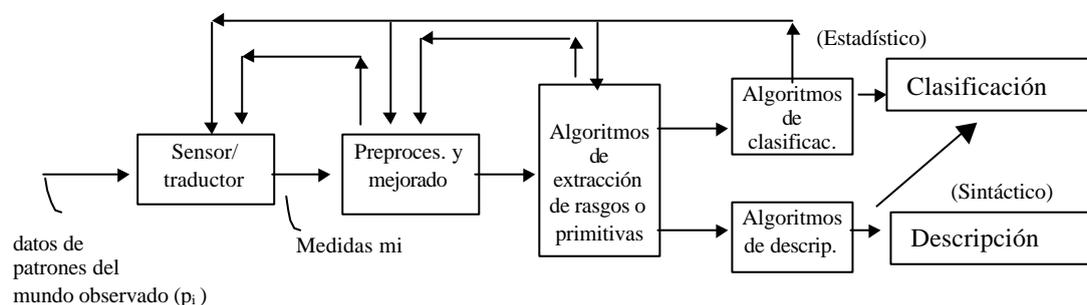


Figura 4.1 - Estructura de un sistema de PR

A los pasos antes vistos de un sistema de PR, se le agregan dos más, con lo cual tenemos las siguientes 5 etapas: 1) diseño de un localizador de objetos, 2) selección de rasgos, 3) diseño de un clasificador, 4) entrenamiento del clasificador, y 5) evaluación de su rendimiento o “performance” [Cas96].

No es tema de interés aquí detallar el diseño de un localizador de objetos ni la selección de rasgos, pero sí se debe destacar la importancia de ambas etapas.

**Diseño del clasificador:** establece la estructura lógica del clasificador y su base matemática para la regla de decisión que se utilizará en la clasificación.

Para cada objeto encontrado el clasificador computa un valor para cada clase que indica el **grado** con el cual el objeto se parece a los objetos de la clase.

- El valor antes dicho se computa como *una función de los rasgos*, y se usa para seleccionar la clase más apropiada en la asignación.
- La mayoría de las reglas de decisión se reducen a una regla que utiliza un umbral (threshold) para particionar el espacio de rasgos en regiones disjuntas, una (o más) para cada clase. Cada región se corresponde con una clase simple.

Si los valores de los rasgos caen en una región particular, entonces el objeto se asigna a la correspondiente clase. Muchas veces, una o más de tales regiones pueden corresponderse con una clase llamada **desconocida**.

**Entrenamiento del clasificador:** una vez que las reglas de decisión se establecieron, se debe evaluar cuáles son los valores de **umbral** que separan las clases. Esto se hace, generalmente, por entrenamiento del clasificador usando un grupo de objetos conocidos.

El *conjunto de entrenamiento* es una colección de objetos de cada clase que fueron clasificados previamente por algún método preciso.

**Medición del rendimiento:** la precisión del clasificador puede ser directamente estimada tabulando su rendimiento sobre un conjunto de objetos de test. Para ello el conjunto debe ser suficientemente grande, y estar libre de errores.

Existen diferentes técnicas y es importante que el conjunto de test sea diferente del de entrenamiento.

## 4.2. Clasificación supervisada vs. no supervisada

En esta sección se presentan en forma breve algunos de los métodos de clasificación supervisada y no supervisada [Mar94][www7], de forma tal de dar un contexto para la comparación entre dichos métodos y el propuesto en la presente tesis (Capítulo 6).

Podemos diferenciar a los clasificadores en las siguientes categorías:

1. **Clasificación Supervisada:** se trabaja con dos hipótesis:

- a) las clases son de naturaleza **determinística** (se tiene un vector que representa a todos los objetos de una clase, y que se conoce como **vector prototipo**)
- b) toda la información necesaria y suficiente para su diseño se encuentra disponible a priori.

Pueden usarse varios algoritmos de clasificación supervisada para asignar un pixel u objeto desconocido a una clase entre un conjunto de clases posibles. La elección particular del clasificador o regla de decisión depende de la naturaleza particular de los datos de entrada y de la salida esperada. Los algoritmos de clasificación paramétrica asumen que el vector de medidas observadas,  $X_c$ , para cada clase y por cada rasgo, tiene una distribución ‘Gaussiana’ por naturaleza. Los algoritmos de clasificación no paramétrica no tienen tal hipótesis [Jen96].

2. **Clasificación No Supervisada:** las clases no son conocidas a priori. Se recurre a un agrupamiento natural (“**clustering**”).

No existe ningún reconocimiento externo que guíe el diseño de las funciones discriminantes. La única información que se requiere es el vector de rasgos, sin embargo, algunos algoritmos necesitan conocer el número de clases. Trabajan recibiendo vectores de rasgos y agrupándolos para formar clases.

### 4.3. Clasificadores utilizados en el área de sensado remoto

#### Clasificación supervisada

##### - Método lineal basado en regionalización [Gon92][Mar94]

- Un clasificador particiona el espacio de rasgos ( $R$ ) en regiones de decisión etiquetadas como clases. Si se usan regiones de decisión para la asignación de una clase posible única, estas regiones deben cubrir todo  $R$  y ser disjuntas
- El borde de cada región de decisión es un límite de decisión.
- Con este punto de vista, la clasificación de un vector desconocido  $x$ , resulta algo simple: **determinamos la región de decisión (en  $R$ ) en la que cae  $x$ , y asignamos  $x$  a esa clase.**

A pesar de que esta estrategia de clasificación es directa, la determinación de las regiones de decisión es un desafío. Las funciones discriminantes en el caso de  $n$  rasgos, pasan a ser hiperplanos

##### - Método lineal basado en distancia

##### (Clasificador de mínima distancia) [Gon92][Lil94]

Supongamos que se tienen  $M$  clases y que cada una está representada por un vector prototipo:

$$m_j = \frac{1}{N_j} \sum_{x \in w_j} x \quad j = 1 \dots M \quad (\text{Ec 4.1})$$

$N_j$ : es el número de vectores patrones para la clase  $w_j$ .

La sumatoria se toma sobre estos vectores.

Una forma de determinar de qué clase es miembro un vector patrón desconocido  $x$ , es **asignarlo a la clase más cercana a su prototipo**. Es decir, medimos su similitud con cada clase computando su distancia al vector prototipo de la clase.

Se puede usar la distancia Euclídea para determinar la proximidad o cualquier combinación pesada de rasgos. Si usamos la distancia “euclídeana”, se reduce el problema a computar las medidas de distancia

$$d_j = \|x - m_j\| \quad j=1 \dots M \quad \text{(Ec 4.2 a)}$$

$$\|a\| = (a^T a)^{1/2} \quad \text{es la norma euclídeana.} \quad \text{(Ec 4.2 b)}$$

Entonces, asignamos  $x$  a la clase  $w_i$  si  $d_i(x)$  es la menor distancia encontrada. Esto es, la menor distancia implica la mejor concordancia o “matching” en esta formulación. No es difícil demostrar que esto es equivalente a evaluar las funciones:

$$d_j = x^T m_j - \frac{1}{2} m_j^T m_j \quad j=1 \dots M \quad \text{(Ec 4.3)}$$

y se asigna  $x$  a la clase  $w_i$  si  $d_i(x)$  lleva al valor numérico más grande.

El límite de decisión entre la clase  $w_i$  y  $w_j$  para un clasificador de mínima distancia es:

$$d_{ij} = d_i(x) - d_j(x) = 0 \quad \text{(Ec 4.4)}$$

En la clasificación de datos sensados remotamente, es necesario que el usuario provea los vectores medios para cada clase en cada banda.

La ventaja de este método es que es simple y eficiente computacionalmente. El problema es que es insensible a diferentes grados de varianza en los datos de respuesta espectral. Por lo que no es recomendable para aplicaciones en las que las clases espectrales están cercanas unas de otras en el espacio de medidas y tienen alta varianza.

- **Método de clasificación del paralelepípedo [Jen96][www7]**

Se puede introducir sensibilidad a la varianza de la categoría considerando un rango de valores en cada conjunto de entrenamiento. El rango puede estar dado, por ejemplo, por el valor más bajo y más alto en cada banda.

El método se puede definir entonces como sigue. Se usan para clasificar los datos de entrenamiento en  $n$  bandas espectrales. Se tiene un vector de medias  $n$ -dimensional,  $M_c = (U_{c1}, U_{c2}, \dots, U_{cn})$  donde  $U_{ck}$  es el valor medio de los datos de entrenamiento obtenidos para la clase  $c$  en la banda  $k$ , entre  $m$  clases posibles. Se llama  $S_{ck}$  a la desviación estándar de los datos de entrenamiento de la clase  $c$  en la banda  $k$ .

Usando un umbral basado en la desviación estándar y siendo  $Bv_{ijk}$  el valor del pixel de la banda  $k$  en las coordenadas espaciales  $(i,j)$ , el algoritmo del paralelepípedo decide que  $Bv_{ijk}$  está en la clase  $c$ , si y sólo si:

$$(U_{ck} - S_{ck}) \leq Bv_{ijk} \leq (U_{ck} + S_{ck}) \quad \text{(Ec 4.5)}$$

$c = 1, 2, \dots, m$ . Número de clases

$k = 1, 2, 3, \dots, n$ . Número de bandas

Si definimos los límites (inferior y superior) de decisión como:

$$L_{ck} = U_{ck} - S_{ck} \quad \text{y} \quad H_{ck} = U_{ck} + S_{ck} \quad \text{(Ec 4.6)}$$

El algoritmo del paralelepípedo se convierte en:

$$L_{ck} \leq Bv_{ijk} \leq H_{ck} \quad \text{(Ec 4.7)}$$

Los límites de decisión forman un paralelepípedo  $n$ -dimensional en el espacio de rasgos. Si el valor de un pixel está por arriba del umbral inferior y por debajo del superior para todas las bandas evaluadas, se asigna el pixel a la clase. Cuando el

pixel no satisface este criterio para ninguna de las clases se asigna a la clase “desconocida”.

El algoritmo del paralelepípedo es computacionalmente eficiente para clasificar datos sensados remotamente, sin embargo algunos paralelepípedos se superponen. Esto provoca que un pixel puede satisfacer el criterio para más de una clase. La superposición se debe en parte a que las distribuciones de las categorías que exhiben correlación o alta covarianza no se representan correctamente por regiones de decisión rectangulares. La covarianza es la tendencia de los valores espectrales de variar similarmente en dos bandas, visto esto en un diagrama se observan como nubes elongadas e inclinadas. Por ello, se dice que los datos no se ajustan a regiones de decisión rectangulares.

### **Clasificadores estadísticos óptimos**

Hasta ahora se usaron *vectores prototipos fijos*, representativos de cada clase, con lo que se admite un comportamiento determinístico de los elementos de una clase.

Hay situaciones en las que los vectores de algunas clases presentan una dispersión significativa respecto a su media y por eso no conviene usar la hipótesis determinística sino un enfoque estadístico

Las consideraciones probabilísticas se vuelven importantes para el reconocimiento de patrones dada la aleatoriedad bajo la cual las clases patrones son generadas.

#### **- Clasificador de Bayes [Dud73][Fuk90][Sch92]**

El enfoque “bayesiano” ha sido usado para el reconocimiento de objetos cuando la distribución de los objetos no es tan directa. En general, hay una superposición significativa en los valores de rasgos de diferentes objetos. En el momento de decidir se encontrarían varias clases como posibles candidatas a las que asignar el objeto. Para tomar una buena decisión se puede usar el enfoque de Bayes.

En este enfoque se utiliza el conocimiento probabilístico sobre los rasgos y la frecuencia de los objetos. Supongamos que conocemos que la probabilidad de los objetos de la clase  $w_j$  es  $P(w_j)$ . Esto significa que a priori conocemos que la probabilidad de que un objeto de la clase  $j$  aparezca es  $P(w_j)$ , y entonces en ausencia de cualquier otro conocimiento podemos minimizar la probabilidad de error, asignando el objeto desconocido a la clase para la cual  $P(w_j)$  es máxima.

Las decisiones sobre la clase de un objeto se realizan usualmente basándose en observaciones de rasgos. Supongamos que la probabilidad  $P(x/w_j)$  fue dada. La misma representa la probabilidad de que el objeto pertenezca a la clase  $w_j$  dado que el vector de rasgos observados es  $x$ . Basándonos en este conocimiento podemos calcular la probabilidad a posteriori  $P(w_j/x)$ .

La probabilidad a posteriori es la probabilidad que, para la información y observaciones dadas, el objeto desconocido pertenece a la clase  $w_j$ . Usando la regla de Bayes:

$$P(w_j/x) = \frac{P(x/w_j)P(w_j)}{P(x)} \quad \text{donde } P(x) = \sum_{j=1}^m P(x/w_j)P(w_j) \quad (\text{Ec 4.8})$$

El objeto desconocido debería ser asignado a la clase con la mayor probabilidad a posteriori.

Para el clasificador de Bayes se tiene en cuenta el riesgo condicional. Si el clasificador decide que  $x$  proviene de la clase  $w_j$ , incurrió en una pérdida llamada  $L_{ij}$ .

Como el patrón  $x$  pudo pertenecer a cualquiera de  $m$  clases a considerar, el promedio de pérdida incurrida en asignar  $x$  a la clase  $w_j$  es

(Ec 4.9)

$$r_j(x) = \sum_{k=1}^m L_{kj} P(w_k/x) \quad \text{esto se llama riesgo o pérdida promedio condicional}$$

Si reemplazamos en la fórmula anterior usando (Ec 4.8) obtenemos:

$$r_j(x) = \left( \frac{1}{P(x)} \right) \sum_{k=1}^m L_{kj} P(x/w_k) P(w_k) \quad (\text{Ec 4.10})$$

donde  $P(x/w_k)$  es la función de densidad de probabilidad de los patrones de la clase  $w_k$  y  $P(w_k)$  es la probabilidad de ocurrencia de la clase  $w_k$

Dado que  $1/P(x)$  es positivo y común a todos los  $r_j(x) j=0, \dots, m$  se puede sacar de la ecuación sin afectar el orden relativo de estas ecuaciones desde la de menor a la de mayor valor.

Entonces se reducen a:

$$r_j(x) = \sum_{k=1}^m L_{kj} P(x/w_k) P(w_k) \quad (\text{Ec 4.11})$$

El clasificador tiene M clases posibles entre las que puede elegir para cualquier patrón desconocido x. Se computa:  $r_1(x), r_2(x), \dots, r_m(x)$  para cada patrón x, y se asigna el patrón a la clase con menor pérdida. El total de pérdida con respecto a todas las decisiones será mínimo.

Finalmente, se establece la siguiente regla de decisión. Sean  $w_1, \dots, w_m$  las posibles clases entre las que el clasificador puede asignar el objeto desconocido.

$$r_i(x) < r_j(x) \Rightarrow \hat{I} = w_i \quad " i, j = 1, 2, \dots, m. i \neq j$$

Existen otros enfoques que utilizan como base la filosofía del clasificador de Bayes. Por ejemplo, en sensado remoto puede ser útil realizar la clasificación teniendo en cuenta las diferentes consecuencias, y por lo tanto también costos, asociados con cada tipo de error. Existen aplicaciones donde se busca minimizar el costo del error de la clasificación, en lugar del error general de clasificación [Bru2000].

### - Clasificador de Máxima Verosimilitud [Fuk90][Jen96][Lil94][www2]

Este clasificador asume que los datos de entrenamiento para cada clase en cada banda tienen una distribución normal o Gaussiana. En otras palabras, los datos con histogramas bi-modales o trimodales en una sola banda no son ideales.

Utiliza como estadísticas el vector de media ( $M$ ) y la matriz de covarianza ( $V$ ) de cada clase para cada banda. La regla que se aplica para un vector desconocido  $x$  es: se decide por la clase  $c$ , si y sólo si:  $P_c \geq P_i$  con  $i=1, 2, \dots, m$  (clases posibles), donde  $P_c$  es la probabilidad de que  $x$  pertenezca a la clase  $c$ .

Entonces para clasificar un vector de medidas  $x$  de un pixel u objeto desconocido, se debe calcular el valor de  $P_c$  para cada clase. Luego, se asigna el objeto a la clase con mayor probabilidad. Si todas las probabilidades están por debajo de un umbral dado por un analista, se asigna a la clase desconocida.

Esta ecuación asume que cada clase tiene igual probabilidad de ocurrir, es decir las  $P(w_j)$  con  $j=1, \dots, m$  tienen todas igual valor. Esto difiere del clasificador de Bayes que no realiza tal suposición. Bayes aplica dos factores de peso a la estimación de la probabilidad. Primero, el analista determina la probabilidad a priori, o verosimilitud anticipada de ocurrencia para cada clase en la escena dada. Segundo, hay un peso asociado con el riesgo de clasificar mal para cada clase. Estos dos factores juntos actúan para minimizar el costo de clasificar mal, resultando en una clasificación teóricamente óptima.

Tanto el clasificador de Máxima verosimilitud como el de Bayes tienen un alto costo computacional. Esto se incrementa particularmente cuando se tiene un gran número de canales espectrales involucrados y/o muchas clases entre las que se debe distinguir.

Entre las aplicaciones de sensado remoto que utilizan este clasificador se encuentra el estudio de mares congelados en las regiones polares para entender el clima global y los procesos geofísicos que gobiernan los cambios climáticos [Rem2000].

### **Enfoque neuronal [Bis95][Fuk90][www5]**

La alternativa de *computación neuronal* surge de intentar imitar la forma en que los sistemas neuronales biológicos guardan y manipulan información. Esto lleva a una clase de sistemas neuronales artificiales denominados redes neuronales. Se los considera técnicas de modelado sofisticado, capaces de modelizar funciones extremadamente complejas. En particular, las redes neuronales son no lineales. Durante muchos años los modelos lineales han sido la técnica más frecuentemente usada, dado que los mismos eran conocidos por encontrar buenas soluciones en problemas de optimización. Sin embargo, en aquellos problemas donde la aproximación lineal no resultaba válida, los modelos no se comportaban correctamente.

La unidad básica de las redes neuronales, la neurona artificial, simula las cuatro funciones básicas de las neuronas naturales, pero son mucho más simples. Básicamente, una neurona biológica recibe una entrada de otras fuentes, las combina de algún modo, realiza una operación no lineal en el resultado y luego da como salida el resultado final.

Es importante aclarar que, generalmente, las redes neuronales toman una entrada numérica y producen también una salida numérica. La función de transferencia de una unidad se elige de manera tal que acepte una entrada en cualquier rango y la salida sea limitada a un cierto rango. Este último hecho, junto con el que hay que exigir que la información esté en forma numérica, implica que las soluciones neuronales requieren de etapas de pre y post procesamiento para cuando se trabaja en aplicaciones reales [Bis95].

Cada entrada se multiplica por un peso de conexión, estos pesos serán representados como  $w_{ij}$  (ver gráfico 4.1). En el caso más simple, en que los productos son sumados, se aplica una función de transferencia para generar un resultado que es la salida.

Para implementar una red neuronal se debe atravesar por un período de prueba y error en el diseño de la misma antes de encontrar el diseño satisfactorio. El diseño se torna en un tema complejo para quienes optan por utilizar una red neuronal.

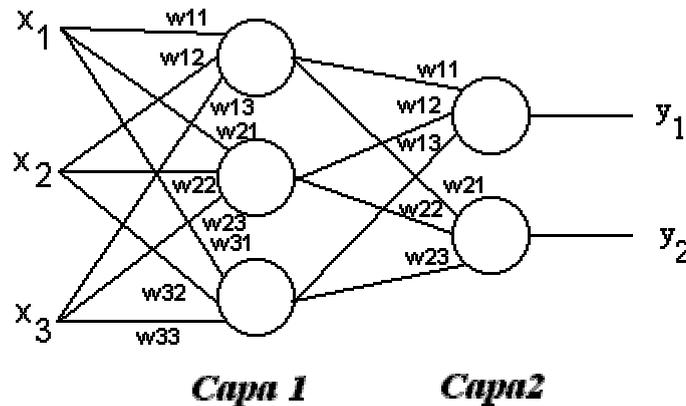


Gráfico 4.1 – Ejemplo de la estructura de una red neuronal

Diseñar una red neuronal consiste en [Dug96]:

- Arreglar las neuronas en varias capas.
- Decidir el tipo de conexión entre las neuronas de diferentes capas, así como entre las neuronas de una misma capa.
- Decidir la forma en que una neurona recibe una entrada y produce una salida.
- Determinar el peso de cada conexión dentro de la red, permitiendo que la red aprenda los valores apropiados de los pesos de conexión, usando el conjunto de datos de entrenamiento.

Se utilizan estas redes como medios para desarrollar adaptativamente los coeficientes de las funciones discriminantes, a través de presentaciones sucesivas de conjuntos de patrones de entrenamiento.

Existen diferentes arquitecturas de redes entre las que se mencionan la de “Multilayer Perceptron”, “RBF (Radial Basis Function)”, Kohonen, etc. No se

desarrollará aquí una descripción detallada de cada una de estas arquitecturas, sólo se verán algunos conceptos generales.

La primera de ellas, una de las más populares, permite modelizar funciones complejas, y el número de capas y de neuronas determinan dicha complejidad. Para estas redes se debe determinar el valor adecuado para los parámetros libres, es decir los pesos y los valores de umbral que permitan minimizar el error.

Los algoritmos de entrenamiento de la red pueden ser supervisados o no supervisados, sin embargo los primeros son los más comunes. En los supervisados, el usuario propone un conjunto de datos de entrenamiento, que contienen ejemplos de datos de entrada junto con su correspondiente salida. La red aprende a inferir la relación entre ambas. Un algoritmo de entrenamiento supervisado conocido y muy usado es el de “Back Propagation”, donde se calcula el vector gradiente de la superficie de error. Los datos de entrenamiento determinarán también el correcto funcionamiento de la red. La cantidad de datos de entrenamiento debe ser tal, que permita encontrar el mínimo error de la superficie y no estancarse en mínimos locales.

Las redes de Kohonen son diseñadas para realizar entrenamiento no supervisado, donde sólo tenemos las variables de entrada y se intenta aprender de la estructura de los datos. Dichas redes pueden aprender a reconocer agrupamientos de datos similares y pueden también relacionar clases similares entre sí. Cuando se encuentran datos nuevos, la red no puede reconocerlos y esto indica una novedad. Una red Kohonen sólo tiene dos capas: la de entrada y la de salida de unidades radiales. Se entrenan mediante un algoritmo iterativo, comenzando con un conjunto de centros radiales aleatorios, el algoritmo los ajusta gradualmente para reflejar los agrupamientos en los datos de entrenamiento.

La principal ventaja encontrada en utilizar redes neuronales para aplicaciones de sensado remoto es su posibilidad de hacer clasificaciones a partir de múltiples

fuentes. Las redes que se utilizan en sensado remoto, generalmente, contienen una capa de entrada que está compuesta por nodos que se activan con los datos de la imagen, y una capa de salida cuyos nodos representan las clases posibles para las que se hace el entrenamiento. Ambas capas están separadas por una o más capas escondidas. Un nodo de una capa se engancha con todos los nodos de las capas por debajo. El número de iteraciones, el de capas escondidas y los radios de aprendizaje se determinan por prueba y error durante el proceso de entrenamiento, ya que no existe una metodología precisa para la selección de la red óptima en una determinada aplicación.

Existen algunos trabajos realizados en el campo de sensado remoto utilizando redes neuronales, algunos de ellos combinándolas con técnicas de “wavelets” [www2].

### **Clasificación no supervisada [Lan99][www12]**

Existen situaciones en las que se dispone de un conjunto de datos relacionados por ciertas características, pero no se conoce a priori la clasificación de los mismos. Es más, puede no conocerse a priori la cantidad de clases presentes. En estos casos, se pueden usar los métodos de agrupamiento para dar un entendimiento de la estructura de los datos y una medida numérica útil acerca de las características de los mismos.

Además, los métodos de agrupamiento permiten reducir la cantidad de información agrupando ítems de datos similares. Como se ha dicho, una de las razones para utilizar algoritmos de clasificación es la obtención de herramientas automáticas para ayudar a construir categorías o taxonomías.

El problema del “clustering” se puede ver como el problema de la taxonomía biológica, donde las plantas y animales son clasificados según ciertas características en reinos y familias, “creados” a partir de información anterior de otras plantas y animales. Aquellas plantas o animales que no se correspondan adecuadamente con alguna de las categorías existentes podrían ser miembros de una nueva categoría o “cluster”.

Los métodos de agrupamiento pueden ser clasificados en dos tipos: por partición o jerárquicos.

Estos últimos trabajan mezclando pequeños “clusters” o dividiendo “clusters” grandes. Los métodos pertenecientes a este tipo, difieren en la forma de decidir cuáles son los “clusters” pequeños que deben unirse o cuáles los grandes que deben dividirse. En todos los casos, el resultado final del algoritmo es un árbol de “clusters” que muestra la forma en que están relacionados. El resultado del agrupamiento estaría determinado por el nivel de corte de dicho árbol.

Por otro lado, los métodos de agrupamiento por partición intentan descomponer el conjunto de datos en clases disjuntas. Típicamente el criterio global busca minimizar alguna medida de disimilitud entre las muestras pertenecientes a una misma clase mientras que busca maximizar la diferencia entre diferentes clases.

A continuación se detallan algunos métodos de agrupamiento analizados.

**a) Con número de clases conocidas.**

• ***Método de las k-medias*** [Mar94][www10][www11]

El nombre de este algoritmo hace referencia a que se conoce a priori que existe un número  $k$  de clases o patrones involucrados en el problema. Es un algoritmo sencillo, pero muy eficiente, siempre y cuando se conozca el valor de  $k$  con exactitud.

Partiendo de un conjunto de objetos a clasificar:  $X_1, X_2, \dots, X_p$ , el algoritmo realiza las siguientes operaciones:

1. Se seleccionan al azar entre los elementos a agrupar  $k$  vectores, de forma de constituir los centroides de las  $k$  clases. Recordar que  $k$  es el número de clases, ingresado por el usuario.
2. Se realiza un proceso recursivo, en el que en una cierta iteración genérica  $n$  se distribuyen todas las muestras entre las  $k$  clases de acuerdo a la menor distancia de la muestra y los centroides de dichas clases.

3. Una vez redistribuidos los elementos a agrupar entre las diferentes clases, es preciso calcular nuevamente o actualizar los centroides de las clases.

4. Se repite el proceso (a partir de 2) hasta que no existan cambios significativos en los centroides de las clases respecto de la iteración anterior.

De acuerdo un trabajo de investigación realizado sobre estos métodos de agrupamiento, se obtuvieron los siguientes resultados de acuerdo a dos opciones implementadas para el paso 1:

**Opción 1:** Se eligen los k primeros puntos sin importar si hay valores repetidos.

**Opción 2:** Se eligen los primeros k puntos distintos.

Para la opción 1, la imagen se recorre por filas hasta reunir k elementos distintos. En caso de no haber en la imagen k puntos distintos, se reduce el valor de k a la cantidad de valores encontrados.

### **Breve análisis del método**

Este método es fuertemente dependiente del k seleccionado por el usuario.

Si seleccionamos un valor de k mayor que la cantidad de clases existentes en la imagen de entrada, se observa que se crean clases ficticias.

Para imágenes cuyos patrones se encuentran dispersos, puede observarse que se crean clases que no contienen elementos. Esto se debe a que los centros están muy separados entre sí y que la variedad de patrones es inferior al número de clases.

También se puede observar que cuando se tiene un valor de k mayor que la cantidad real de clases existentes, y se elige la opción 1 para seleccionar los centros iniciales, no se suele lograr una clasificación correcta.

- **Método Isodata** [Tou74][www8][www9]

ISODATA es el acrónimo de la definición en inglés: Iterative Self-organizing Data Analysis Techniques, al que se le agregó la letra A para conseguir una palabra más fácilmente pronunciable.

Este método está basado en el algoritmo de k-medias, con el agregado de una cantidad de parámetros y operaciones que llevan a mejorar ciertos aspectos del mismo. Esto a su vez, le da un mayor contenido heurístico y el usuario deberá tener conocimiento de la medida en que influye cada uno de estos parámetros en el resultado.

A diferencia del algoritmo de las k-medias, el valor de k utilizado en el método Isodata es un valor esperado de clases, no un número exacto. Por ello, el algoritmo inicialmente considera un número A de clases, que a lo largo de la ejecución se trata de aproximar a k.

Como ya se mencionó anteriormente, existen situaciones en las cuales el método de las k-medias genera clases con muy pocos elementos o simplemente vacías. Por ello, la primer acción del ISODATA es eliminar estas clases y lo hace utilizando el parámetro  $\theta_N$ , que representa la cantidad mínima de elementos que debe contener una clase para considerarse como tal.

Se vio para k-medias, que cuando el número de clases consideradas es menor que la cantidad real de clases existentes, se producen dispersiones muy grandes, precisamente causadas por los agrupamientos forzados de elementos.

El algoritmo ISODATA utiliza como criterio de división:

- La relación entre la dispersión por agrupamiento ( $D_j$  dispersión del agrupamiento j) y la dispersión global (D) y el número de elementos del agrupamiento.

Este criterio es muy débil cuando se trata de clases con dispersiones no uniformes, ya que un alto porcentaje de clases verificarán la condición  $D_j > D$ . Esto no podría solucionarse mediante  $\theta_N$  ya que si se aumenta demasiado el valor de este parámetro se descartarían demasiadas clases en el paso de eliminar agrupamientos.

- La cantidad de clases existentes hasta el momento. En este caso  $\theta_S$  (desviación típica máxima) se utiliza para solucionar el problema de tener un número real de clases menor que el esperado y una dispersión baja.

Suponiendo que el número de agrupamientos sea demasiado alto, se producirán clases cuyos centros están muy cercanos. Para solucionar este problema, el método ISODATA une agrupamientos teniendo en cuenta la distancia entre los centros. Se utiliza el parámetro  $\theta_C$  como cota superior para el valor de las distancias a considerar, y el parámetro  $L$  como límite de la cantidad máxima de clases a unir por iteración.

### **Ventajas y Desventajas**

- Provee mejores resultados que el método de k-medias
- Es fuertemente dependiente de los parámetros ingresados, por lo que hay que tener suficiente conocimiento sobre ellos.
- Permite una mayor interacción con el usuario, mediante el ajuste de los parámetros. Si se tiene un conocimiento del tipo de imagen con la que se trabaja se logran los resultados deseados.

### **b) Con número de clases desconocidas.**

- *Algoritmo adaptativo* [Mar94]

Éste es un método heurístico incremental que emplea únicamente dos parámetros muy relacionados:

$\hat{\sigma}$ : umbral de distancia para crear agrupamientos

$\theta$ : fracción de  $\hat{\sigma}$  que determina *total confianza*.

La líneas generales del algoritmo son las siguientes:

1. La parte esencial del algoritmo es crear agrupamientos en base al umbral de distancia  $\hat{\sigma}$  (ponderado por  $\theta$ ). El primer agrupamiento se establece arbitrariamente.
2. Cuando un patrón se asigna a un agrupamiento, se recalcula el centro del agrupamiento. Este cálculo puede hacer que algunos patrones cambien de estado, eliminándose del agrupamiento al que pertenecían o asignándose a un agrupamiento.
3. Los cambios de estado son posibles porque se hacen repetidas pasadas del conjunto de patrones utilizado para agrupar. Este proceso repetitivo se termina cuando no hay reasignaciones: la partición se considera estable.
4. Se utiliza una parte,  $N$ , del total de patrones a agrupar,  $M$ , para definir los agrupamientos.

Uno de los problemas más graves de este método es su fuerte dependencia del orden de presentación de los patrones de entrada. Dado que los centros se van adaptando a medida que ingresan los patrones, se puede llegar a clasificaciones erróneas si se trata de clases solapadas (**Figura 4.2 a y b**).

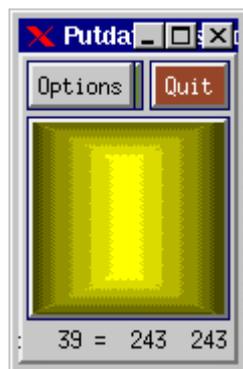


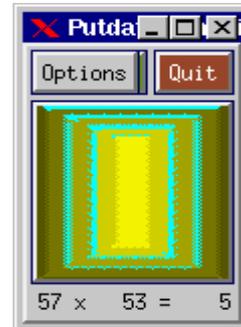
Figura 4.2 a - Imagen original



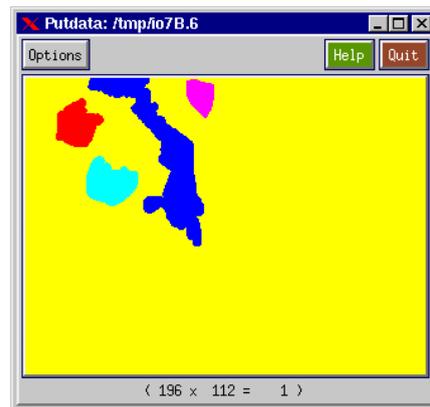
Figura 4.2 b - Imagen resultante de aplicar método adaptativo con parámetros  $q = 0,5$  y  $t = 1$ . Clases solapadas

También, es importante la elección de los valores  $\theta$  y  $\tau$ , ya que esto incidirá en el tamaño de la región de aceptación, indeterminación o rechazo. (**Figura 4.3**)

**Figura 4.3-** Resultado de aplicar el método con un valor de  $\tau = 50$  y  $\theta = 0,5$ . Al aumentar  $\tau$  las clases se van uniendo y quedan menos clases, pero más distinguibles. El color celeste pertenece a la clase de rechazo.



Para la imagen de la **Figura 4.2 a**, el método no encuentra una solución aceptable. Para clases con centros perfectamente separados el método da buenos resultados como puede verse en la **Figura 4.4**.



**Figura 4.4 -** Resultado de aplicar el método. Se obtienen las mismas clases que en la imagen original.

#### Ventajas:

- Es un método simple
- Es rápido ya que realiza cálculos sencillos
- Se utiliza un almacenamiento mínimo ya que los patrones se recorren secuencialmente, y sólo se guarda la información de los centros existentes hasta el momento.

- No es necesario conocer a priori el número de clases

**Desventajas:**

- Supone agrupamientos compactos y separados claramente. Presenta problemas cuando hay solapamientos.
  - Está sesgado por los primeros patrones
  - Depende del orden de presentación de los patrones
  - Depende de los valores de  $\theta$  y  $\tau$  seleccionados.
  - No permite descartar clases con muy poca cantidad de elementos.
- ***Algoritmo de Batchelor y Wilkins [Mar94]***

Este algoritmo, propuesto por Batchelor y Wilkins, es llamado también de máxima distancia. Se trata de un método heurístico incremental que emplea un único parámetro:

$f$ : fracción de la distancia media entre los agrupamientos existentes. Se usa para calcular un umbral de distancia para decidir si se crea un agrupamiento.  $0 \leq f \leq 1$ .

Las líneas generales del algoritmo son las siguientes:

1. Se crea un agrupamiento si la distancia de un patrón al agrupamiento más cercano supera un valor umbral. El primer agrupamiento se establece arbitrariamente.
2. En este algoritmo, a diferencia del adaptativo, el umbral de distancia no es fijo y se calcula en base al parámetro y a la distancia media entre los agrupamientos existentes en el momento de su evaluación.
3. El aprendizaje termina cuando no se crean nuevos agrupamientos.

Resumiendo, trata de mejorar la dependencia de los datos de entrada que tiene el método anterior, tomando como criterio para la creación de clases un factor (factor de creación,  $f$ ) de la distancia media entre los “clusters” existentes.

Esto si bien introduce una mejora en la clasificación, agrega tiempo de cálculo ya que todos los patrones que no han sido clasificados hasta el momento son inspeccionados para ver cual puede convertirse en el próximo centro. Esto implica que la cantidad de consultas sobre cada patrón es del orden  $n^2$ .

En cuanto a la memoria, este método está en desventaja con respecto al anterior, ya que es necesario guardar información sobre los patrones no clasificados.

Dado que los centros de los “clusters” no son recalculados a medida que se incorporan patrones a las clases, se pueden presentar problemas en caso de clases muy dispersas.

Para la imagen original presentada en la **Figura 4.2 a**, este método no logra resolver adecuadamente el problema de la clasificación. Para valores altos de  $f$  (factor de creación), el método tiende a decrementar la cantidad de clases. Para valores más pequeños se obtienen imágenes con mayor cantidad de clases, pero solapadas (**Figura 4.5**).



Figura 4.5 - Aplicación del algoritmo de Batchelor & Wilkins

Un valor de  $f$  intermedio, no llega a encontrar todas las clases. Como se observa a continuación en la **Figura 4.6**:

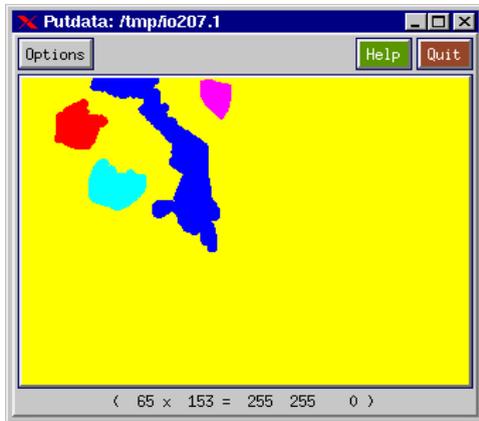


Figura 4.6 a- Imagen Original

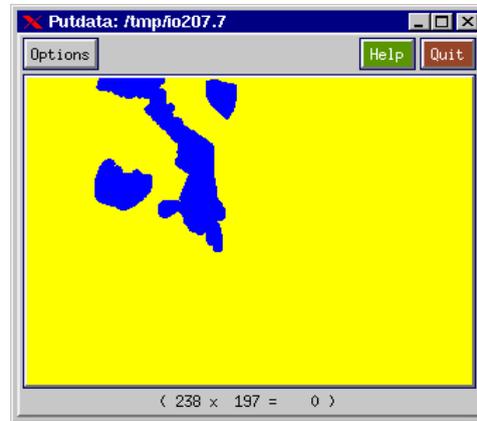


Figura 4.6 b - Para valores de  $f > 0.6$ , no se logran los resultados esperados. Para valores de  $f \leq 0.5$  dio el resultado deseado.

Con este ejemplo de la **Figura 4.5** se quiere mostrar que mediante este método para imágenes sin solapamientos, donde las clases están perfectamente separadas se pueden llegar a obtener buenos resultados dando el valor adecuado al parámetro  $f$ .

#### Ventajas:

- Es un método simple
- No es necesario conocer a priori el número de clases

#### Desventajas:

- El resultado cambia con la elección del primer patrón
- Requiere almacenamiento adicional para registrar los patrones que aún no han sido clasificados.

- Requiere una gran cantidad de cálculo por cada patrón a clasificar, ya que calcula la máxima de las mínimas distancias.
- Es necesario cuantificar la fracción de distancia entre clases a considerar para decidir si se debe crear un nuevo agrupamiento o no.

#### 4.4. Métodos basados en modelos biofísicos

Dentro de los métodos que se utilizan para la clasificación de imágenes obtenidas con sensores remotos, encontramos un conjunto de procedimientos que permiten el análisis de datos espectrales. Entre ellos, tenemos el análisis de mezclas espectrales (spectral mixture analysis = SMA) [Pin98] [Ust93][Ust98][www3]. Los enfoques de mezcla asumen que las observaciones multiespectrales pueden ser entendidas como combinaciones de firmas espectrales extremas (llamadas miembros extremos) de objetos individuales presentes en la escena. SMA es un marco de trabajo integrado y estructurado que simultáneamente resuelve el problema de pixel de mezcla, la calibración y variaciones en la geometría de la luz. Los resultados se muestran en términos de proporciones de miembros que pueden ser relacionados con unidades observacionales estándares. La forma general de la ecuación de SMA para cada banda se expresa como:

$$R_b = \sum_{em=1}^N F_{em} R_{em,b} + E_b \quad (\text{Ec 4.12})$$

donde  $R_b$  es la radiancia en la banda  $b$

$F_{em}$  es el coeficiente de fracción de cada miembro

$R_{em}$  pesando su radiancia en la banda  $b$

$E_b$  es un término de error para la radiancia no modelada en la banda  $b$

Los miembros extremos son elegidos para explicar los materiales espectralmente distintos que forman la vaina convexa del volumen espectral.

El método es relativamente insensible a los rasgos sutiles de absorción, y produce errores de cuantificación significativos debido a la variabilidad de los miembros

extremos que surgen de mezclas lineales y no lineales (por ejemplo, por geometría de la luz y dispersión) en un pixel.

El SMA es útil para aplicaciones de mapeo de vegetación debido a la continua variación en la composición de un pixel en la escala de muchos de los satélites. Cuando se trabaja con los miembros extremos (tipos espectrales puros o clases) en el SMA, esto puede ser similar en concepto a los clasificadores tradicionales, aunque no están contruidos de la misma manera. Esto es, pueden ser considerados como bloques de construcción básicos a partir de los cuales los pixeles varían en proporciones de componentes ambientales comunes (suelo, vegetación, etc.). Las clases definidas en los algoritmos de clustering son generalmente determinadas por otro criterio, por ejemplo, la categoría taxonómica (soja, maíz, etc.).

Los índices de vegetación (ver **Capítulo 2, Sección 7**) pueden verse como modelos lineales de dos miembros extremos, e intentan directamente estimar una planta dada a partir de la manipulación de las mediciones espectrales.

Existe otra técnica conocida como foreground/background analysis (FBA) desarrollada por Smith et al. como una mejora del SMA [Smi94]. En esta técnica, las medidas espectrales son divididas en dos grupos las del fondo (background) y las del primer plano (foreground) que comprenden un subconjunto seleccionado de espectros los cuales enfatizan la presencia de una firma espectral de interés.

#### **4.5. Método de razonamiento evidencial**

Como se dijo, esta investigación tiene como objetivo estudiar técnicas de clasificación de imágenes obtenidas por sensado remoto. Se vienen produciendo numerosos avances en el campo de “remote sensing”, tales como resoluciones espaciales y espectrales altas y que pueden poseer bandas de información numerosas y propiedades estadísticas diversas (por ejemplo, imágenes hiperespectrales). Todo esto, sumado a la necesidad de combinar datos de múltiples fuentes auxiliares (ejemplo: modelos digitales de elevación, datos climatológicos, datos temáticos de

un sistema de información geográfico) ha llevado a buscar salidas alternativas a los métodos de clasificación convencionales [Ped95 a].

Se presenta aquí un posible enfoque alternativo a los métodos de clasificación tradicionales basado en la teoría de Dempster – Shafer [Dem67][Sha76][Mur98]. Este método ha sido utilizado en aplicaciones para clasificación de bosques y de hielos permanentes en Canadá utilizando imágenes multiespectrales [Ped93].

La teoría matemática de la evidencia fue propuesta por Shafer (1976) como una extensión y refinamiento de la Regla de Dempster de combinación (Dempster, 1967). La misma provee una base general y heurística para integrar cuerpos distintos de información a partir de fuentes independientes.

A pesar que la teoría es general en naturaleza, y podría ser aplicada a cualquier problema que requiera agrupamiento de información para determinar la mejor respuesta a partir de un conjunto de opciones, será aquí presentada en términos de la nomenclatura y principios de la clasificación de sensado remoto. Para un pixel dado, la tarea de una clasificación es asignar el pixel a un miembro de un conjunto de clases.

## **Definiciones**

### ***Definición 4.1 - Marco de discernimiento:***

En la teoría de evidencia [Gar95][Rus92], el conjunto de todas las clases posibles constituye el marco explícito dentro del cual la discriminación ocurre, y se refiere como el marco de discernimiento ( $U$ ). Por ejemplo: si estamos tratando de determinar la enfermedad de un paciente, el marco de discernimiento es el conjunto de todas las enfermedades posibles que puede presentar el mismo.

A cada subconjunto  $S$  de  $U$  se le asocia una medida de **soporte o evidencia** y una de **plausibilidad**.

**Definición 4.2 - Evidencia o soporte:**

El soporte se define como la masa o evidencia que se tiene a favor de una clase. Usualmente es un número real entre 0 y 1, inclusive.

**Definición 4.3 - Función de creencia o vector de evidencia:**

Para una fuente de datos dada, el conjunto de todas las masas sobre el marco de discernimiento es una función de creencia, la cual en esta investigación también se llama **vector de evidencia**.

Ejemplo: sea  $U=\{A, B, C\}$ , y  $m(A)= 0.24$ ,  $m(B)=0.5$ ,  $m(C)= 0.10$  siendo  $m$  el soporte para una cierta fuente.

Entonces el vector de evidencia o función de creencia para esa fuente es: [0.24, 0.5, 0.10]

**Definición 4.4 - Plausibilidad:**

Además del soporte evidencial, la teoría considera una medida de **plausibilidad**, o la cantidad de evidencia que falla para refutar una proposición. La plausibilidad representa la evidencia que no refuta una proposición, y se calcula como 1 menos la suma del soporte para todas las otras proposiciones.

$$P_j = 1 - \sum_{i=1}^m s_i \quad \forall i \neq j$$

donde  $P_j$  es la plausibilidad para la clase  $j$  y  $s_i$  es el soporte para la clase  $i$ .

En el contexto de una clasificación de sensado remoto, la plausibilidad para la clase  $C_i$  podría ser computada como  $1 - S(\neg C_i)$ , donde  $S$  representa el soporte evidencial. La verdadera factibilidad de una proposición está dentro del rango de valores posibles en el intervalo que va desde la medida de soporte a la de plausibilidad para la clase  $C_i$ , el cual es llamado **intervalo evidencial**. El uso del intervalo evidencial permite que tanto el soporte en favor del rótulo de clase y el nivel asociado de incertidumbre sean incluidos en una regla de decisión.

**Ejemplo:** supongamos que dos médicos examinan un paciente y están de acuerdo en que sufre o de varicela (V), o rubéola (R), o de sarampión (S). Entonces  $U = \{V, R, S\}$ . Sin embargo, difieren en el diagnóstico teniendo cada uno en cuenta su conocimiento previo, análisis realizados al paciente, etc.:

Médico 1 (M1), Médico 2 (M2)

$$M1(\{V\}) = 0.70$$

$$M1(\{R\}) = 0.10$$

$$M1(\{S\}) = 0$$

$$M2(\{V\}) = 0.30$$

$$M2(\{R\}) = 0.20$$

$$M2(\{S\}) = 0.40$$

Como se puede apreciar en los valores anteriores, están de acuerdo en la baja creencia de que sea rubéola, pero el médico 2 cree más en un sarampión que en varicela. Sin embargo, el médico 1 parece tener la suficiente evidencia para asegurar que es varicela.

Los valores otorgados a cada posible subconjunto de interés de  $U$  constituyen el **soporte o evidencia** a su favor. Cada médico constituye una fuente diferente de información.

La función de creencia o vector de evidencia es:

$$\text{Para la fuente } M1 = [0.70, 0.10, 0]$$

$$\text{Para la fuente } M2 = [0.30, 0.20, 0.40]$$

**Suma ortogonal [Dem67][Ped95 b]**

Dados los vectores evidenciales (por ejemplo, calculados para un pixel en 1 conjunto de datos multifuente o en el caso anterior para cada médico), la tarea que queda es

**combinar la evidencia** de todas las fuentes en una forma unidimensional conteniendo una única medida de soporte y plausibilidad para cada clase.

La descomposición de los vectores evidenciales de una fuente específica en una función de masa resultante se alcanza por suma ortogonal usando la Regla de Dempster de combinación. El poder de esta regla puede ser aplicado a cualquier número de fuentes, cada una de las cuales conteniendo evidencia para un conjunto de clases.

La suma ortogonal de evidencia a partir de dos fuentes trabaja multiplicando secuencialmente la evidencia para una clase dada de una fuente por la evidencia de cada clase de la siguiente fuente. Luego, se aplica un factor de normalización que corrige para cualquier masa que haya sido adjudicada al conjunto vacío.

La suma ortogonal de dos vectores de evidencia  $m_1$  y  $m_2$  se denota por  $m_1 \oplus m_2$

Supongamos que trabajamos con conjuntos de clases simples, entonces la ecuación de la suma ortogonal de Dempster para determinar la nueva masa  $m'$  asignada a la proposición  $n$ -ésima de  $A$  puede escribirse como:

$$m'_i(A_n) = K^{-1} \sum_{A_i \cap A_j = A_n} m_1(A_i) m_2(A_j) \quad (\text{Ec 4.13 a})$$

$$K = 1 - \sum_{A_i \cap A_j = \Phi} m_1(A_i) m_2(A_j) \quad (\text{Ec 4.13 b})$$

Continuemos con el ejemplo anterior [San2000]:

Tabla 4.1 – Cálculo de suma ortogonal dos fuentes, de acuerdo al ejemplo

$\oplus$	Fuente: médico 1			
Fuente: médico2	M1(V)=0.70	M1(R)=0.10	M1(S)=0	M1( $\Theta$ )=0.20
M2(V)=0.30	M1(V)*M2(V)=0.21	M1(R)*M2(V)=0.03 $\phi$	M1(S)*M2(V)=0 $\phi$	M1( $\Theta$ )*M2(V)=0.06
M2(R)=0.20	M1(V)*M2(R)=0.14 $\phi$	M1(R)*M2(R)=0.02	M1(S)*M2(R)=0 $\phi$	M1( $\Theta$ )*M2(R)=0.04
M2(S)=0.40	M1(V)*M2(S)= 0.28 $\phi$	M1(R)*M2(S)=0.04 $\phi$	M1(S)*M2(S)=0	M1( $\Theta$ )*M2(S)=0.08
M2( $\Theta$ )=0.10	M1(V)*M2( $\Theta$ )=0.07	M1(R)*M2( $\Theta$ )=0.01	M1(S)*M2( $\Theta$ )=0	M1( $\Theta$ )*M2( $\Theta$ )=0.02
M1 $\oplus$ M2	$K^{-1} \sum m(V)=0.666$	$K^{-1} \sum m(R)=0.137$	$K^{-1} \sum m(S)=0.156$	$K=1- m(\phi)=0.51$
Plausibilidad	0.707	0.178	0.197	

La función de creencia o vector de evidencia resultante es:

$$M1 \mathbf{\hat{A}} M2 = [0.666, 0.137, 0.156]$$

Una regla de decisión puede ser elegir la clase con mayor soporte [Lee87][Wil90]. Para este ejemplo la clase con mayor soporte es la V (varicela). Otra opción es seleccionar la clase con mayor plausibilidad [Kim90][Sri90]. También autores como Peddle han optado por la mayor suma de soporte y plausibilidad [Ped95 a].

### Especificación de conocimiento

Una de las dificultades en la aplicación de la teoría matemática de evidencia para una aplicación dada, es que el marco evidencial no incluye especificación de cómo derivar o crear las medidas de soporte y de plausibilidad que se usan como entrada al procedimiento (esto también afecta la computación de medidas de incertidumbre)

En algunas instancias, esto no es un problema si la información disponible puede ser considerada evidencia apropiada a ser usada como entrada directa de la teoría de evidencia. Sin embargo, puede no ocurrir tal situación y se debe crear una interface para el razonamiento evidencial que permita derivar los valores de soporte y plausibilidad necesarios.

Obviamente, la habilidad de esta interface para trasladar la información disponible en evidencia, es crítica para lograr las ventajas ofrecidas por el razonamiento evidencial y afecta el grado de éxito obtenido.

Los datos de imagen de sensado remoto no proveen medidas directas de evidencia para la entrada al clasificador, y por eso se debe aplicar un proceso separado para derivar las medidas requeridas. Peddle propone computar las medidas de evidencia a partir de datos de entrenamiento en un marco de **clasificación supervisada [Ped95 b]**.

Este tipo de clasificación involucra al analista de la imagen para que determine el conjunto de clases con las que se trabajará y para cada clase, áreas representativas dentro de la imagen (entrenamiento del clasificador).

La **frecuencia de ocurrencia** de los valores de pixel individual constituye la base para formar vectores evidenciales para todas las clases.

Las premisas subyacentes para este método son que:

- 1) **los datos de entrenamiento contienen evidencia para el conjunto de clases**
- 2) **la frecuencia de ocurrencia de un valor dado en el conjunto de entrenamiento representa las magnitudes de soporte para la clase.**

Ejemplo:

Supongamos que se tiene un pixel a clasificar cuyos valores son (0.45, 0.9, 198); el primer valor se corresponde con la fuente 1, el segundo con la fuente 2 y así siguiendo, y además se tienen las siguientes cantidad de muestras para cada fuente y clase para el valor del pixel correspondiente:

Tabla 4.2 - Cantidad de muestras por fuente y clase. Tsn se refiere al total de muestras para una clase

	TSn	Fuente 1 (0.45)	Fuente 2 (0.9)	Fuente 3 (198)
Clase1	223	56	23	10
Clase2	300	80	12	12
Clase3	70	1	34	14
Clase4	90	24	44	33

¿Cómo se deriva entonces la evidencia?

Tabla 4.3 a - Frecuencia de Ocurrencia para la clase 1 [Ped91]

Clase 1 (TSn)	Fuente 1						
Valor de pixel	0	0.2	0.4	0.45	0.6	0.8	1
Cantidad de ocurrencias	2	34	78	56	40	13	0

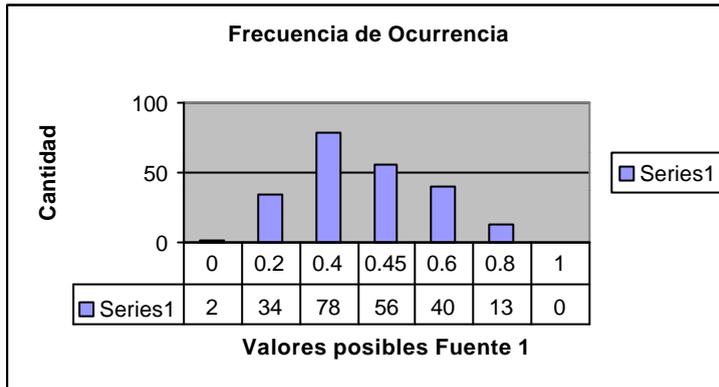


Figura 4.6 – Frecuencia de Ocurrencia para la fuente 1

Tabla 4.3 b - Frecuencia de Ocurrencia para la clase 2

Clase2	Fuente 1						
Valor de pixel	0	0.2	0.4	0.45	0.6	0.8	1
Cantidad de Ocurrencias	4	5	50	80	120	40	1

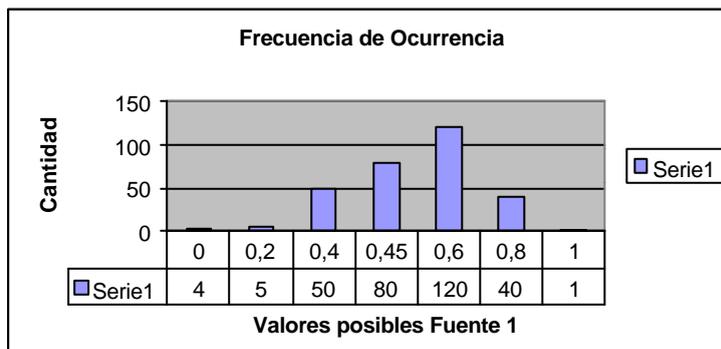


Figura 4.7 – Frecuencia de Ocurrencia para la fuente 1

Tabla 4.5 - Evidencia derivada

	TSn	Fuente 1	Fuente 2	Fuente 3
Clase1	223	$56/223=0.251$	0.103	0.044
Clase2	300	0.266	0.04	0.04
Clase3	70	0.014	0.485	0.2
Clase4	90	0.266	0.488	0.366

### Transformación de Bin

Para datos cuantitativos (por ejemplo, radio de medidas), se puede transformar la frecuencia de ocurrencia para extender el conocimiento de los datos de entrenamiento a un rango dinámico mayor de los datos de la fuente, y reducir cualquier desvío asociado con las cuentas de frecuencias individuales.

Esto se realiza utilizando una función que depende de la distancia, y es lineal y multiplicativa. Se basa en dos principios:

- Si un valor  $I$  ocurre en los datos de entrenamiento para la clase  $c$ , entonces valores similares también son indicativos de la clase (ejemplo: para valores cuantitativos, los datos que van de  $+/- 1$  pertenecen a la clase  $c$ )
- La probabilidad,  $p$ , de que valores similares representen la clase  $c$  incrementa con la proximidad a  $I$ , es decir,  $p(I +/- 1 \in c) > p(I +/- 2 \in c)$

El usuario puede especificar el tamaño de bin para cada fuente individual. La propagación de la evidencia se produce en forma simétrica.

La función a aplicarse para un valor de dato de entrenamiento  $i$  es la siguiente:

$$f(j) = f(j) + a \times (b - 2 \times |i - j|) \quad (\text{Ec 4.14})$$

Donde:

$$a = f(i)$$

$b$  = es el tamaño de “bin” especificado por el usuario

$f(j)$  = evidencia para el dato  $j$

y se debe cumplir que  $|i - j| < b/2$

Esta función debe aplicarse para cada valor de muestra de todas las clases para las fuentes que el usuario indique.

El enfoque de “transformación de bin” permite que la evidencia sea distribuida consistente y objetivamente a partir de los datos de múltiples fuentes, formatos, y escalas de medición diferentes. Sin embargo, **esta transformación no puede ser aplicada a cualquier tipo de datos**, ya que por ejemplo si una de las fuentes es el resultado de una clasificación anterior, no tendría sentido extender la distribución de los datos para esa fuente en particular.

El usuario también podría tener la opción de especificar factores de peso distintos para las fuentes individuales, si hay suficiente información a priori sobre la importancia relativa de cada fuente de datos para la clasificación.

#### **4.6. Matriz de confusión e indicador Khat**

Una de las formas de expresar la precisión de la clasificación es la matriz de error, también llamada de confusión o tabla de contingencia. Las matrices de error son simplemente tablas mostrando las observaciones de datos reales de suelo en comparación con la información derivada de los datos sensados remotamente. Son matrices cuadradas, con el número de filas y columnas igual al número de categorías cuya precisión en la clasificación se está evaluando.

La matriz se desarrolla a partir de la clasificación de píxeles del conjunto de entrenamiento, se lista la cantidad de píxeles por tipo categoría (fila) versus los píxeles clasificados en cada categoría de tipo de suelo (columna).

A partir de estas matrices se pueden estudiar varios errores de clasificación como los de omisión (exclusión) y los de comisión (inclusión). Los píxeles pertenecientes a la diagonal son los que han sido correctamente clasificados, mientras que el resto representan errores.

**Error de comisión:** corresponden a los elementos de la columna (no pertenecientes a la diagonal)

**Error de omisión:** corresponde a los elementos de la fila que no pertenecen a la diagonal.

Se pueden obtener otros descriptores, como por ejemplo la precisión general, que se computa como el número total de píxeles correctamente clasificados sobre el total de píxeles de referencia.

Para analizar la matriz de error en más detalle se calcula un coeficiente de acuerdo. El mismo se conoce como **KAPPA (KIA)**, y también como **KHAT**. Esta medida estadística fue introducida por el psicólogo COHEN en 1960 y fue adoptada para la evaluación de la precisión en campos de sensado remoto por Congalton y Mead (1983) [Con83][Ros86].

KIA permite evaluar la precisión de una clasificación en contraposición con los datos reales de suelo. La siguiente es la fórmula para calcular este coeficiente.

$$\kappa = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})} \quad (\text{Ec 4.15})$$

r      número de filas de la tabla de clasificación

$x_{ii}$     número de combinaciones de la diagonal

$x_{i+}$     total de observaciones en la fila i

$x_{+i}$     total de observaciones en la columna i

N      número total de observaciones

Resumiendo, se tiene que

$$k = \frac{Po - Ap}{1 - Ap} \quad (\text{Ec 4.16})$$

donde  $Po$  es la precisión observada y  $Ap$  es el acuerdo probable.

### **4.7. Conclusiones del capítulo**

En este capítulo se presentan los métodos de clasificación más conocidos y utilizados, incluyendo ejemplos para algunos de ellos.

También, se introduce una división de los mismos en supervisados y no supervisados. El primer grupo se caracteriza por tener un vector prototipo para cada clase y tener un maestro que guía el proceso de clasificación, mientras que en el segundo, se trabaja con una agrupación natural de los datos de acuerdo a características que los hacen similares. Por otra parte, no existe ningún supervisor que guíe tal proceso.

El método de razonamiento evidencial tal como fue presentado por autores como Peddle es explicado aquí.

La razón de este capítulo es proveer un contexto para desarrollar el método que se presenta en esta tesis y su comparación con los métodos de clasificación más tradicionales. ◆

## **CAPITULO 5**

### **Método propuesto:**

#### **Razonamiento Evidencial Dinámico**

##### **5.1. Introducción**

Esta tesis presenta y describe un nuevo método de clasificación (RED: razonamiento evidencial dinámico) basado en el razonamiento evidencial al que se le introducen una serie de modificaciones.

RED permite la inclusión de nueva evidencia para el proceso de clasificación y propone una regla de decisión para la asignación de un objeto desconocido a una clase.

El algoritmo de razonamiento evidencial provee una forma de combinar evidencia a partir de distintas fuentes de información. Es una técnica de clasificación supervisada, que utiliza un conjunto de muestras de entrenamiento. RED agrega una etapa de aprendizaje para introducir la evidencia, lo que provoca una mejora en la precisión. Este proceso consiste en observar el valor obtenido de Khat cuando se realiza la clasificación del conjunto de muestras de entrenamiento, y decidir si es necesario modificar la evidencia actual.

La regla de decisión planteada utiliza, en principio, la medida de plausibilidad y la de soporte y estudia una serie de situaciones antes de tomar la decisión sobre la clase a la que se asignará el objeto desconocido. Su objetivo es realizar un análisis de la aceptación o no aceptación del objeto desconocido como perteneciente a una de las clases definidas para el algoritmo. Cuando no existe claridad respecto de esta decisión usando las medidas de soporte y plausibilidad, se agregan otras medidas como la cantidad de fuentes que aportan evidencia a favor de una clase y un peso para mostrar la “importancia” de la información de esa fuente para la clase en

cuestión. Con esto se quiere lograr obtener decisiones más cercanas a la realidad, analizando cuidadosamente los casos en que el soporte para varias clases es similar o cuando la evidencia no sea “suficiente”. Se consideran distintas alternativas para el significado de “suficiente” y diferentes posibilidades de decisión en dichos casos.

Se aplica el método propuesto para clasificar cultivos en imágenes hiperespectrales de la región de Nebraska (USA) [Pra98]. Se presentan los resultados obtenidos para evaluar la precisión de RED.

## **5.2. Descripción del método**

La técnica de Razonamiento Evidencial propuesta por Peddle [Ped95 b], utiliza un conjunto de muestras de entrenamiento, del que se extraen las medidas de soporte y plausibilidad involucradas en la clasificación. Las fuentes de información a partir de las que se calculan las medidas de soporte y plausibilidad pueden ser de diferente naturaleza, por ejemplo se puede tener el resultado de una clasificación previa (rótulo asignado en la clasificación), un indicativo de la textura de una región, el valor de intensidad de un pixel, etc.

El método RED propone una forma de incorporar evidencia como parte de un proceso de aprendizaje en el que se va mejorando la precisión del clasificador. Con este fin, dado un conjunto de muestras, se evalúan los resultados de su clasificación y en caso de no ser "óptimos" se agregan los datos de las muestras (aquellos generados por las diferentes fuentes de información) como nueva evidencia. La forma en que se analizan los resultados de la clasificación para determinar su precisión, es a través de la matriz de error o confusión y el indicador Khat (ver **Capítulo 4, Sección 6** [Ros86]). Este indicador permite analizar el error ocurrido en la clasificación. Para poder determinar a qué llamamos “óptimo” se utiliza un parámetro de precisión  $\alpha$  que pone un umbral para el aprendizaje.

En este sentido, RED puede ser considerado como una combinación del clasificador de razonamiento evidencial con un reconocedor de aprendizaje supervisado.

En una primera etapa, trabaja igual que el razonamiento evidencial. Se almacena información sobre las diferentes clases involucradas a partir de un conjunto de muestras iniciales, de las cuales se conoce a priori a qué clase pertenecen. A partir de esta información se calcula el soporte para cada muestra de una clase y fuente en particular (se sugiere tener presente lo explicado en el **Capítulo 4**).

La segunda etapa consiste en permitir que el clasificador evidencial aprenda de los resultados de la clasificación de diferentes conjuntos de entrenamiento, y se necesita ayuda del experto, de modo de incorporar nuevos datos que mejoran el comportamiento del mismo.

Esto está basado, como se dijo, en la idea de un clasificador con aprendizaje supervisado. Cuando se habla de reconocimiento con aprendizaje supervisado, se quiere indicar que existe un proceso *maestro* que se encarga de enseñar al sistema, corrigiéndole cada vez que se equivoque, es decir, cuando clasifique incorrectamente un objeto [Mar94]. Es necesario entonces, que este proceso maestro tenga una forma de evaluar cuando se está incurriendo en un error o cuando se ha tomado una decisión correcta.

Se tiene por ejemplo, un vector  $x(\mathbf{k})$  ( $\mathbf{k}$  se refiere al instante genérico en que se extrae la muestra) del conjunto de muestras de entrenamiento, cuya pertenencia a una clase específica es conocida por el maestro.

La muestra  $x(\mathbf{k})$  es clasificada por el reconocedor automático en virtud del conjunto de funciones discriminantes (ffdd) que en ese instante ( $\mathbf{k}$ ) se esté manejando. Se modifican las funciones discriminantes (ffdd) en función de los resultados de la clasificación que se realizó.

La modificación se basa en si se produjo un acierto (coincide la decisión con la del maestro) o un error (difiere la decisión con la del maestro). Se pueden plantear diferentes algoritmos de modificación de las ffdd. Se puede utilizar para éstos un parámetro de error que dice si hay acierto o error, en nuestro caso se utiliza el parámetro de precisión  $\alpha$  para determinar si se debe modificar la evidencia.

De esta forma, RED utiliza un conjunto de datos a clasificar, como muestras de aprendizaje, de las cuales se conoce a priori a qué clase pertenecen. De acuerdo a esta información y a los resultados obtenidos en la clasificación, se permite al clasificador modificar el conocimiento que tenía hasta el momento realizando un ajuste mediante la incorporación de nueva evidencia.

Cuando se decide incorporar nuevas muestras a la base de conocimiento del clasificador se puede estar dentro de dos posibilidades:

Dado el valor de una muestra de una cierta fuente y clase (se sugiere tener en cuenta las definiciones presentadas en el **Capítulo 4 – Sección 5**):

**1.** El valor puede ya existir teniendo un soporte mayor que cero.

En este caso se procede de la siguiente manera:

- Se incrementa la frecuencia de ocurrencia (**fo**) de la muestra
- Se actualiza el valor de cantidad de muestras (TSn) para la clase en cuestión

**2.** El valor puede no existir, no tiene soporte:

Entonces:

- Se agrega el valor de la muestra para la clase y fuente involucradas
- Se actualiza el TSn de la clase

Tanto para el caso 1 como para el 2, se debe cumplir con un tercer paso luego de haber procesado todas las fuentes involucradas:

- Recalcular el soporte para todos los valores de muestra de cada fuente dentro de la clase en cuestión.

Otra modificación introducida al método de razonamiento evidencial es una regla de decisión diferente, que toma en cuenta cuál es la clase con mayor soporte y analiza su aceptación o no como clase definitiva de acuerdo a los resultados de dos etapas de decisión precedentes: **a)** rechazo por falta de evidencia y **b)** rechazo por ambigüedad.

### a) Rechazo por falta de evidencia

En esta etapa de decisión se evalúa la situación en la que la clase final a pesar de ser la de más soporte puede tener muy baja evidencia asignada, es decir la evidencia puede no ser “suficiente” para rotular al objeto como perteneciente a la clase. A esta decisión la llamaremos **rechazo por falta de evidencia**. Pero, inmediatamente surge la pregunta de cómo saber cuándo se tiene evidencia “suficiente” o a qué llamamos evidencia “suficiente”.

#### Regla de decisión con umbral para la evidencia

Se comenzó por introducir un valor de umbral para la evidencia, luego si la clase con mayor soporte estaba por debajo del umbral, se asignaba el objeto a la clase desconocida. Como suele ocurrir en estas situaciones la elección del umbral se basaba en relaciones empíricas encontradas en los datos. Los resultados obtenidos eran fuertemente dependientes de dicho umbral, invadiendo de muestras a la clase desconocida para casos de valores de umbral altos, o asignando, en algunas situaciones, incorrectamente el objeto a una clase para valores de umbral pequeños. Sin embargo, para algunos valores del umbral los resultados fueron razonables. Por ejemplo, entre las opciones elegidas se utilizó el máximo soporte encontrado entre todas las muestras (**Ec 5.1**), con lo cual se pedía tener un mínimo de evidencia que sea resultante de la combinación de varias fuentes para poder superar dicho umbral. De todas formas, se trató de buscar una alternativa en la que no se tuviera que utilizar un umbral para evitar la búsqueda del valor adecuado para este. En la siguiente subsección se detalla una posible alternativa.

**(Ec 5.1)** Sea  $S_j$  el soporte de la clase  $j$  que resultó ser el máximo encontrado entre el de todas las clases.

$S_j < T$  Clase final = desconocida

$S_j \geq T$  Clase final = Clase cuyo soporte es  $S_j$

$T = \text{Max}(S_{ij})$  donde  $S_{ij}$  es el soporte de una muestra  $M_{ij}$  con  $1 \leq i \leq N$  y  $1 \leq j \leq M$

$N$ : cantidad de fuentes y  $M$ : cantidad de clases

### **Regla de decisión considerando la cantidad de fuentes que aportan evidencia**

Otra posibilidad analizada fue la de considerar qué cantidad de fuentes aportan evidencia en favor de la clase con mayor soporte. Qué sucede si en el ejemplo planteado en el **Capítulo 4, Sección 5**, sólo uno de los médicos aporta evidencia para la clase seleccionada por ser la de mayor soporte. ¿ Puede decirse que hemos optado por la decisión correcta?. Habría que estudiar la reputación del médico, cuán confiable es, en qué se basa su creencia, si es suficiente, etc. Pero, si fueran tal vez dos los que aportan evidencia tendríamos más seguridad en arriesgar por una decisión. Generalmente, es lo que una persona realiza en caso de un diagnóstico médico cuando se trata de casos complejos o dudosos, realiza una consulta con otro profesional para tener mayor seguridad. Y si ambos opinan lo mismo mayormente optamos por confiar en la opinión de éstos.

La regla de decisión que se probó entonces, analiza **cuántas son las fuentes que participan aportando evidencia para la clase con mayor soporte**. Para esta tesis se experimentó poniendo una restricción para que al menos dos fuentes hayan aportado evidencia para la clase con máximo soporte, en caso contrario se considera que el objeto debe ser asignado a la clase “desconocida”. No se tiene la evidencia “suficiente”. Además, a esta restricción se le agrega el caso de tener como mayor soporte un valor de 0, lo cual implica que no hay evidencia para la clase en cuestión, ni para ninguna de las restantes. También en tal situación la clase final seleccionada será la desconocida (**Ec 5.2**). Cabe aclarar que el valor de restricción para la cantidad de fuentes puede variarse de acuerdo a la aplicación particular con que se esté trabajando, exigiendo una mayor o una menor cantidad de fuentes que aporten evidencia a la clase de mayor soporte.

El cálculo de las medidas de soporte para cada clase se realiza mediante la combinación de los valores de soporte (Si) dados por cada fuente (i) a cada una de las clases (ver **Capítulo 4**).

**(Ec 5.2)**  $C_j < R_f$  o  $S_j = 0$  Clase final = desconocida

$C_j$  = Cantidad de fuentes que aportan evidencia para la clase  $j$  (Clase con máximo soporte)

$R_f$  = Valor de Restricción de Fuentes

### **b) Análisis de Ambigüedad**

La segunda situación que se investiga es la que se produce si varias clases presentan un soporte similar al máximo. Esto implica que no hay una verdadera claridad respecto de la clase por la que se debe decidir. Para evaluar esto, se utiliza la medida de plausibilidad.

Se sabe que el intervalo de valores para la plausibilidad está entre 0 y 1 y dado que la plausibilidad indica cuanta evidencia hay sin asignar, y que podría llegar a ser asignada a la clase en cuestión, esto da una idea de cuanta evidencia se tiene distribuida entre las clases restantes. Si hay menos de un 50% de evidencia sin asignar, significa que hay un alto porcentaje que fue distribuido entre el resto de las clases. Esto implica que no hay una claridad en la decisión por la clase del objeto desconocido. Cuando se tiene el mayor valor de soporte igual a 1, entonces la plausibilidad deberá ser 0, y no hay evidencia asignada a las otras clases del marco de discernimiento. El caso opuesto sería tener como mayor soporte entre todas las clases un valor de 0, y entonces la plausibilidad sería de 1. De todas formas en tal situación, todas las clases tendrían igual chance y por esto se asigna el objeto a la clase desconocida. Cuando exigimos un 50% o más de plausibilidad, pedimos que al menos exista un 50% de evidencia que esté sin asignarse a las clases restantes, con lo cual la clase en cuestión (la de mayor soporte) tendría más chances de ser elegida como la definitiva.

Se estudiaron diferentes valores para el umbral. Queda de manifiesto a través de los estudios realizados sobre los valores de umbral para el porcentaje, que a mayor valor de umbral se impone una mayor restricción para arriesgar por una clase.

La otra idea estudiada dentro de la etapa de rechazo por ambigüedad, es la de evaluar la distancia existente entre los valores de evidencia de la clase con mayor soporte y el resto de las clases. Si alguna de las clases posee una distancia inferior o igual al parámetro de distancia se considera que no existe claridad para decidir entre las clases basándonos en el mayor soporte. El valor 0.01 parece ser razonable para la aplicación en cuestión y permite obtener los resultados esperados. Sin embargo, queda como trabajo futuro realizar un estudio más fundamentado para este parámetro.

Por otra parte, se plantea la pregunta de cuál es la decisión más acertada en caso de ocurrir la situación de tener que rechazar por ambigüedad (es decir es cierta alguna de las restricciones anteriores).

Una solución dada aquí fue asignar el objeto a la clase desconocida, para cuando se tiene un valor de porcentaje inferior al 50% o la distancia entre las clases está por debajo del umbral propuesto. En este caso, se ve que el algoritmo disminuye su precisión inclinándose mayormente por asignar los objetos desconocidos a la clase desconocida. Por lo que se prosiguió a buscar otra regla que permita decidirse por una de las clases propuestas.

La nueva opción adoptada para los casos en que se está por debajo del umbral es continuar analizando la elección y tratar de asignar el objeto a una clase entre las posibles (y no a la desconocida), teniendo en cuenta la cantidad de fuentes que aportan evidencia, la importancia de dichas fuentes para cada clase, y el valor de soporte obtenido (**Ec 5.3**). La combinación de estos tres factores permite tomar una decisión en situaciones de confusión. Para la cantidad de fuentes se considera un índice (**ICF**: Índice de Cantidad de Fuentes) que está dado por el valor de cantidad de fuentes sobre el total de las fuentes (esto da un número entre 0 y 1). Además se tiene un “peso” que se le asigna a cada relación fuente – clase (valor entre 0 y 1) que indica la importancia de la información de la fuente para la clase dada. Esto implica un conocimiento previo de la influencia de las fuentes para las diferentes clases. Para esta aplicación, por ejemplo se sabe que cuando se trata de distinguir entre lo que es

vegetación sana de lo que no lo es, las bandas del cercano infrarrojo y el rojo resultan de mayor interés al momento de decisión (ver **Capítulo 2, Sección 7**). Por último, el mayor valor obtenido de la combinación de estos tres aspectos permite determinar la decisión a tomar. La combinación está dada por la suma del índice de cantidad de fuentes y el soporte, multiplicada por el peso otorgado como lo indica la ecuación **Ec 5.3**.

**Ec 5.3** Se selecciona la clase  $j$  correspondiente a  $Max(peso\_total_j * (ICF_j + S_j))$  con  $1 \leq j \leq N$  donde  $N$  es el total de clases.

$ICF_j$ : Índice de Cantidad de Fuentes para la clase  $j$

$S_j$ : Soporte para la clase  $j$

$peso\_total_j$ :  $\sum_{i=1..N} peso_{ij} / C_j$ , donde  $i$  representa las fuentes que aportan evidencia para la clase  $j$

$1 \leq j \leq M$  y  $C$  representa la cantidad de fuentes aportando evidencia para la clase  $j$ .

### Regla utilizada por RED

Como consecuencia de los estudios realizados y explicados anteriormente, se determinó para RED la siguiente regla:

- a) **Análisis por falta de evidencia:** se evalúa la cantidad de fuentes que aportan evidencia a favor de la clase con mayor soporte (**Ec 5.2**). Para este estudio se puso como restricción tener al menos dos fuente, por lo que la regla asigna el objeto a la clase desconocida en caso de no cumplirse la restricción. De igual manera se procede si el mayor soporte encontrado es 0. Para este objetivo el algoritmo debe mantener la cuenta de cuántas fuentes aportan evidencia para cada clase (soporte mayor que cero).
- b) **Análisis de rechazo por ambigüedad:** si todavía no se optó por la clase desconocida se evalúa el rechazo por ambigüedad utilizando como umbral el 50% del intervalo posible de la plausibilidad (se podría decir que esto da un intervalo de confianza para la decisión). Cuánto más porcentaje se pida mayor será la evidencia que puede ser asignada y que no lo fue por la incertidumbre

asociada a los datos. En caso de no superarse dicho umbral o cuando existe alguna distancia entre la clase de mayor soporte y el resto de las clases menor que el parámetro de distancia, se estudia entre las clases posibles la que da mayor combinación entre soporte, peso de la fuente para la clase e índice de cantidad de fuentes, y se asigna el objeto a dicha clase (**Ec 5.3**).

Finalmente, cuando se clasifica una región homogénea, por ejemplo, tomar una porción de un campo cultivado cualquiera de la imagen, se introduce una última decisión o una etapa de post-clasificación, que se basa en la cantidad de píxeles asignados a cada una de las clases, si se encuentra que más del 80% de los píxeles fueron asignados a la misma clase, la región es considerada o rotulada como perteneciente a dicha categoría. En caso contrario, se le otorga el rótulo de “Desconocida”. Esta última fase del clasificador RED sólo se utiliza para el caso que se quiera dar al usuario final un valor único de clase para la región seleccionada, y esto agrega información. Aquellas regiones donde se desconoce la pertenencia a una clase, terminarán por asignarse a la clase desconocida.

### **5.3. Objetivos**

El objetivo de la modificación introducida al razonamiento evidencial es, por un lado, agregar un proceso de aprendizaje para el clasificador, de manera tal que el mismo incorpore nuevas piezas de evidencia para las distintas clases, hasta lograr un comportamiento "óptimo" del mismo para el conjunto de entrenamiento con el que se trabaja.

La definición de "óptimo" depende de la aplicación en cuestión y del grado de error que se pretende obtener. En el caso particular sobre el que se trabaja, interesa no superar el 10% de error. Esto es evaluado mediante el indicador Khat.

Este proceso de aprendizaje permite que se incorpore evidencia al sistema cuando se dispone de ésta, logrando de esta forma una mejora en el comportamiento del clasificador.

El razonamiento evidencial presentado en [Ped95 a] y [Ped95 b] no describe una forma de incorporar nueva evidencia, ni permite evaluar si es necesario hacerlo. Trabaja con un conjunto inicial de muestras de entrenamiento, y un proceso de transformación de bin (ver **capítulo 4, sección 5**) que permite extender dicho conjunto de muestras para lograr una mejor distribución de los datos.

El proceso de aprendizaje tiene por objetivo incorporar evidencia a partir de un conjunto de muestras de entrenamiento, evaluando si el clasificador se comporta con un error por debajo del parámetro de precisión o no. Sólo en el caso que el error sea mayor que este valor se agregan las muestras para modificar la evidencia que se tenía hasta el momento y lograr una mejora en la precisión del mismo. Esto permite extender el conocimiento actual del clasificador, pero dependiendo de un análisis previo que evalúa si la evidencia a incorporar es necesaria para obtener la respuesta del clasificador deseada. Tener errores superiores al 10% implica la necesidad de obtener mayor evidencia para mejorar la respuesta, por lo cual se ejecuta el aprendizaje. El valor del 10% para cota del error puede ser modificado de acuerdo a la precisión deseada para la aplicación con la que se trabaje.

Puede incorporarse de ser necesario nueva evidencia en cualquier momento, y modificar así la base de conocimiento actual, es por ello que surge el nombre de *Dinámico* para el método aquí presentado.

Por otra parte, el otro objetivo de este método es el de realizar un análisis adecuado de las medidas de soporte y plausibilidad obtenidas. Se tienen en cuenta también la cantidad de fuentes intervinientes en la decisión y el peso asignado a las mismas respecto de cada clase. De esta manera, se pretende mejorar la decisión de asignar un objeto a una clase en situaciones donde la evidencia es resultante del aporte de sólo una de las fuentes o es inferior al parámetro de cantidad de fuentes ( $R_f$ ), y cuando se produce confusión debido a la cercanía de los soportes entre las distintas clases. Es decir, el hecho de optar por la clase con mayor soporte resulta un riesgo cuando no se posee una distancia suficiente entre el soporte de las distintas clases. Por tanto, con todo esto se trata de lograr una decisión más cercana a la realidad.

## **5.4. Comparación teórica con los métodos convencionales**

Los algoritmos de clasificación supervisada presentados en el capítulo anterior se distinguían entre aquellos que no realizaban suposiciones estadísticas (no paramétricos) y aquellos que realizaban tales consideraciones (paramétricos).

Cuando se analizaron los clasificadores supervisados no paramétricos, destacamos que algunos de ellos presentan dificultades al momento de trabajar con clases solapadas, debido a su alta dispersión. Tal es el caso, del clasificador del paralelepípedo (donde no se logra un ajuste con la distribución de los datos cuando los mismos presentan alta covarianza), o los clasificadores basados en regionalización (en los cuales se encuentran problemas con la superposición de clases) [Jen96][Ped93]. En este sentido, el clasificador de razonamiento evidencial dinámico, puede obtener valores de soporte cercanos para clases solapadas y realiza un análisis más específico para tomar la decisión de asignar una clase al objeto desconocido (análisis de ambigüedad, ya explicado en la **sección 2** de este capítulo), por lo que en la mayoría de los casos toma la decisión acertada. No es necesario determinar un rango para cada una de las bandas como realiza el clasificador del paralelepípedo, en donde las regiones determinadas por esos rangos podían no ajustarse a los datos.

El enfoque de redes neuronales presenta ciertas ventajas en cuanto a los inconvenientes de los métodos basados en clasificación supervisada no paramétrica. Se ha mostrado que tanto las redes neuronales como el enfoque de razonamiento evidencial presentan un considerable potencial para el análisis de imágenes a partir de múltiples fuentes y la clasificación de cobertura de suelo [Dug96]. Se pueden destacar algunos aspectos ventajosos que proveen las redes, por un lado, no requieren de la suposición de una cierta distribución para los datos (como en el caso de los clasificadores estadísticos), y por otro, permite integrar diferentes niveles de datos (direccional, nominal, etc.). Sin embargo, el diseño de las redes neuronales se basa en una serie de decisiones que influyen en su posterior rendimiento, por ejemplo, decidir el tipo de conexión entre las neuronas de diferentes capas, así como entre las

neuronas de una misma capa, la forma en que una neurona recibe una entrada y produce una salida, y el peso de cada conexión dentro de la red. Básicamente, se tiene que estudiar la arquitectura de red óptima para lograr un correcto funcionamiento del sistema de clasificación. El método RED requiere de la elección de algunos valores de parámetros, entre ellos, el porcentaje de plausibilidad que se usará como umbral, y los pesos asignados a cada par fuente-clase. El más difícil de establecer puede ser el primero, sin embargo se sabe que valores altos (más del 50%) imponen una restricción mayor para arriesgar por una clase, ya que se pide un alto porcentaje de evidencia no asignada a ninguna clase, y valores bajos permiten arriesgar muchas veces erróneamente por una clase. El valor recomendado en este caso es el 50%. Respecto del peso de los pares fuente-clase, puede resultar sencillo realizar tal asignación si se conoce la aplicación y con qué fuentes se trabaja. En esta tesis, por ejemplo, se trabaja con las diferencias normalizadas de las bandas contiguas y cuatro rasgos de textura de primer orden. Por lo tanto, se sabe que la diferencia normalizada de las bandas correspondientes al rojo y al infrarrojo es significativa a la hora de clasificar vegetación, por lo cual esta fuente de información recibirá mayor peso. En el peor de los casos, se trabaja con un peso igual para todas las posibles combinaciones de fuente-clase, y se estaría considerando sólo el valor de soporte y el índice de cantidad de fuentes aportando evidencia.

Los clasificadores paramétricos, como el de Bayes o el de Máxima Verosimilitud, permiten obtener muy buenos resultados si se dispone de cierta información a priori y si los datos respetan una determinada distribución estadística [Sch92][Tou74]. Para ambos, se requiere asumir una distribución normal de los datos, y además para el clasificador de Bayes es necesario conocer la probabilidad de cada clase. Es decir, a priori se debe contar con cierta información para que el clasificador pueda funcionar de una manera óptima.

Otro problema encontrado es el alto costo computacional de los clasificadores estadísticos, que se incrementa particularmente cuando se tiene un gran número de canales espectrales involucrados o muchas clases entre las que se debe distinguir. Por otra parte, cuando se trabaja con información heurística, una probabilidad de 0.40

para una proposición no necesariamente indica que a su negación se le deba asignar una probabilidad de 0.60 (como en la teoría de Bayes). El razonamiento evidencial y RED realizan una distinción entre "falta de creencia" y "no creencia", por lo que en el caso anterior no considera que si se tiene un soporte de 0.40 para una de las clases, el resto de las clases recibe el 0.60 que queda [Ped93]. El concepto de incertidumbre es importante en la clasificación, especialmente cuando la evidencia es distribuida a partir de una variedad de fuentes diferentes. De esta manera, se provee una representación más adecuada de la situación cuando alguna o toda la información disponible es insuficiente para decidir entre cualquiera de las proposiciones.

Resumiendo, tanto el método de razonamiento evidencial como el razonamiento evidencial dinámico, presentan una serie de ventajas respecto de los clasificadores clásicos mencionados:

- No es necesario presuponer una distribución para los datos.
- La teoría provee una base general y heurística para integrar cuerpos distintos de información a partir de fuentes independientes. De esta forma, pueden incorporarse un alto número de datos y de diferente naturaleza. Incluso es posible incorporar los resultados de una clasificación previa, lo cual puede resultar muy útil para el análisis de la evolución de un área geográfica particular.
- Se permite manejar la evidencia no asignada o incertidumbre. La mayoría de los algoritmos de clasificación no tienen un mecanismo explícito para manejar inconsistencias, errores, o incertidumbre. Esto es particularmente importante con conjuntos de datos dispares, de múltiples fuentes, los cuales pueden poseer niveles diferentes de calidad de información, o instancias de datos perdidos o indefinidos.

Como se puede observar, el método de razonamiento evidencial dinámico propuesto, mantiene las ventajas presentadas en el método de razonamiento evidencial, incorporando una serie de variaciones que modifican en forma positiva el comportamiento del clasificador. La etapa de aprendizaje descrita en la sección

anterior permite la incorporación de nueva evidencia y esto tiende a un notable mejoramiento en los resultados obtenidos (ver **Capítulo 6**). Claro está, que es necesario contar con información confiable sobre la pertenencia de las muestras que se agregan por medio del proceso de aprendizaje a una cierta categoría o clase. Si se dispone de nuevos conjuntos de muestras los mismos pueden mejorar considerablemente los resultados del clasificador.

En cuanto a la regla de decisión propuesta por RED, la misma permite establecer un umbral de seguridad para no arriesgar por una clase a menos que se disponga de una cierta evidencia. Además, la regla trabaja analizando cuál es la clase con mayor soporte, pero no sólo utiliza esta información para la decisión, sino que también estudia la medida de plausibilidad y la distancia entre los soportes de las clases con el fin de saber si otras clases han recibido una evidencia similar. En tal caso, se considera que la clase a asignar es aquella que posee el mayor valor resultante de la combinación del índice de cantidad de fuentes (**ICF**), los pesos de las mismas respecto de la clase, y el soporte. En el **Capítulo 6** esto puede ser visto para la aplicación con la que se trabaja.

### **5.5. Conclusiones del capítulo**

En este capítulo se ha presentado el método de razonamiento evidencial dinámico, sus objetivos, y su descripción. Este método presenta una serie de aspectos positivos: se puede tener como entrada al clasificador un gran número de variables, no es necesario presuponer una determinada distribución estadística, los datos pueden ser de diferente naturaleza y se tiene en cuenta la incertidumbre asociada a los mismos. Todos estos aspectos también son característicos del método de razonamiento evidencial. Sin embargo, la posibilidad de incorporar nueva información para mejorar el rendimiento del clasificador y la decisión final que toma en cuenta no sólo los valores de soporte y plausibilidad, sino también la cantidad de fuentes que aportan evidencia y la importancia de cada fuente para las distintas clases, son características propias del método de razonamiento evidencial dinámico. ◆

## CAPITULO 6

### Aplicación del razonamiento evidencial dinámico

#### 6.1. Introducción

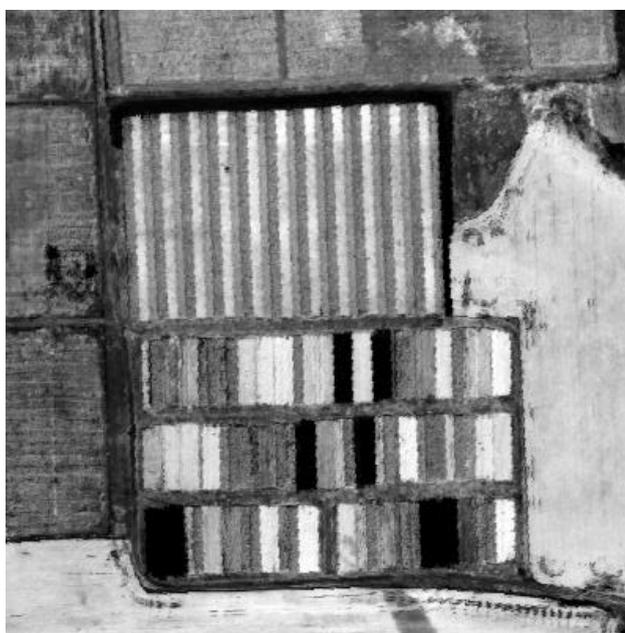
El método RED ha sido aplicado a la clasificación de cultivos en imágenes hiperespectrales de la región de Nebraska (USA). Esta región es rica en la producción de cereales, y sus cultivos más característicos son el maíz, la soja, el sorgo, y la alfalfa.

La empresa que proveyó las imágenes tanto multiespectrales como hiperespectrales, realiza estudios analizando el "stress" de los cultivos y se cuenta con los datos de referencia que los mismos utilizan. En la **Figura 6.1**, puede observarse parte de una de las imágenes utilizadas para la clasificación.

Para aplicar el clasificador se trabajó de la siguiente manera:

Se tomaron como entrada al clasificador las 10 bandas ( $b_i$ ) espectrales que componen las imágenes hiperespectrales usadas. A las mismas se las utilizó para calcular la diferencia normalizada entre bandas consecutivas, es decir  $(b_i - b_{i+1}) / (b_i + b_{i+1})$  para  $i=1, \dots, 9$ . El hecho de utilizar las diferencias normalizadas surge de la idea de acotar los valores dentro de un rango de manera que no exista tanta dispersión y el método no se vea influenciado por valores individuales, esto permite evitar en cierta manera el proceso de transformación de bin (utilizado para proveer una distribución del rango de valores - Ver **Capítulo 4**). Además se utilizan 4 rasgos de textura calculados sobre una de las bandas (760 nanómetros): la media, el "skewness" (medida de simetría), el rango y la desviación estándar, que son estadísticas de primer orden (ver **Capítulo 3 Sección 4**), y permiten incorporar información espacial al sistema y de este modo no tener sólo información espectral.

Esta decisión también está sustentada en el conocimiento que se tiene acerca de que los diferentes materiales de la superficie terrestre poseen una respuesta espectral diferente y las diferencias normalizadas permiten captar la información de los picos y valles que tienen dichas firmas espectrales (en particular las de la vegetación sana). Cuando la curva da un salto de un valor pequeño a uno mayor se obtendrán valores negativos y el valor absoluto de esta diferencia permitirá evaluar la intensidad de dicho salto (**Figura 6.2**). Para los distintos cultivos, si bien todos tienen una curva espectral similar, se encuentran diferencias que pueden detectarse cuando se tiene el detalle de una imagen hiperespectral. Se sabe que los tipos de cultivo específicos pueden ser identificados en base a los patrones de respuesta espectral y la textura de la imagen. El agregar los rasgos espaciales permite tener nuevas variables de discriminación para la clasificación. Las distintas formas de plantación, la altura, la forma de las hojas de los diferentes cultivos influyen sobre las características de textura de una imagen digital [**Jen96**][**Ped91**].



**Figura 6.1 – Subimagen de la imagen 1m0809cornng.pix utilizada para la clasificación**

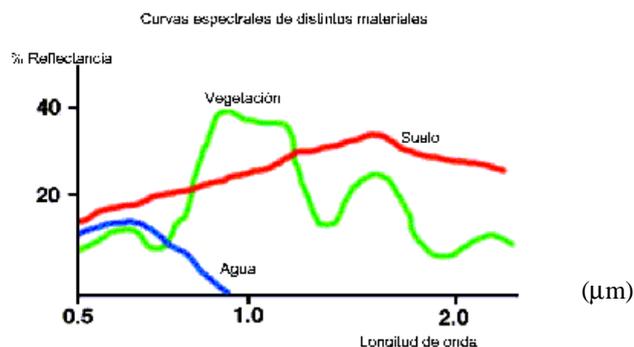


Figura 6.2 – Comparación de curvas espectrales de distintos materiales. Se muestra la reflectancia que caracteriza a estos materiales en las distintas bandas espectrales. Se puede observar, por ejemplo, que mientras que la vegetación tiene su máxima reflectancia en el cercano infrarrojo, el agua la tiene en el espectro visible. El eje x representa la longitud de onda medida en micrómetros

Es importante destacar en este punto, que la idea de esta tesis **no se centró en la búsqueda de las fuentes de información que resultaran óptimas para el método**. Es probable que exista un conjunto de fuentes que provean una mayor separabilidad para las clases en cuestión, y tal vez dicho conjunto sea aún menor en cardinalidad que el actual. En este trabajo **se puso como objetivo la prueba y análisis del método propuesto y su funcionamiento**, aún en casos donde exista una superposición entre las clases en un espacio N-dimensional de rasgos (de hecho, existe cierto solapamiento entre la clase sorgo y maíz, y aún así se obtienen los resultados esperados). Sin embargo, es cierto que previo a la elección de este conjunto de fuentes se estudiaron otros posibles con los cuales no se obtuvieron tan buenos resultados como con el conjunto seleccionado. Se probó trabajar con cada una de las bandas como una fuente de información, y con diferentes rasgos de textura.

La base de conocimiento inicial para el clasificador se formó a partir de un conjunto de muestras cuya pertenencia a una clase es conocida. Como muestras, por un lado se utilizaron píxeles de los que se extrajo su valor de intensidad en cada una de las bandas, y luego a partir de los mismos se calcularon las diferencias normalizadas. Por otro lado, se calcularon los valores de textura para cada una de dichas muestras, utilizando una ventana de 3x3 sobre una de las bandas espectrales (760 nm).

Se quiere resaltar la ventaja de poder incorporar información al sistema de *diferente naturaleza* como son los rasgos espaciales por un lado, y los espectrales por otro. Cada uno de estos rasgos se considera una fuente de información diferente para el razonamiento evidencial y el razonamiento evidencial dinámico.

En la **Figura 6.3**, se pueden observar las curvas espectrales de los conjuntos de muestras utilizados para el entrenamiento inicial.

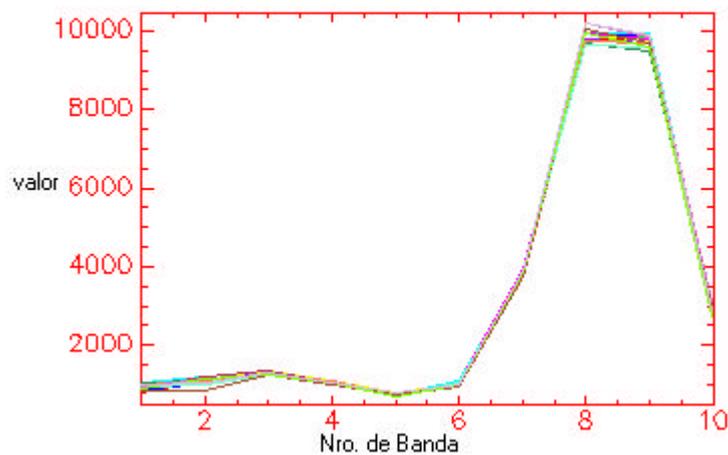


Figura 6.3 a – Muestras de la clase soja

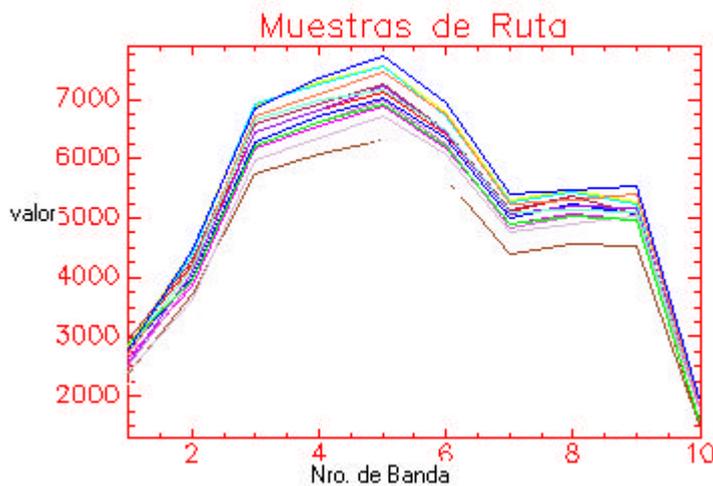


Figura 6.3 b – Muestras de la clase ruta

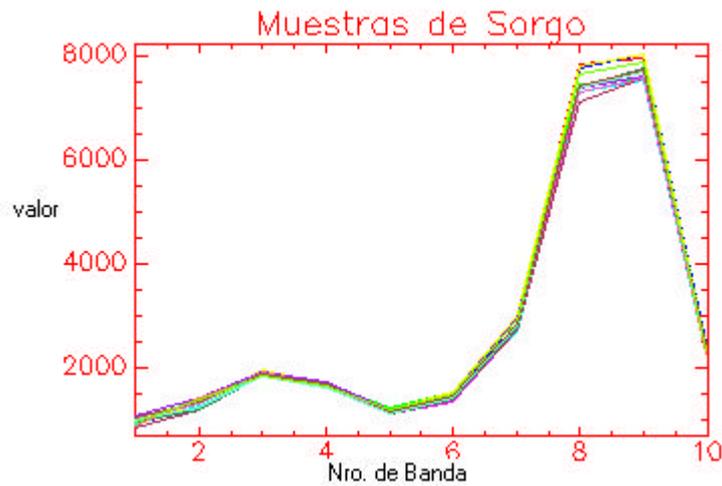


Figura 6.3 c – Muestras de la clase sorgo



Figura 6.3 d – Muestras de la clase maíz

Después de la etapa de entrenamiento inicial se prosiguió con la etapa de aprendizaje del clasificador con un conjunto de muestras de entrenamiento para las diferentes clases involucradas.

El primer conjunto de muestras de test, arrojó resultados que indicaban la necesidad de tener mayor cantidad de información para poder clasificar correctamente.

Por lo tanto, es necesario realizar el proceso de aprendizaje. Consecuentemente, se incorporaron las muestras a la base de conocimiento, y se calcularon los soportes para todo el conjunto nuevamente. Así, se procedió con cada uno de los conjuntos de test en este proceso de aprendizaje, y automáticamente, de acuerdo a los resultados obtenidos, el clasificador determinó si era necesario incorporar la información o no. La decisión del clasificador de aprender del conjunto de test o no hacerlo, se basa en el valor del indicador Khat. Sólo se aprende si el valor de Khat es inferior a un  $\alpha$  considerado como el **parámetro de precisión**. Para este caso, se tomó un  $\alpha$  igual a 0.90 equivalente a tener el 90% de precisión más que si se hiciera una clasificación al azar. De esta manera, el sistema sólo incorpora las muestras cuando se tiene una precisión por debajo de la indicada por  $\alpha$ . Si Khat arroja valores inferiores a 0.90, no se ha alcanzado la precisión pretendida para el clasificador respecto de las muestras de entrenamiento. En la siguiente sección se analiza más detalladamente la influencia del parámetro de precisión.

El proceso de aprendizaje se repite presentando los mismos conjuntos de muestras hasta que no se produzcan modificaciones en la base de conocimiento. En la primer y segunda presentación del conjunto de muestras se utilizó como parámetro de precisión  $\alpha=0.90$ . No fue necesaria una tercera presentación ya que todos los conjuntos fueron clasificados con un valor de Khat superior a  $\alpha$ .

### **Análisis del parámetro de precisión**

El parámetro de precisión permite controlar el proceso de aprendizaje de forma tal de regular la incorporación o no de las muestras de entrenamiento al sistema. De acuerdo a los valores de Khat que arroja el clasificador, se puede ver cómo está funcionando el mismo para las muestras que se le presentan y si corresponde o no continuar aprendiendo. Se sabe que cuando Khat tiene un valor de 1 significa que el clasificador evita en un 100% los errores que se tendrían si se utilizara un clasificador completamente aleatorio. Cuando los valores de  $\alpha$  se aproximan a 1, existe una mayor incorporación o aprendizaje en el sistema, es decir se agregan más cantidad de muestras a la base de conocimiento, esto conlleva por un lado a un

aumento en la precisión del clasificador y por otro, a un mayor tiempo de respuesta en posteriores clasificaciones. Por tal razón, se busca un equilibrio entre la precisión y el tiempo de respuesta esperados para la aplicación. Para esta clasificación se probaron diferentes valores para el parámetro de precisión, encontrando la mejor respuesta con el valor ya sugerido.

## 6.2. Resultados obtenidos.

### 6.2.1. Análisis del proceso de aprendizaje

En esta sección la intención es mostrar cómo funciona el proceso de aprendizaje para la aplicación en cuestión. Se presenta la forma en que el clasificador va logrando el aprendizaje a través de la incorporación de nueva evidencia.

Se muestran a continuación algunos resultados obtenidos en la aplicación del método RED en las imágenes descritas. Los resultados se evalúan utilizando la matriz de confusión, la precisión general y el indicador Khat.

Se seleccionaron conjuntos de entrenamiento diferentes de los utilizados para el entrenamiento inicial. Se realizó la etapa de aprendizaje del clasificador presentando las muestras de entrenamiento para cada clase en la forma descrita en el **Capítulo 3**. En una segunda pasada de los conjuntos de entrenamientos el valor de Khat para todos los casos resultó ser superior a  $\alpha$ , indicando una alta precisión para dichos conjuntos.

Tabla 6.1 - Conjunto 1 - Matriz de confusión

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	74	6	5	0	0	85
Maíz	1	19	22	0	0	42
Sorgo	0	7	56	0	0	63
Ruta	9	3	0	37	0	49
Desc.	0	0	0	0	0	0
Total	84	35	83	37	0	239

**Precisión general:** 77%

**Precisión por clase:** soja (87%), maíz (45%), sorgo (88%), ruta (71%)

**Khat:** 0.69

El valor de Khat no logra superar el valor  $\alpha$  (0.90) establecido para la aplicación, con lo cual se decide agregar la evidencia dada por el conjunto de muestras actual. Se incorpora el conjunto de muestras a la base de conocimiento del clasificador y se calculan nuevamente los soportes para cada fuente y clase. Luego, se evalúa el clasificador con el conjunto de muestras 2, utilizando la base de conocimiento modificada por la incorporación de las nuevas muestras.

**Tabla 6.2 - Conjunto 2 - Matriz de confusión**

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	84	0	0	0	0	84
Maíz	0	22	8	0	0	30
Sorgo	0	2	54	0	0	56
Ruta	0	0	0	17	0	17
Desc.	0	0	0	0	0	0
Total	84	24	62	17	0	187

**Precisión general:** 95 %

**Precisión por clase:** soja (100%), maíz (73%), sorgo (96%), ruta (100%)

**Khat:** 0.92

Para este caso, no se incorporan los datos del conjunto de muestras 2, ya que el clasificador arrojó un valor de Khat igual a 0.92 (92%), cercano al valor máximo que puede tomar el indicador. Esto implica que el clasificador cuenta con la evidencia necesaria para arrojar el resultado adecuado para la clasificación del conjunto de muestras actuales, y por tanto no modifica su conocimiento.

**Tabla 6.3 - Conjunto 3 - Matriz de confusión**

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	72	2	3	0	0	77
Maíz	0	16	8	0	0	24
Sorgo	0	2	88	0	0	90
Ruta	0	0	0	30	0	30
Desc.	0	0	0	0	0	0
Total	72	20	94	30	0	221

**Precisión general:** 93%

**Precisión por clase:** soja (93%), maíz (67%), sorgo (95%), ruta (100%)

**Khat:** 0.89

Se vuelven a incorporar los datos, en este caso del conjunto de test3, ya que el clasificador arrojó un valor de Khat inferior a 0.90.

Tabla 6.4 - Conjunto 4 - Matriz de confusión

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	89	1	0	0	0	90
Maíz	0	10	0	0	0	10
Sorgo	0	4	92	0	0	96
Ruta	0	2	2	50	0	54
Desc.	0	0	0	0	0	0
Total	89	17	94	50	0	250

**Precisión general:** 96 %

**Precisión por clase:** soja (99%), maíz (100%), sorgo (97%), ruta (92%)

**Khat:** 0.94

El clasificador no incorpora las muestras, dado el valor de Khat indica un error inferior al 10%.

Tabla 6.5 - Conjunto 5 - Matriz de confusión

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	64	0	0	0	0	64
Maíz	2	24	10	0	0	36
Sorgo	0	3	97	0	0	100
Ruta	0	0	0	30	0	30
Desc.	0	0	0	0	0	0
Total	66	27	107	30	0	230

**Precisión general:** 93%

**Precisión por clase:** soja (100%), maíz (67%), sorgo (97%), ruta (100%)

**Khat:** 0.90

El clasificador no incorpora esta información, debido a los buenos resultados obtenidos.

Tabla 6.6 - Conjunto 6 - Matriz de confusión

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	88	1	1	0	0	90
Maíz	2	15	2	1	0	20
Sorgo	0	5	125	0	0	130
Ruta	0	0	0	30	0	30
Desc.	0	0	0	0	0	0
Total	90	21	128	31	0	270

**Precisión general:** 95%

**Precisión por clase:** soja (98%), maíz (75%), sorgo (95%), ruta (100%)

**Khat:** 0.93

**Tabla 6.7 - Conjunto 7 - Matriz de confusión**

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	64	0	0	0	0	64
Maíz	1	38	17	0	0	56
Sorgo	1	4	85	0	0	90
Ruta	0	0	5	107	0	112
Desc.	0	0	0	0	0	0
Total	66	42	107	107	0	322

**Precisión general:** 91%

**Precisión por clase:** soja (100%), maíz (69%), sorgo (94%), ruta (95%)

**Khat:** 0.88

Las muestras del conjunto 6 no se incorporan y se incorporan las muestras del conjunto 7.

**El porcentaje promedio para la primera pasada resultó ser de 87 %.**

Luego de realizar la primera pasada de los conjuntos de entrenamiento, se volvieron a presentar los mismos al clasificador y no fue necesario realizar una tercer pasada ya que no hubo modificación de la base de datos de conocimiento en la pasada anterior (es decir que se obtuvo un valor superior o igual a **a** para todos los conjuntos presentados).

Se muestran a continuación los resultados obtenidos para los conjuntos de test en la segunda pasada:

**Tabla 6.8 - Conjunto 1 - Matriz de confusión**

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	85	0	0	0	0	85
Maíz	0	42	0	0	0	42
Sorgo	0	0	63	0	0	63
Ruta	0	0	0	49	0	49
Desc.	0	0	0	0	0	0
Total	85	42	63	49	0	249

**Precisión general:** 100%

**Precisión por clase:** soja (100%), maíz (100%), sorgo (100%), ruta (100%)

**Khat:** 1.00

Tabla 6.9 - Conjunto 2 - Matriz de confusión

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	84	0	0	0	0	84
Maíz	0	29	1	0	0	30
Sorgo	0	0	56	0	0	56
Ruta	0	0	0	17	0	17
Desc.	0	0	0	0	0	0
Total	84	29	57	17	0	187

Precisión general: 99%

Precisión por clase: soja (100%), maíz (97%), sorgo (100%), ruta (100%)

Khat: 0.99

Tabla 6.10 - Conjunto 3 - Matriz de confusión

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	77	0	0	0	0	77
Maíz	0	23	1	0	0	24
Sorgo	0	0	90	0	0	90
Ruta	0	0	0	30	0	30
Desc.	0	0	0	0	0	0
Total	77	24	90	30	0	221

Precisión general: 100%

Precisión por clase: soja (100%), maíz (96%), sorgo (100%), ruta (100%)

Khat: 0.99

Tabla 6.11 - Conjunto 4 - Matriz de confusión

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	89	1	0	0	0	90
Maíz	0	8	2	0	0	10
Sorgo	0	7	89	0	0	96
Ruta	1	1	1	51	0	54
Desc.	0	0	0	0	0	0
Total	90	17	92	51	0	250

Precisión general: 95%

Precisión por clase: soja (99%), maíz (80%), sorgo (93%), ruta (95%)

Khat: 0.92

Tabla 6.12 - Conjunto 5 - Matriz de confusión

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	64	0	0	0	0	64
Maíz	0	32	4	0	0	36
Sorgo	0	5	95	0	0	100
Ruta	0	0	0	30	0	30
Desc.	0	0	0	0	0	0
Total	64	37	99	30	0	230

Precisión general: 96%

Precisión por clase: soja (100%), maíz (95%), sorgo (96%), ruta (100%)

Khat: 0.94

Tabla 6.13 - Conjunto 6 - Matriz de confusión

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	88	1	1	0	0	90
Maíz	2	16	2	0	0	20
Sorgo	0	5	125	0	0	130
Ruta	0	0	0	30	0	30
Desc.	0	0	0	0	0	0
Total	91	21	128	30	0	270

**Precisión general:** 96%

**Precisión por clase:** soja (98%), maíz (80%), sorgo (96%), ruta (100%)

**Khat:** 0.94

Tabla 6.14 - Conjunto 7 - Matriz de confusión

	Soja	Maíz	Sorgo	Ruta	Desc.	Total
Soja	64	0	0	0	0	64
Maíz	0	56	0	0	0	56
Sorgo	0	0	90	0	0	90
Ruta	0	0	0	112	0	112
Desc.	0	0	0	0	0	0
Total	64	56	90	112	0	322

**Precisión general:** 100%

**Precisión por clase:** soja (100%), maíz (100%), sorgo (100%), ruta (100%)

**Khat:** 1.00

Como se explicó anteriormente, dado que no hubo modificación de la base de conocimiento, no se continúa con el proceso de aprendizaje.

A continuación se resaltan algunos puntos de este proceso:

- ✓ El porcentaje promedio de valor de Khat obtenido en la primera pasada es de 87.85 %, mientras que el obtenido en la segunda pasada es de 96.85 %. Esto indica una mejora respecto de la respuesta del clasificador luego del proceso de aprendizaje.
- ✓ Respecto de los valores de clasificación por cada clase, analizamos como se modifican a lo largo del proceso de entrenamiento:

Tabla 6.15 – Comparación entre los valores promedios obtenidos en la 1º y 2º pasada

Clase	1ra. Pasada Promedio	2da. Pasada Promedio
Soja	96.71 %	99.57 %
Maíz	70.85 %	92.57 %
Sorgo	94.57 %	97.85 %
Ruta	94 %	99.28 %

Esta tabla permite afirmar que los promedios de respuesta para cada clase son superiores en la segunda pasada del proceso de aprendizaje, lo cual demuestra una mejora introducida por este proceso en el comportamiento del clasificador para el conjunto de muestras de entrenamiento.

- ✓ Estos resultados dan la posibilidad de afirmar el buen comportamiento del clasificador RED para las muestras de entrenamiento, pero todavía falta probar al mismo para conjunto de test diferentes de las muestras de entrenamiento, a fin de tener una evaluación real del clasificador.

### 6.2.2 Evaluación del Clasificador y de su regla de decisión

La sección anterior estuvo dedicada al estudio del proceso de aprendizaje que utiliza RED. En esta sección se analiza, por un lado cómo se comporta el clasificador utilizando conjuntos de test diferentes a los utilizados como entrenamiento, y por otro lado cómo influye la regla de decisión incorporada en la clasificación.

Para poder entender en qué medida influye la regla de decisión se compara con otras alternativas como la de seleccionar el máximo soporte. De esta forma se evalúan y contraponen los resultados de cada una. Además se investiga cómo funcionan las dos etapas de rechazo propuestas por RED, especialmente se tiene en cuenta cómo afectan al funcionamiento del clasificador.

Con el objetivo de medir la precisión del clasificador se seleccionaron regiones de test, para las diferentes clases con las que se trabaja, de 4 imágenes hiperespectrales diferentes (para más referencias sobre el material de trabajo ver **Capítulo 3**). Es importante destacar que dichas regiones no coinciden con las utilizadas para el entrenamiento. Fueron elegidas aleatoriamente y dependiendo de los datos de referencia con los que se cuenta (por ejemplo, no es posible seleccionar igual cantidad de muestras para todas las clases dado que no todas las imágenes presentan los tres tipos de cultivos).

### 6.2.2.1 Análisis de la precisión de RED para diferentes conjuntos de test

A continuación se presentan los resultados obtenidos de la aplicación de RED a dichos conjuntos de test:

Tabla 6.16 - Clase Maíz

Clase Maíz	Porcentaje asignado a Clase:				
	Soja	Maíz	Sorgo	Ruta	Desc.
Región 1. Total: 49 píxeles	0 %	86 %	14 %	0 %	0 %
Región 2. Total: 28 píxeles	0 %	89 %	10 %	0 %	0 %
Región 3. Total: 64 píxeles	1.5 %	81 %	17 %	0 %	0 %
Región 4. Total: 30 píxeles	0 %	90 %	10 %	0 %	0 %
Región 5. Total: 40 píxeles	0 %	90 %	10 %	0 %	0 %
Región 6. Total: 100 píxeles	2 %	88 %	10 %	0 %	0 %
Región 7. Total: 84 píxeles	2 %	89 %	8 %	0 %	0 %
Región 8. Total: 10 píxeles	0 %	100 %	0 %	0 %	0 %
Región 9. Total: 12 píxeles	0 %	100 %	0 %	0 %	0 %
Región 10. Total: 25 píxeles	4 %	80 %	16 %	0 %	0 %
Región 11. Total: 20 píxeles	0 %	95 %	5 %	0 %	0 %
Región 12. Total: 8 píxeles	0 %	87 %	12 %	0 %	0 %
Región 13. Total: 30 píxeles	0 %	96 %	3 %	0 %	0 %

Porcentaje promedio para la clase maíz: 90.07 %

Tabla 6.17 - Clase Ruta

Clase Ruta	Porcentaje asignado a Clase:				
	Soja	Maíz	Sorgo	Ruta	Desc.
Región 1. Total: 38 pixeles	0 %	0 %	0 %	100 %	0 %
Región 2. Total: 36 pixeles	0 %	0 %	0 %	100 %	0 %
Región 3. Total: 75 pixeles	1 %	0 %	0 %	98 %	0 %
Región 4. Total: 56 pixeles	0 %	0 %	0 %	100 %	0 %
Región 5. Total: 56 pixeles	0 %	0 %	0 %	100 %	0 %
Región 6. Total: 54 pixeles	0 %	0 %	0 %	100 %	0 %
Región 7. Total: 32 pixeles	0 %	0 %	0 %	100 %	0 %
Región 8. Total: 60 pixeles	0 %	0 %	0 %	100 %	0 %
Región 9. Total: 40 pixeles	0 %	0 %	0 %	100 %	0 %
Región 10. Total: 26 pixeles	0 %	0 %	0 %	100 %	0 %
Región 11. Total: 33 pixeles	0 %	0 %	0 %	100 %	0 %
Región 12. Total: 64 pixeles	0 %	0 %	0 %	100 %	0 %
Región 13. Total: 68 pixeles	0 %	0 %	0 %	100 %	0 %
Región 14. Total: 40 pixeles	0 %	0 %	0 %	100 %	0 %

Porcentaje promedio para la clase ruta: 99.85 %

Tabla 6.18 - Clase Soja

Clase Soja	Porcentaje asignado a Clase:				
	Soja	Maíz	Sorgo	Ruta	Desc.
Región 1. Total: 90 pixeles	98 %	1 %	0 %	0 %	0 %
Región 2. Total: 84 pixeles	98 %	1 %	0 %	0 %	0 %
Región 3. Total: 70 pixeles	100 %	0 %	0 %	0 %	0 %
Región 4. Total: 120 pixeles	98 %	1 %	0 %	0 %	0 %
Región 5. Total: 48 pixeles	100 %	0 %	0 %	0 %	0 %
Región 6. Total: 63 pixeles	100 %	0 %	0 %	0 %	0 %
Región 7. Total: 72 pixeles	97 %	2 %	0 %	0 %	0 %
Región 8. Total: 32 pixeles	90 %	6 %	3 %	0 %	0 %
Región 9. Total: 36 pixeles	94 %	2 %	2 %	0 %	0 %
Región 10. Total: 63 pixeles	89 %	9 %	1 %	0 %	0 %

Porcentaje promedio para la clase maíz: 96.4 %

Tabla 6.19 - Clase Sorgo

Clase Sorgo	Porcentaje asignado a Clase:				
	Soja	Maíz	Sorgo	Ruta	Desc.
Región 1. Total: 255 pixeles	0 %	2.7 %	97 %	0 %	0 %
Región 2. Total: 312 pixeles	0.6 %	5 %	94 %	0 %	0 %
Región 3. Total: 70 pixeles	1.4 %	0 %	98 %	0 %	0 %
Región 4. Total: 70 pixeles	0 %	7 %	93 %	0 %	0 %
Región 5. Total: 72 pixeles	1 %	19 %	79 %	0 %	0 %

Porcentaje promedio para la clase maíz: 92.2 %

Por lo que se puede observar en las tablas anteriores se tiene un porcentaje promedio superior o igual al 90% para todos los casos. Respecto de los porcentajes

individuales para cada región, se puede afirmar que todos ellos se encuentran por encima del 80%.

### 6.2.2.2 Análisis de la influencia de la regla de decisión propuesta por RED

Con el fin de examinar en qué medida influye la regla de decisión, se incluye un nuevo punto de evaluación que consiste en observar cuántos píxeles son rechazados por las dos etapas propuestas por RED. Para ello, se utilizan algunas de las regiones de entrenamiento y otras de test seleccionadas aleatoriamente, a continuación se presentan los valores obtenidos, en la última columna de las tablas 1-3 se muestra la cantidad de píxeles rechazados por ambigüedad que fueron luego clasificados correctamente por la regla propuesta por RED:

Tabla 6.20 a -

Conjunto de Entrenamiento: 1	Rechazo por falta de evidencia	Rechazo por ambigüedad	Cantidad de píxeles rechazados asignados a la clase correcta
Soja	0 píxeles	7 píxeles	7 píxeles (100 %)
Maíz	0 píxeles	18 píxeles	18 píxeles (100 %)
Sorgo	0 píxeles	6 píxeles	6 píxeles (100 %)
Ruta	0 píxeles	0 píxeles	0 píxeles

Tabla 6.20 b -

Conjunto de Entrenamiento: 6	Rechazo por falta de evidencia	Rechazo por ambigüedad	Cantidad de píxeles rechazados asignados a la clase correcta
Soja	0 píxeles	16 píxeles	14 píxeles (87.5 %)
Maíz	0 píxeles	17 píxeles	14 píxeles (82.3 %)
Sorgo	0 píxeles	27 píxeles	21 píxeles (78 %)
Ruta	0 píxeles	8 píxeles	8 píxeles (100 %)

Tabla 6.20 c -

Regiones de Test	Rechazo por falta de evidencia	Rechazo por ambigüedad	Cantidad de píxeles rechazados asignados a la clase correcta
Región 1 Soja (90 píxeles)	0 píxeles	25 píxeles	24 píxeles (96 %)
Región 1 Maíz (49 píxeles)	0 píxeles	42 píxeles	39 píxeles (92,8 %)
Región 1 Sorgo (255 píxeles)	0 píxeles	68 píxeles	60 píxeles (88.8 %)
Región 1 Ruta (38 píxeles)	0 píxeles	14 píxeles	14 píxeles (100 %)

Como se puede ver a través de las tablas anteriores (**Tablas 6.20 a-c**), un alto porcentaje de los pixeles rechazados en la etapa de “Rechazo por ambigüedad”, son clasificados correctamente utilizando el índice que combina cantidad de fuentes, los pesos de los pares fuente-clase y el soporte. Para los ejemplos mostrados no hay pixeles rechazados por la etapa de "Rechazo por falta de evidencia", aunque se ha visto en otras regiones que algunos pixeles son asignados a la clase desconocida por esta etapa. Se evaluó que a medida que se incrementa el valor del parámetro de cantidad de fuentes aportando evidencia a favor de la clase, aumenta la cantidad de pixeles asignados a la clase desconocida por esta etapa de rechazo. A continuación se muestra una tabla donde figuran los promedios de cantidad de fuentes para los pixeles de las diferentes regiones evaluadas.

### Histogramas de Cantidad de Fuentes

Tabla 6.21 - Región de Entrenamiento 1

Cant. Fuentes	0	1	2	3	4	5	6	7	8	9	10	11	12	13
<b>Clases</b>														
<b>Soja</b>	0	0	0	0	0	0	0	0	0	3	16	26	40	0
<b>Maíz</b>	0	0	0	0	0	1	1	0	1	0	0	12	27	0
<b>Sorgo</b>	0	0	0	0	0	0	0	0	0	1	9	21	32	0
<b>Ruta</b>	0	0	0	0	0	0	0	0	0	0	4	25	20	0

Tabla 6.22 - Conjunto de Entrenamiento 2

Cant. Fuentes	0	1	2	3	4	5	6	7	8	9	10	11	12	13
<b>Clases</b>														
<b>Soja</b>	0	0	0	0	0	6	15	23	21	17	2	0	0	0
<b>Maíz</b>	0	0	0	5	1	11	7	5	1	0	0	0	0	0
<b>Sorgo</b>	0	0	0	0	0	1	5	14	19	13	4	0	0	0
<b>Ruta</b>	0	0	0	1	0	2	4	5	4	1	0	0	0	0

Tabla 6.23 - Conjunto de Entrenamiento 3

Cant. Fuentes	0	1	2	3	4	5	6	7	8	9	10	11	12	13
<b>Clases</b>														
<b>Soja</b>	0	0	0	0	0	1	0	0	1	3	14	28	30	0
<b>Maíz</b>	0	0	0	0	0	2	0	1	0	0	2	8	11	0
<b>Sorgo</b>	0	0	0	0	0	0	0	0	1	7	18	32	32	0
<b>Ruta</b>	0	0	0	0	0	0	0	0	1	1	12	6	10	0

Tabla 6.24 - Conjunto de Entrenamiento 4

Cant. Fuentes	0	1	2	3	4	5	6	7	8	9	10	11	12	13
<b>Clases</b>														
<b>Soja</b>	0	0	0	0	1	10	15	30	25	9	0	0	0	0
<b>Maíz</b>	0	0	0	0	1	4	1	2	2	0	0	0	0	0
<b>Sorgo</b>	0	0	0	0	0	1	16	20	30	18	9	2	0	0
<b>Ruta</b>	0	0	2	4	8	14	8	14	3	1	0	0	0	0

Tabla 6.25 - Conjunto de Entrenamiento 5

Cant. Fuentes	0	1	2	3	4	5	6	7	8	9	10	11	12	13
<b>Clases</b>														
<b>Soja</b>	0	0	0	0	0	8	8	27	12	9	0	0	0	0
<b>Maíz</b>	0	0	0	1	3	7	9	10	6	0	0	0	0	0
<b>Sorgo</b>	0	0	0	0	1	5	11	34	34	14	1	0	0	0
<b>Ruta</b>	0	0	0	2	2	8	11	5	1	1	0	0	0	0

Tabla 6.26 - Conjunto de Entrenamiento 6

Cant. Fuentes	0	1	2	3	4	5	6	7	8	9	10	11	12	13
<b>Clases</b>														
<b>Soja</b>	0	0	1	0	1	7	17	33	22	8	1	0	0	0
<b>Maíz</b>	0	0	0	3	9	1	3	4	0	0	0	0	0	0
<b>Sorgo</b>	0	0	0	0	0	2	13	35	38	36	6	0	0	0
<b>Ruta</b>	0	0	1	1	2	6	10	8	2	0	0	0	0	0

Tabla 6.27 - Conjunto de Entrenamiento 7

Cant. Fuentes	0	1	2	3	4	5	6	7	8	9	10	11	12	13
<b>Clases</b>														
<b>Soja</b>	0	0	0	0	0	0	0	0	0	2	18	22	22	0
<b>Maíz</b>	0	0	0	0	1	2	2	0	0	1	2	19	29	0
<b>Sorgo</b>	0	0	0	0	0	0	1	0	0	2	12	45	30	0
<b>Ruta</b>	0	0	0	0	0	0	0	0	4	6	23	47	32	0

Haciendo una lectura rápida de la información condensada en estas tablas, se observa que para los conjuntos de entrenamiento se tiene que la cantidad de fuentes aportando evidencia se concentran entre 5 y 12, prácticamente no hay casos con sólo 2 fuentes aportando evidencia (se registran 5 casos), y no hay ningún caso donde sólo 1 fuente aporte evidencia. Por lo tanto, para los conjuntos de entrenamientos (esto es una vez llevado a cabo el proceso de aprendizaje), no aparecen casos donde se rechace por falta de evidencia. Esto parece tener lógica dado que precisamente se ha entrenado al clasificador a partir de estas muestras, y por tanto existe al menos un mínimo de evidencia para ellas.

Se verá ahora que ocurre con algunos de los conjuntos de test:

**Tablas 6.28- Muestra el Histograma de cantidad de fuentes de diferentes regiones de test**

**Tabla 6.28 a**

Cant. Fuentes	0	1	2	3	4	5	6	7	8	9	10	11	12	13
Región 1 de Soja	0	0	0	1	3	4	7	30	23	17	5	0	0	0

**Tabla 6.28 b -**

Cant. Fuentes	0	1	2	3	4	5	6	7	8	9	10	11	12	13
Región 1 de Sorgo	0	0	0	1	2	11	30	69	85	46	9	0	2	0
Región 2 de Sorgo	0	0	0	0	3	10	39	81	93	72	14	0	0	0
Región 2 de Sorgo	0	0	0	0	0	3	9	14	26	12	6	0	0	0

**Tabla 6.28 c -**

Cant. Fuentes	0	1	2	3	4	5	6	7	8	9	10	11	12	13
Región 1 de Ruta	0	0	0	0	3	3	11	11	8	2	0	0	0	0
Región 2 de Ruta	0	0	0	1	0	5	6	12	7	5	0	0	0	0

**Tabla 6.28 d -**

Cant. Fuentes	0	1	2	3	4	5	6	7	8	9	10	11	12	13
Región 6 de Maíz	0	0	3	11	19	23	30	11	3	0	0	0	0	0
Región 7 de Maíz	0	0	0	10	13	16	23	17	5	0	0	0	0	0

Para el caso de las regiones de test presentadas se puede observar la mayor cantidad concentrada entre 3 y 10 (es decir, las clases con mayor soporte presentan evidencia aportada por este número de fuentes principalmente)

Se muestran a continuación, algunos de los casos de región desconocida para el algoritmo, donde varía la distribución anterior y adquiere sentido el rechazo por falta de evidencia.

**Tabla 6.29 – Regiones desconocidas por el algoritmo tomadas de la imagen “Corn”**

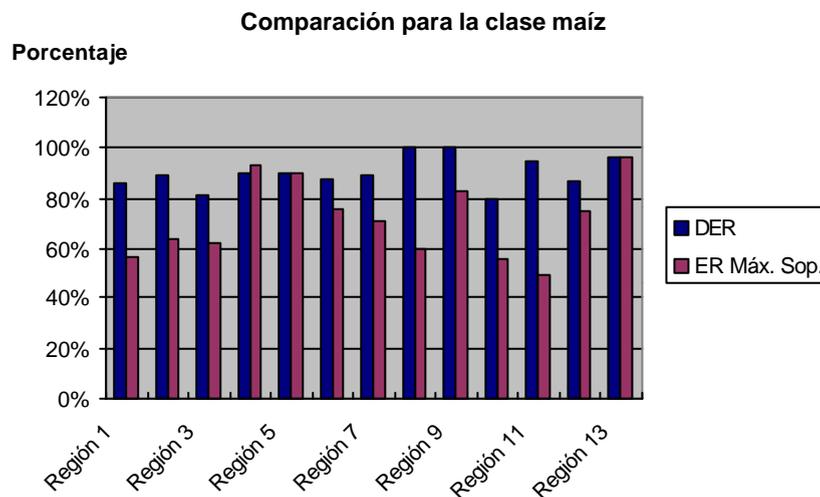
Cant. Fuentes	0	1	2	3	4	5	6	7	8	9	10	11	12	13
Región 1 Desconocida	0	14	61	44	13	0	0	0	0	0	0	0	0	0
Región 2 Desconocida	0	9	36	39	10	2	2	2	0	0	0	0	0	0

Es importante observar cómo se concentran ahora principalmente entre 1 y 4 fuentes aportando evidencia. Este estudio abre una nueva posibilidad de análisis para la etapa de "Rechazo por falta de Evidencia", donde en lugar de considerar la cantidad de

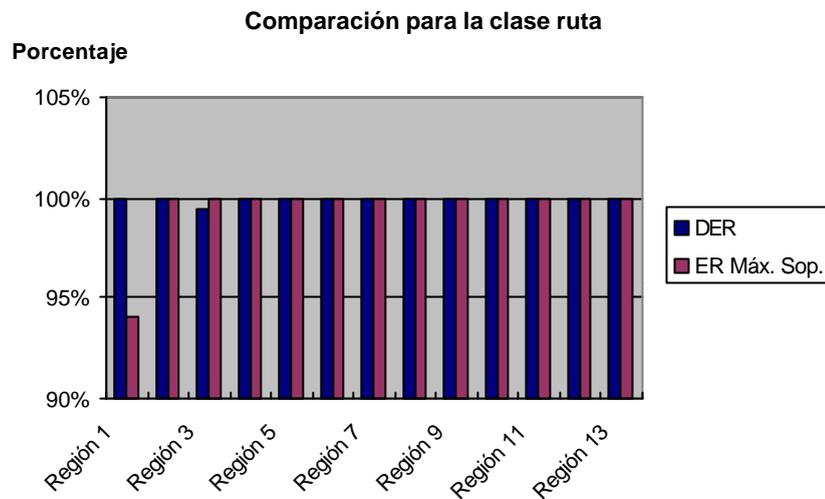
fuentes aportando evidencia, se podría evaluar la distribución de los histogramas anteriores, para dilucidar si se trata de una región perteneciente a una de las clases conocidas o no.

### 6.2.2.3 Análisis comparativo de RED

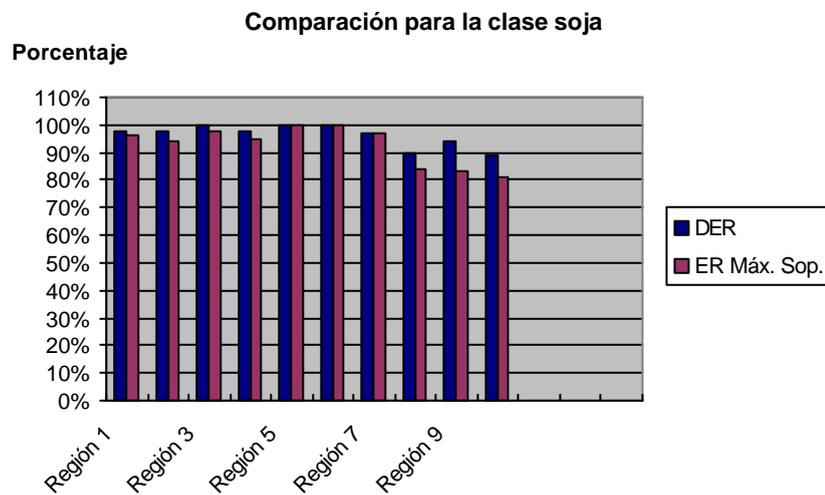
Se realiza en esta sección un análisis comparativo entre los resultados obtenidos utilizando RED (los mostrados anteriormente en la **Sección 6.2.2.1**) y los obtenidos, para los mismos conjuntos de test, con el algoritmo de Razonamiento evidencial utilizando como regla la del máximo soporte (ERMS). La base de conocimiento con la que se trabaja es la misma para ambos algoritmos. Como puede observarse en las **Figuras 6.3 – 6.6**, con RED se logran en la mayoría de los casos porcentajes de acierto mayores que para el algoritmo ERMS. Las tablas presentan los porcentajes de pixeles asignados por cada algoritmo a la clase correcta (es decir se sabe que la región a clasificar pertenece a dicha clase).



**Figura 6.3 - Esta tabla presenta una comparación de los resultados de los algoritmos DER y ER con la regla de máximo soporte para la clase maíz**



**Tabla 6.31-** Esta tabla presenta una comparación de los resultados de los algoritmos DER y ER con la regla de máximo soporte para la clase ruta



**Tabla 6.32 -** Esta tabla presenta una comparación de los resultados de los algoritmos DER y ER con la regla de máximo soporte para la clase soja

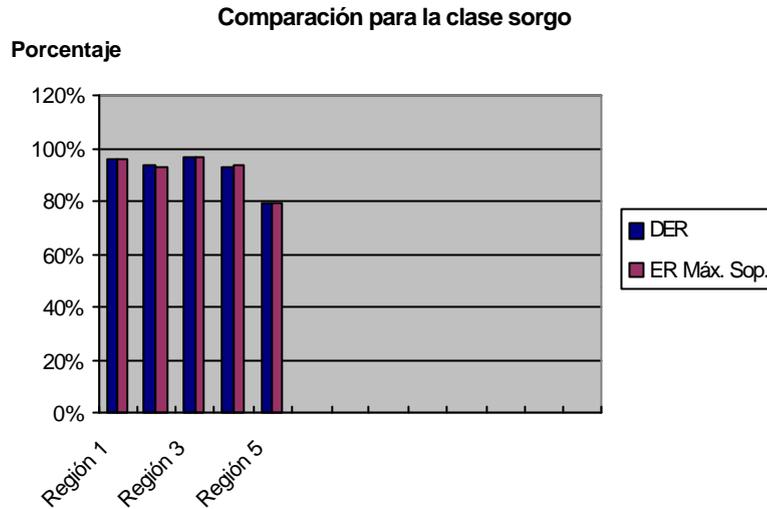


Tabla 6.33 - Esta tabla presenta una comparación de los resultados de los algoritmos DER y ER con la regla de máximo soporte para la clase sorgo

#### Clase Maíz

RED: 90.07 % ER: 71.76 %

#### Clase Ruta

RED: 99.85 % ER: 99.57 %

#### Clase Soja

RED: 96.4 % ER: 92.9 %

#### Clase Sorgo

RED: 91.8 % ER: 91.8 %

Se desprende de los resultados anteriormente expuestos que RED presenta un mayor o igual porcentaje promedio para todas las clases con las que se trabajó. En cuanto a los valores individuales de porcentaje para cada región clasificada, como se dijo anteriormente RED supera o iguala en la mayoría de los casos a los porcentajes obtenidos con ERMS.

Por otra parte, se estudió el algoritmo de razonamiento evidencial utilizando como regla de decisión la que elige la clase con mayor soporte más plausibilidad [Ped95 a]. Este se probó para las mismas regiones de test con las que se realizó la comparación anterior, y los porcentajes obtenidos resultaron similares a los de ER con la regla de soporte máximo.

Otras pruebas realizadas consistieron en evaluar el algoritmo RED pero utilizando igual regla de decisión, con la salvedad de asignar a la clase desconocida cuando se produce rechazo por ambigüedad. Se observó en esta experimentación que gran parte de los pixeles eran asignados a la clase desconocida. Esto puede verse en las tablas de la **Sección 6.2.2.3**, donde se presentan los pixeles por región que son rechazados por ambigüedad. Si se asignan los mismos a la clase desconocida, ésta se vería inundada de pixeles.

Para completar este análisis de resultados se presentan algunos valores obtenidos para regiones cuya clase es desconocida para el algoritmo. La mejor precisión obtenida aquí es la del algoritmo RED que asigna cuando encuentra rechazo por ambigüedad a la clase desconocida. En el caso de RED propiamente dicho, distribuye la asignación de pixeles entre las diferentes clases existentes, de igual forma se comporta ERMS, esto puede mejorarse teniendo en cuenta la distribución de la cantidad de fuentes aportando evidencia (histograma de cantidad de fuentes, ver **Sección 6.2.2.2**). También debajo se presentan casos donde se trabaja con muestras que pertenecieron al conjunto de entrenamiento, de forma tal de comparar cómo responden RED y ERMS ante las mismas. Se muestran a continuación, sólo algunos de los resultados obtenidos utilizando regiones desconocidas y otras de entrenamiento.

**Región desconocida 1 de Imagen Bug 1. Se trata de una región de árboles de 121 píxeles.**

**Precisión por clase utilizando RED:**

soja (17%), maíz (58%), sorgo (22%), ruta (0.8%), desconocida (0.8%)

**Precisión por clase utilizando RED con asignación a la clase desconocida en caso de rechazo por ambigüedad:**

soja (0 %), maíz (4.1%), sorgo (4.9%), ruta (0%), desconocida (90.9%)

**Precisión por clase utilizando ERMS:**

soja (7.43 %), maíz (56 %), sorgo (33%), ruta (2.4 %)

**Región desconocida 2 de Imagen Bug 1. Se trata de una región de 49 píxeles.**

**Precisión por clase utilizando RED:**

soja (24.4%), maíz (18.3%), sorgo (48.9%), ruta (8%)

**Precisión por clase utilizando RED con asignación a la clase desconocida en caso de rechazo por ambigüedad:**

soja (0 %), maíz (0%), sorgo (2%), ruta (0%), desconocida (97.9%)

**Precisión por clase utilizando ERMS:**

soja (24.4 %), maíz (18.3 %), sorgo (48.9%), ruta (8 %)

**Conjunto de Entrenamiento 1**

**Precisión por clase utilizando RED:**

soja (100%), maíz (100%), sorgo (100%), ruta (100%)

**Precisión por clase utilizando RED con asignación a la clase desconocida en caso de rechazo por ambigüedad:**

soja (91 %), maíz (57%, el resto asignado a la clase desconocida), sorgo (90%), ruta (100%)

**Precisión por clase utilizando ERMS:**

soja (100%), maíz (92%), sorgo (100%), ruta (100%)

**Conjunto de Entrenamiento 2**

**Precisión por clase utilizando RED:**

soja (100%), maíz (97%), sorgo (100%), ruta (100%)

**Precisión por clase utilizando RED con asignación a la clase desconocida en caso de rechazo por ambigüedad:**

soja (83 %), maíz (16%, el resto asignado a la clase desconocida), sorgo (87.5%), ruta (88%)

**Precisión por clase utilizando ERMS:**

soja (97%), maíz (83%), sorgo (96%), ruta (100%)

### Conjunto de Entrenamiento 3

#### **Precisión por clase utilizando RED:**

Región soja (100%), Región maíz (96%), Región sorgo (100%), Región ruta (100%)

#### **Precisión por clase utilizando RED con asignación a la clase desconocida en caso de rechazo por ambigüedad:**

Región soja (87 %), Región maíz (37%, el resto asignado a la clase desconocida), Región sorgo (89%), Región ruta (100%)

#### **Precisión por clase utilizando ERMS:**

Región soja (98.7%), Región maíz (87.5%), Región sorgo (100%), Región ruta (100%)

### 6.3. Conclusiones del capítulo

En este capítulo se presentó una aplicación con la que se estudia el comportamiento del método RED propuesto en esta tesis. Se trabajó con imágenes de una región del estado de Nebraska, donde se analizan campos cultivados. Las imágenes son, como se explica en el **Capítulo 3**, obtenidas con un sensor *Casi*, y tienen tamaño aproximado de 55 MB cada una (para tener más información referirse al **Capítulo 3**).

En la primera sección se describe la aplicación, mientras que en las subsiguientes, se realiza el seguimiento de cómo se desarrolla el proceso de aprendizaje y cómo afecta la regla de decisión propuesta al momento de clasificar. Finalmente, se compara el método propuesto con el de razonamiento evidencial con regla del máximo soporte y la de máximo soporte más plausibilidad. También se analiza otra posible regla de decisión para RED. Se presentan los resultados obtenidos para un conjunto de regiones, surgidas de 4 imágenes hiperespectrales diferentes.

El método propuesto arroja los resultados esperados. Aún así, se debe evaluar el costo computacional que el mismo introduce respecto de la precisión necesaria para la aplicación. ◆

## **CAPITULO 7**

### **Conclusiones y líneas de investigación futuras**

El método propuesto tiene ciertas ventajas respecto de los métodos convencionales de clasificación, se muestra particularmente atractivo para el análisis de imágenes hiperespectrales. Está basado en el método de razonamiento evidencial propuesto por Peddle, permitiendo integrar numerosos datos de diferente naturaleza. No es necesario presuponer una distribución de los datos como ocurre con el clasificador de máxima verosimilitud, el cual supone una distribución "gaussiana" [Ped93][Pin98][www7].

RED permite que la base de conocimiento con la que se trabaja no sea estática, sino que por medio de un proceso de aprendizaje se pueden incorporar nuevos datos al sistema. La regla de decisión utilizada por el método propuesto no sólo tiene en consideración la incertidumbre asociada a los datos, que permite distinguir entre no creencia y falta de creencia, sino que se evalúa la decisión de un rechazo por falta de evidencia y un rechazo por ambigüedad. Para el caso de rechazo por ambigüedad se analiza un índice surgido del indicador de la cantidad de fuentes aportando evidencia para la clase, el peso de las fuentes que intervienen y el valor de soporte. La clase para la que se obtuvo el mayor valor de este índice es la que utilizaremos para asignar el pixel.

Se ha experimentado que el método arroja buenos resultados para el tipo de problemas con el que se ha trabajado.

Sin embargo, RED puede resultar más complejo y costoso computacionalmente (dependiendo de la cantidad de fuentes y clases con las que se trabaje) que algunos de los métodos convencionales de clasificación. Por ello se debe evaluar, de acuerdo a la naturaleza de la aplicación, la conveniencia de emplear dicho método. Al respecto, se ha empezado a trabajar en el estudio de la paralelización del algoritmo. Se desarrolló una primera versión paralela de RED trabajando sobre un "cluster" de

PCs trabajando con un esquema de maestro-esclavo para la clasificación de la imagen, donde los procesos esclavos trabajan sobre regiones disjuntas y exhaustivas de la imagen [San2001]. Se continúan estudiando nuevas alternativas de paralelización, no sólo que tengan en cuenta la división de la imagen, sino que también se analice una paralelización del algoritmo en sí mismo.

Por otro lado, quedan todavía por explorar varios aspectos relacionados con el tema de esta tesis.

- 1) Analizar y medir la conveniencia de trabajar con imágenes hiperespectrales respecto de las multiespectrales. Se sabe que el contar con las imágenes hiperespectrales tiene como ventajas tener datos disponibles para cualquier aplicación, mientras que para las multiespectrales se tiene información de algunas bandas con lo cual no alcanzará para todo tipo de aplicaciones. Esto de todas formas sigue siendo tema de investigación.
- 2) En cuanto al método propuesto, se proponen como trabajos futuros estudiar diversos caminos para derivar la evidencia, analizar la posibilidad de trabajar con clases jerárquicas, y evaluar cómo influyen estas modificaciones en los resultados. También, realizar un análisis de los parámetros necesarios para el funcionamiento de RED, como el parámetro de precisión, y los pesos asociados a los pares fuente-clase. Se continúa investigando sobre la etapa de Rechazo por falta de evidencia para tomar en cuenta la distribución del histograma de cantidad de fuentes.
- 3) Respecto de la aplicación con la que se presentó el método RED, quedan numerosos aspectos para estudiar. Se pretende extender la aplicación para el estudio de la evolución de diferentes cultivos, siguiendo sus distintas etapas evolutivas en el tiempo. Además se sugiere atacar uno de los aspectos que esta tesis ha dejado un poco de lado por no ser un objetivo de la misma, que es el de estudiar si las fuentes de información seleccionadas para incluir como entrada a la clasificación son las que optimizan el resultado de la misma. Es decir, encontrar el conjunto minimal de fuentes que aporten evidencia y que maximicen el comportamiento del clasificador. ◆

## Referencias y Bibliografía

**[Ang97]** Edward Angel

“Interactive Computer Graphic. A top – down approach with OpenGL”  
Adisson Wesley Logman. 1997.

Es un libro que presenta los aspectos principales de computación gráfica y desarrolla ejemplos utilizando OpenGL. Se puede destacar una sección especialmente dedicada a la interacción entre la luz y los distintos materiales, donde se habla de los fenómenos de absorción, reflexión y transmisión. Además se presenta el modelo de Lambert y otros.

**[Bax94]** Gregory A. Baxes

"Digital Image Processing. Principles and Applications"  
John Wiley & Sons Inc. 1994.

Se trata de un libro que presenta en forma sencilla los conceptos básicos involucrados en el procesamiento de imágenes. Presenta varios ejemplos de las operaciones de morfología como erosión, y dilatación.

**[Bis95]** Christopher M. Bishop

"Neural Networks for Pattern Recognition"  
Clarendon Press Oxford. 1995.

Este libro provee un primer tratamiento comprensivo sobre redes neuronales desde una perspectiva de reconocimiento de patrones estadística.

**[Bra94]** Ronald N. Bracewell

“Two – Dimensional Imaging”  
Prentice Hall. 1994.

En este libro se desarrollan conceptos sobre las imágenes vistas como señales multidimensionales. Se desarrollan temas como respuesta de impulso, función de transferencia, respuesta de frecuencia, etc.

**[Bru2000]** Lorenzo Bruzzone

“An approach to feature selection and classification of remote sensing images based on the Bayes rule for minimum cost”.  
IEEE Transactions on Geoscience and Remote Sensing.  
Vol. 38, Nro.1. Enero 2000.

Se trata de un trabajo en donde se describe un método de clasificación basado en la regla de Bayes. Este método parte de la premisa de que cada una de las decisiones tomadas en la clasificación tiene un costo asociado que puede ser diferente. El autor propone buscar el costo mínimo para encontrar el clasificador que más se ajuste al problema particular.

**[Cas96]** Kenneth R Castleman  
“Digital Image Processing”  
Prentice Hall. 1996

Introduce los conceptos fundamentales sobre imágenes digitales, toma aspectos de las diferentes etapas del procesamiento. Muestra cómo aplicar diferentes técnicas para resolver problemas reales, en campos como biología, astronomía, medicina, etc.

**[Che85]** Cheeseman.  
"In Defense of Probability"  
Proceedings of the International Conference on Artificial Intelligence,  
pág. 1002-1009, 1985.

**[Con83]** Russell G. Congalton, Roy A. Mead  
“A Quantitative Method to Test for Consistency and Correctness”  
Photointerpretation. - Photogrammetric Engineering and Remote Sensing  
Vol.49, 1: 69 – 74. 1983.

Introduce la medida estadística Khat para evaluar la precisión en el campo de sensado remoto.

**[Dem67]** A. P. Dempster.  
“Upper and Lower Probabilities Induced by a Multivalued Mapping”.  
Annals of Mathematical Statistics. Vol. 38, pág. 325- 339. 1967.

Artículo que presenta y describe la suma ortogonal propuesta por Dempster.

**[Dud73]** R. Duda, P. Hart  
"Pattern Classification and Scene Analysis"  
John Wiley. 1973.

Se trata de uno de los libros de cabecera en el tema de Reconocimiento de patrones. En particular, se tratan todos los temas relacionados con el reconocimiento de patrones estadístico.

**[Dug96]** Duguay – Peddle  
“Comparison of evidential reasoning and neural network approaches in a multi-source classification of alpine tundra vegetation”  
Canadian Journal of Remote Sensing  
Vol.22 – Nro.4 – 1996

Trabajo que presenta una comparación del método de razonamiento evidencial implementado por Peddle y el enfoque de redes neuronales, en una aplicación de clasificación de vegetación en la tundra alpina.

**[Fol96]** Foley, van Dam, Feiner, Hughes  
"Computer Graphics Principles and Practice. 2nd Edition in C"  
Adisson Wesley. 1996.

En este libro los autores exploran múltiples perspectivas de "Computer graphics". Particularmente, interesan para esta tesis los aspectos que se presentan sobre modelos de iluminación, manipulación de imágenes. Métodos de trazado de rayos, radiocidad, etc.

**[Fuk90]** Keinosuke Fukunaga  
"Statistical Pattern Recognition"  
2<sup>nd</sup> Edition. Academic Press. 1990.

Es un libro sobre reconocimiento de patrones estadístico. Permite tener un conocimiento de base sobre el tema. Es utilizado como libro de base para muchos cursos universitarios dedicados al reconocimiento de patrones.

**[Gar95]** T. D. Garvey, J.D. Lowrance, y M.A. Fischler.  
"An inference technique for integrating knowledge from disparate sources"  
Multisensor Integration and Fusion for Intelligent Machines and Systems  
(R. C. Luo and M. G. Kay, eds.), pág. 309-325. Norwood, New Jersey: Ablex  
Publishing Corporation., 1995.

Se describen técnicas de fusión de datos, entre las que se incluye la basada en la teoría de la evidencia.

**[Gat97]** Nahum Gat and Suresh Subramanian  
"Spectral Imaging: Technology & Applications"  
Vol. 3, Nro. 1. February 1997  
<http://www.techexpo.com/WWW/opto-knowledge/hyperspectrum/hypersp4.html>

Es una página donde puede encontrar información sobre las distintas formas de adquisición de imágenes que tienen los sensores. También se habla sobre las aplicaciones de sensado remoto, algoritmos de clasificación más utilizados, etc.

**[Gon92]** Rafael C. González, Richard E. Woods  
"Digital Image Processing"  
Addison-Wesley Publishing Comp. 1992

Es un libro sobre procesamiento de imágenes digitales que permite introducir los conceptos básicos involucrados en esta área.

**[Gor90]** J. Gordon y E. H. Shortliffe.  
"The Dempster-Shafer Theory of Evidence"  
Readings in Uncertainty Reasoning, G. Shafer, and J. Pearl, editores, pág. 529-539  
Morgan Kaufmann Publishing Co., Menlo Park, CA. 1990.

Se presentan los conceptos principales de la teoría de la evidencia de Dempster y Shafer.

**[Har92]** R. Haralick, Linda Shapiro  
"Computer and Robot Vision"  
Volumen I. Addison Wesley. 1992.

Este primer volumen del libro cubre temas de visión de bajo nivel, a excepción de las secciones que hablan de formas a partir de textura (en el capítulo de textura). Se presentan los conceptos básicos de imágenes (operaciones de mejorado de la imagen, segmentación, morfología matemática).

**[Har93]** Robert M. Haralick, Linda Shapiro  
"Computer and Robot Vision "  
Volumen II. Addison Wesley. 1993.

El segundo volumen cubre técnicas de más alto nivel, como iluminación, proyección perspectiva, fotogrametría analítica, movimiento, sistemas de visión con base de datos de conocimiento, etc.

**[Hor86]** Berthold Paul Horn  
"Robot Vision"  
The MIT Press McGraw Hill. 1986.

Este libro presenta un enfoque del campo de visión por computadora, usando una notación consistente basada en un entendimiento detallado del proceso de formación de la imagen. Da referencias a trabajos de investigación actuales en el área. Da material para ingenieros que requieren aplicar métodos de visión de computadora al mundo real. Los capítulos en la primera parte del libro enfatizan el desarrollo de descripciones simbólicas simples a partir de las imágenes, mientras los capítulos restantes tratan con métodos que explotan estas descripciones. Ofrece también un conjunto de ejercicios de complemento.

**[Hus91]** Zahid Hussain  
"Digital Image Processing"  
Ellis Horwood Limited. 1991.

Este libro discute la teoría de imágenes y de visión, incluye soluciones paralelas orientadas al procesamiento de imágenes y visión por computadora. Se describen aplicaciones reales sobre estos temas, y se subrayan las distintas limitaciones que presentan las técnicas descriptas.

**[Hut92]** S. A. Hutchinson y A.C. Kak  
"Multisensor Strategies Using Dempster-Shafer Belief Accumulation"  
Data Fusion in Robotics and Machine Intelligence, M. A. Abidi and R. C. Gonzalez, editores, Academic Press, pág. 165-209, 1992.

Se trata de un trabajo relacionado con el tema de la teoría de la evidencia.

**[Jah95]** Bernd Jahne

"Digital Image Processing Concepts, Algorithms, and Scientific Applications"  
3<sup>rd</sup> Edition. Springer – Verlag. 1995.

Es una guía práctica que le permite al lector adquirir los conceptos básicos y actualizados de procesamiento de imágenes.

**[Jai89]** Anil K Jain

"Fundamentals of Digital Image Processing"  
Prentice Hall. 1989.

Es un libro de procesamiento de imágenes que permite obtener una base teórica del tema.

**[Jai95]** Ramesh Jain, Rangachar Kasturi, Brian G. Schunck

"Machine Vision"  
McGraw-Hill International Editions. 1995.

Sirve como introducción al campo de visión por computadora y se centra en los conceptos básicos y técnicas más importantes dentro del área. Se presentan temas como calibración de la cámara, color y textura, detección de movimiento y reconocimiento de objetos.

**[Jen96]** Jensen

"Introductory Digital Image Processing. A remote sensing perspective"  
2da edición. Prentice Hall. 1996

Es un libro que presenta las distintas etapas del procesamiento de imágenes, pero específicamente para aplicaciones en el área de sensado remoto. Se puede leer sobre las técnicas que se aplican en el mejorado, segmentación y análisis de las imágenes.

**[Kim90]** H. Kim, y P. Swain.

"A Method for Classification of Multisource Data Using Interval- Valued Probabilities and its Applications to Hiris Data"  
Proceedings of a Workshop on Multisource Data Integration in Remote Sensing, NASA Conference Publication 3099, pág. 75-81. 1990.

Este trabajo presenta un método de clasificación para datos tomados de múltiples fuentes. Se presenta una aplicación del mismo.

**[Kli93]** G. J. Klir.

"Developments in Uncertainty-Based Information"  
Advances in Computers, Vol. 36, pág. 255-332, Academic Press. 1993.

Describe el concepto de incertidumbre. Presenta la teoría de Dempster y Shafer, y técnicas basadas en lógica difusa.

**[Lan99]** L. Lanzarini, C. Sanz, L. Acosta Burllaile  
“Evaluación de técnicas de clasificación no supervisadas”  
Informe técnico. Laboratorio de Investigación y Desarrollo en Informática (LIDI).  
Facultad de Informática, UNLP.

Se presenta un análisis de cuatro técnicas de “clustering” o clasificación no supervisada. Se comparan a partir de diferentes pruebas realizadas sobre imágenes de prueba utilizando Khoros.

**[Lee87]** T. Lee, J. Richards, y P. Swain.  
“Probabilistic and Evidential Approaches for Multi-source Data Analysis”  
IEEE Transactions on Geoscience and Remote Sensing, Vol. 25, Nro. 3, pág.  
283-292. 1987.

Se trata de un estudio y comparación de métodos de clasificación basados en enfoques probabilísticos y basados en la teoría de la evidencia, aplicados al análisis cuando se trabaja con múltiples fuentes.

**[Lev85]** Martin D Levine  
"Vision in Man and Machine"  
McGraw Hill. 1985.

Se trata de un libro que cubre los aspectos fundamentales de visión por computadora.

**[Lil94]** Thomas M. Lillesand, Ralph W. Kiefer  
"Remote Sensing and Image Interpretation"  
3<sup>rd</sup> Edition. John Wiley. 1994.

Es uno de los libros de cabecera para sensado remoto. Provee conocimientos sobre interpretación de imágenes visuales y técnicas de procesamiento de imágenes digitales. Cubre tópicos como clasificación de imágenes, evaluación de la precisión, sistemas de observación de la Tierra utilizados por la NASA, escáner hiperespectral, sistemas de sensado nuevos, etc. También trata los principios de adquisición e interpretación de los datos colectados con sensores no fotográficos.

**[Lim90]** Jane S Lim  
"Two – Dimensional Signal and Image Processing"  
PTR Prentice Hall. 1990.

Este texto cubre los principios y aplicaciones principales de procesamiento de señales e imágenes.

**[Lot95]** R. Lotufo, N. Delfino d’Ávila Mascarenhas  
SIBGRAPI 95 VIII Simposio Brasileiro de Computación Gráfica y Procesamiento de Imágenes. SBC Universidad Federal de San Carlos, SP \_ UFSCar- 1995.

Presenta un conjunto de artículos referidos al área de Computación Gráfica y Procesamiento de Imágenes.

**[Mar82]** David Marr  
"Vision"  
Freeman and Company. 1982

Este libro presenta los conceptos sobre el sistema visual humano, y las técnicas y conceptos principales de visión por computadora. Es muy recomendable para los que quieren introducirse en el área.

**[Mar94]** Darío Maravall Gómez – Allende  
"Reconocimiento de Formas y Visión Artificial"  
Assison-Wesley Iberoamericana. 1994.

Se trata de un libro que presenta no sólo conceptos teóricos, sino también aplicaciones y nociones prácticas de reconocimiento de patrones y visión artificial. Se describen diferentes técnicas de clasificación (supervisadas y no supervisadas).

**[Mas99 a]** Laurent Mascarilla y Carl Frélicot.  
"Combining Rejection – Based Pattern Classifiers".  
Univerté de La Rochelle,  
Laboratoire d'Informatique et d'Imagerie Industrielle. 1999

Se trata de un trabajo que presenta la descripción y aplicación de un método de clasificación, en donde se habla de la teoría de la evidencia.

**[Mas99 b]** Laurent Mascarilla, Carl Frélicot, E. Zahzah.  
"Combining: An alternative for choosing between reject - first and accept- first classifiers"  
NAFIPS '99. Junio 1999

En este trabajo se utilizan dos posibles estrategias de rechazo en la clasificación de patrones, y luego sus resultados son combinados con el modelo de Dempster-Shafer para clasificar o rechazar patrones. Provee resultado sobre datos artificiales.

**[Mur98]** R. Murphy  
"Dempster-Shafer Theory for Sensor Fusion in Autonomous Mobile Robots"  
IEEE Transactions on Robotics and Automation, Vol. 14, Nro. 2. Abril 1998.

Este trabajo presenta una aplicación de la teoría de Dempster-Shafer para la fusión de sensores.

**[Pal94]** P. Palacharla y P.C. Nelson  
"Understanding Relations between Fuzzy Logic and Evidential Reasoning Methods".  
Proceedings of Third IEEE International Conference on Fuzzy Systems, Orlando, FL  
pp. 1933-1938, June 1994.

Es un trabajo que presenta una comparación entre los métodos de razonamiento evidencial y los basados en lógica difusa.

**[Ped91]** D. Peddle y S. Franklin  
“Image Texture Processing and Data Integration for Surface Pattern Discrimination”  
Photogrammetric Engineering & Remote Sensing  
Vol.57- Nro. 4. 1991.

Es una publicación que describe un trabajo del área de sensado remoto, donde se utilizan técnicas de procesamiento de textura y de integración de datos.

**[Ped92]** D. Peddle y S. Franklin  
“Multisource evidential classification of surface cover and frozen ground”  
International Journal R. S.  
Vol. 13- Nro. 17. 1992

Es una publicación donde se describe el método de razonamiento evidencial aplicado al área de sensado remoto.

**[Ped93]** D. Peddle y S. Franklin  
“Classification of Permafrost Active Layer Depth from Remotely Sensed and Topographic Evidence”  
Remote Sensing Environment. 1993.

En este trabajo se describe una aplicación de sensado remoto donde se aplica la teoría de la evidencia como técnica de clasificación.

**[Ped93]** Peddle  
“An Empirical comparison of evidential reasoning, linear discriminant analysis, and maximum likelihood algorithms for alpine land cover classification”  
Canadian Journal of Remote Sensing.  
Vol.19. Nro.1- 1993

Es un trabajo de análisis de la aplicación de diferentes métodos de clasificación, comparándolos entre sí. Específicamente se estudia el comportamiento del método de razonamiento evidencial en contraposición con el análisis de discriminante lineal y el de máxima verosimilitud, en una aplicación de cobertura de suelo alpino.

**[Ped95 a]** Peddle  
“Mercury®: An evidential reasoning image classifier”  
Computers& Geosciences.  
Vol. 21 – Nro. 10- 1995

Es un trabajo que presenta al clasificador de razonamiento evidencial utilizando regla de soporte + plausibilidad. Explica cómo fue implementado y utilizado en aplicaciones de sensado remoto.

**[Ped95 b]** Peddle

“Knowledge Formulation for Supervised Evidential Classification”

Photogrammetric Engineering & Remote Sensing

Vol.61- Nro. 4 – 1995

Este trabajo que describe la forma en que se deriva la evidencia en el marco del clasificador de razonamiento evidencial.

**[Ped97]** Peddle, Hall, LeDrew y Knapp

“Classification of Forest land cover in BOREAS II: comparison of results from sub pixel scale physical modeling approach and a training based method”

Canadian Journal of Remote Sensing. Vol.23- Nro. 2- 1997

Se trata de un trabajo que analiza y compara la clasificación de áreas forestales utilizando métodos basados en modelos biofísicos y métodos basados en entrenamiento.

**[Ped98]** D. Peddle y Duguay

“Mountain Terrain Analysis using a knowledge–based interface to a GIS”

Geomática

Vol.52 – Nro. 3- 1998

Trabajo del área de sensado remoto donde se describe la utilización de GIS para análisis de terreno montañoso.

**[Pin98]** Jorge E. Pinzón, Susan L. Ustin, John F. Pierce

“Robust Feature Extraction for Hyperspectral Imagery Using Both Spatial and Spectral Redundancies”.

<http://vache.ucdavis.edu/papers/html/pinzonetal1998e/paperfr.html>

Se trata de un trabajo realizado en la Universidad de California, se puede acceder al mismo a través de la URL a la que se hace referencia en el párrafo anterior.

**[Pra91]** William K. Pratt

"Digital Image Processing"

2<sup>nd</sup> Edition

John Wiley-1991

Esta segunda edición cubre los nuevos desarrollos en el área de procesamiento de imágenes. Tiene cinco secciones que exploran la caracterización de imágenes continuas, técnicas de muestreo y cuantificación, junto con la representación matemática de imágenes discretas. Presenta técnicas de procesamiento de señales en dos dimensiones, técnicas de mejorado, restauración y análisis de imágenes.

**[Pra98]** Documentos internos del grupo de desarrollo PRA (Photon Research Associates)

Se trata de un conjunto de documentos que describen el proyecto “Verde” realizado en el año 1998 por este grupo. Se presentan objetivos, material, y desarrollo de este proyecto, junto con los resultados obtenidos.

**[Rem2000]** Quinn P. Remund, David G. Long y Mark Dinkwater  
“An Iterative Approach to multisensor Sea Ice Classification”  
IEEE Transactions on Geoscience and Remote Sensing.  
Vol. 38, Nro. 4, Julio 2000.

Se trata de un trabajo donde se utiliza el clasificador de máxima verosimilitud para una aplicación de aguas congeladas.

**[Ros86]** George H. Rosenfield, Katherine Fitzpatrick- Lins  
“A Coefficient of Agreement as a Measure of Thematic Classification Accuracy”.  
Photogrammetric Engineering and Remote Sensing  
Vol.52, Nro. 2, pág. 223 – 227. Feb.1986.

Se define uno de los índices que permiten evaluar la precisión en una clasificación. En particular, se explica y define el indicador Khat.

**[Rus92]** E. H. Ruspini, J. D. Lowrance, y T. M. Strat  
"Understanding evidential reasoning"  
International Journal of Approximate Reasoning, Vol. 6, pág. 401- 424. Mayo 1992.

Trabajo donde se presenta un análisis sobre el razonamiento evidencial.

**[Rus95]** John C. Russ  
"The Image Processing Handbook" 2<sup>nd</sup> Edition  
CRC Press-1995

*Cubre métodos con dos propósitos:*

- Mejorar la apariencia visual de las imágenes para el ojo humano
- Preparar las imágenes para medición de los rasgos y estructuras presentes

Presenta una colección extensa de herramientas de procesamiento de imágenes, que permiten que el usuario de sistemas basados en computadoras entienda estos métodos, y que puedan desarrollar programas adicionales para una aplicación particular. Incluye comparaciones de diferentes algoritmos que pueden ser usados para propósitos similares.

**[San2000]** C. Sanz.

“Análisis de Imágenes hiperespectrales. Clasificación de cultivos”

WICC2000 (Workshop de Investigadores en Ciencias de la Computación)

<http://wicc2000.info.unlp.edu.ar/WICC2000/papersvi.htm>

Presenta los distintos conceptos relacionados con el análisis de imágenes obtenidas con sensado remoto. Se describen algunos índices de clasificación. Se presenta el concepto de imagen multiespectral e hiperespectral.

**[San2001]** C. Sanz, A. De Giusti.

"A distributed solution for dynamic evidential reasoning applied to the classification of hyperspectral images"

5<sup>th</sup> World Multi-Conference on Systemics, Cybernetics and Informatics (SCI 2001).

Orlando, Florida. Julio 2001.

SCI es un foro internacional (se viene llevando a cabo desde 1995) donde se reúnen científicos e ingenieros, investigadores, teóricos y prácticos del campo de la Sistematización, Cibernética e Informática.

**[Sch89]** Robert J. Schalkoff

"Digital Image Processing and Computer Vision. An Introduction to Theory and Implementation"

John Wiley and Sons – 1989.

Es una introducción a los conceptos asociados al procesamiento digital y visión por computadoras. Revisa todos los aspectos relacionados con el procesamiento de imágenes, reconocimiento de patrones, geometría óptica, e inteligencia artificial, que permiten resolver problemas de visión por computadora. Discute también, arquitecturas específicas para aplicaciones de visión por computadoras, redes neuronales, detección de bordes y segmentación.

**[Sch92]** Robert Schalkoff

"Pattern Recognition Statistical, Structural and Neural Approaches"

John Wiley and Sons-1992

Explora los conceptos centrales de reconocimiento de patrones, sus métodos y aplicaciones. Describe los enfoques estadísticos, sintácticos y neuronales.

**[Sch97]** John R. Schott

“Remote Sensing: The Image Chain Approach “

Oxford University Press, Inc. -Sept. 1997

ISBN: 0195087267

Cubre los aspectos fundamentales del sensado remoto, analiza el tema como un proceso continuo, incluyendo temas como la interacción de la energía con la materia, propagación de la radiación, y la diseminación de los datos, enfatiza las herramientas y procesos requeridos para la extracción de información a partir de los datos sensados remotamente.

**[Sha76]** G. Shafer.

“A Mathematical Theory of Evidence”

Princeton University Press, Princeton, N.J., pág. 297.

Es la publicación original de Shafer que presenta la teoría de la evidencia.

**[Smi94]** M.O. Smith, D.A. Roberts, J. Hill, W. Mehl, B. Hosgood, J. Verdebout, G. Schmuck, C. Koechler, y J.B. Adams.

“A new approach to determining spectral abundances of mixtures in multispectral images”.

Institute of Electrical Electronics Engineering, Geosciences Remote Sensing Transactions. IGARSS '94, California Institute of Technology, Pasadena, CA. 1994.

Los autores prueban una nueva técnica para poder clasificar mezclas de materiales usando imágenes multiespectrales. La técnica es conocida como FBA (Foreground-Background Analysis). El método busca el máximo contraste entre conjuntos espectrales del fondo y el primer plano mientras simultáneamente minimiza la variabilidad entre estos conjuntos.

**[Sri90]** A. Srinivasan, y J. Richards.

“Knowledge-based Techniques for Multi-source Classification”

International Journal of Remote Sensing, Vol.11, Nro.3, pág.505-525. 1990.

Se presentan técnicas basadas en conocimiento para clasificación utilizando múltiples fuentes.

**[Ste83]** R. Stein

"The Dempster-Shafer Theory of Evidence"

AI Expert, Vol. 8, Nro. 8, pág. 26-31. Agosto 1993.

Artículo que analiza la teoría de la evidencia.

**[Sto97]** William Stoney

“Outlook for the future. Land Sensing Satellites in the Year 2000”

International Geoscience and Remote Sensing Symposium

IGARSS. Singapore- 1997.

Este artículo da un panorama de cómo será el futuro en el área de satélites, qué lanzamientos y tecnologías se esperan.

**[Tou74]** J. T. Tou, R.C. Gonzalez

"Pattern Recognition Principles"

Adisson Wesley-1974

Es un libro interesante para quienes quieren adentrarse en los conceptos del reconocimiento de patrones y las técnicas más usadas en el área.

**[Umb98]** Scott E. Umbaugh  
“Computer Vision and Image Processing“  
A practical Approach using CVIPtools  
Prentice Hall-1998

Da un enfoque orientado a aplicaciones, más que a la teoría de visión de computadoras y procesamiento de imágenes (CVIP). Provee fundamentos sobre el tema, y un ambiente de desarrollo de software. Incluye numerosas ilustraciones que ejemplifican el contenido del libro.

**[Ust93]** S.L. Ustin, M.O. Smith, y J.B. Adams.  
“Remote Sensing of Ecological Processes: A strategy for Developing Ecological Models Using Spectral Mixture Analysis”.  
Ehrlinger, J. and C. Field (Eds), Scaling Physiological Processes: Leaf to Globe,  
Academic Press, New York. Pág. 339-357, 1993.

Es un trabajo que describe el método análisis de mezcla espectral (SMA).

**[Ust98]** Susan L. Ustin, Larry Costick, A. Palacios Orueta, Eric W. Sanderson, y Jorge E. Pinzon  
“Hyperspectral Imaging for Remote Sensing of Vegetation Stress and Indicators of Habitat condition”. Department of Land, Air, and Water Resources. Universidad de California

Es un trabajo sobre una aplicación de sensado remoto utilizando imágenes hiperespectrales, donde se analiza el estado de la vegetación (sana o no sana) y se estudian otros indicadores de condición de habitat. Especialmente se utilizan métodos como el de análisis de mezcla espectral (SMA), FBA, y HFBA, que son desarrollados y explicados en el texto.

**[Wil90]** G. Wilkinson, y J. Megier.  
“Evidential Reasoning in a Pixel Classification Hierarchy – A Potential Method for Integrating Image Classifiers and Expert System Rules Based on Geographic Context”.  
International Journal of Remote Sensing, Vol. 11, Nro.10, pág. 1963-1968. 1990.

Descripción de la técnica de razonamiento evidencial, en particular como un método interesante en el contexto de clasificaciones jerárquicas.

**[Wul93]** Wulder, LeDrew, Franklin y Lavigne  
“Aerial Image texture information in the estimation of northern deciduous and mixed wood forest leaf area index (LAI)”  
Remote Sensing Environment- 1998

Se trata de un trabajo de donde se puede obtener un conjunto de medidas de textura utilizadas en el tipo de aplicación que se presenta.

[www1] [http://rst.gsfc.nasa.gov/Sect13/nicktutor\\_13-5.html](http://rst.gsfc.nasa.gov/Sect13/nicktutor_13-5.html)

Hyperspectral Remote Sensing: Imaging Spectrometers.

Se trata de una página donde se puede obtener información sobre los espectrómetros utilizados en sensado remoto. Se habla de los nuevos sensores que permiten adquirir imágenes hiperespectrales

[www10]

<http://www.fas.umontreal.ca/BIOL/Casgrain/en/labo/R/v3/description/kmeans.html>

Departamento de Ciencias Biológicas - Universidad de Montreal - Canadá

Se describe el método de clasificación no supervisada conocido como k-medias.

[www11] <http://asio.jde.aca.mmu.ac.uk/multivar/kmeans.htm>

Universidad Metropolitana de Manchester

Se describe el método de clasificación no supervisada conocido como k-medias.

[www12] <http://lib-www.lanl.gov/pubs/la-sci/clustering-and-kmeans.html>

Se trata de una página donde se introduce el tema de clasificación no supervisada (clustering). Se explica también uno de los algoritmos más conocidos, el de k-medias.

[www13] <http://www.ai.sri.com/~gister/>

Se presenta un sistema de razonamiento evidencial, denominado Gister.

[www14] <http://www.ai.sri.com/cgi-bin/pubs/>

Se trata de un sitio donde se presentan un conjunto de publicaciones relacionadas con el razonamiento evidencial.

[www15] <http://www.ie.ncsu.edu/kay/msf/related.htm>

North Carolina State University

En este sitio se discuten, entre otras cosas, distintas técnicas aplicadas a la fusión e integración de múltiples sensores. Principalmente, técnicas probabilísticas como Bayes, MAP, ML, y otras como la teoría de la evidencia de Dempster y Shafer.

[www16] <http://telsat.belspo.be/remote.html>

Es un sitio desarrollado por TELSAT, el Programa Nacional de Investigación en Sensado Remoto de la Oficina Federal Belga para cuestiones científicas, técnicas y culturales. Presenta temas relacionados con el sensado remoto, como satélites, calibración, etc.

[www17] <http://www.itres.com/docs/top.html>

ITRES – Compact Airborne Spectrographic Imager

En este sitio se describe el tipo de sensor Casi (utilizado para adquirir las imágenes con las que se trabaja en esta tesis)

[www18] <http://www.rsinc.com/>

Research System.

En estas páginas se puede encontrar una descripción de ENVI y de IDL, con sus características principales. Incluso, se tiene acceso a un tutorial sobre el tema.

[www2] <http://vache.ucdavis.edu/papers/html/ustinetal1998b/>

S.L. Ustin, M.O. Smith, S. Jacquemoud, M.M. Verstraete and Y. Govaerts.  
Vegetation Mapping for Earth Sciences.  
Manual of Remote Sensing: Earth Sciences  
Geobotany: 1998.

Se trata de una página del departamento de recursos hidrológicos, de aire y suelo de la Universidad de California. Se habla de los modelos de reflectancia, y las características espectrales de los vegetales. Se hace también un poco de historia sobre la evolución del sensado remoto, particularmente para aplicaciones de geobotánica.

[www3] <http://resac.gis.umn.edu/concept.html>-  
<http://resac.gis.umn.edu/agriculture.html>

RESAC. Regional Earth Science Applications Center. Consorcio de universidades, estados, agencias de recursos naturales e industrias en Minnesota, Wisconsin y Michigan, que desarrollan métodos de análisis geoespaciales, sensado remoto y modelos de procesos biofísicos para aplicaciones en agricultura, bosques, coberturas de suelo y recursos hidrológicos.

[www4] <http://www.earthscan.com>

EarthScan. Realizan estudios de áreas cultivadas, entre los que se incluyen medidas de áreas, mapas de vigor, etc.

[www5] <http://www.statsoft.com/textbook/stathome.html>

Software para realizar análisis estadístico.

[www6] <http://www.sc.chula.ac.th/courseware/2309507/Lecture/remote18.htm>

Es una página que forma parte de un curso de sensado remoto de la Facultad de Ciencias de la Universidad de Chulalongkorn. Bangkok. Tailandia.

[www7] <http://www.dpi.inpe.br/spring/teoria/classif/classifeng.htm>

INPE (National Institute for Space Research)

Es una página donde se presentan diversos aspectos sobre la clasificación de imágenes digitales.

[www8] <http://www.uwm.edu/~jcz/ISODATA.html>

Universidad de Wisconsin en Milwaukee.

CENTRO PARA EL ESTUDIO DE GRANDES LAGOS.

En esta página se describe el método de clasificación no supervisado, ISODATA.

[www9] <http://deathstar.rutgers.edu/courses/remsens/remensing9/sld003.htm>

Grant F. Walton Center for Remote Sensing and Spatial Analysis (CRSSA). Ubicado en el Campus Cook College de la Universidad Rutgers en New Brunswick, New Jersey. CRSSA trabaja en investigación y formación de recursos humanos en el área de sensado remoto y sistemas de información geográfica (GIS).

## **ANEXO A:**

### **Breve reseña sobre la evolución de los sensores remotos**

La cámara fotográfica sirvió como idea primitiva de sensado remoto por más de 150 años. La idea de fotografiar la superficie terrestre, surgió alrededor de 1840 con fotos tomadas desde los globos aerostáticos. Para la primera guerra mundial, las cámaras montadas en aeroplanos proveían vistas aéreas de largas superficies terrestres, que resultaban sumamente importantes para reconocimiento militar [Gat97].

A partir de allí hasta principios de 1960, la fotografía aérea se mantuvo como herramienta estándar para explorar la superficie desde una perspectiva oblicua o vertical.

Alrededor de 1946, se adquirieron imágenes desde Alemania después de la Segunda Guerra Mundial. Esto fue referido como programa “Viking”.

Los primeros sensores que no estaban basados en cámaras fotográficas, y que se montaron en satélites tuvieron el propósito de observar las nubes. El primer satélite meteorológico, TIROS-1, fue lanzado el 1 de abril de 1960.

Durante los 60's, los sensores de imágenes sofisticados fueron incorporados en satélites. Los primeros fueron cámaras de TV básicas que obtenían imágenes de nubes y de la superficie de la Tierra en blanco y negro y con baja resolución. Otros tipos de sensores fueron desarrollados y tomaban imágenes usando el espectro electromagnético más allá del visible, en las regiones del infrarrojo cercano y termal. El campo de visión era amplio, usualmente 100 kilómetros.

Aproximadamente en 1970 fue cuando se alcanzó una madurez en el sistema operacional para recolectar información sobre la tierra, y coincidió con la puesta de los instrumentos de sensado en laboratorios espaciales y en el Landsat (primer satélite dedicado específicamente a monitorear superficies terrestres y océanos y así mapear los recursos culturales y naturales). Para 1980 una variedad de sensores especializados (CZCS, HCMM, y MAVHRR) fueron puestos en órbita como programas de investigación.

Algunos de los principales observadores de la tierra son: Landsat 1-6 (1973), Seasat (1978), HCMM (1978), SPOT 1-3 (France, 1986), RESURS (Rusia 1985), IRS (1 A - 1 D) (India 1986), ERS 1-2 (1991), JERS 1-2 (Japón 1992), Radarsat (Canadá 1995), ADEOS (Japón 1996). También hay sistemas de radares volando en “shuttles” espaciales.

### **Descripción de los sensores remotos más conocidos**

#### **Landsat: The Multispectral Scanner**

Los dos primeros Landsat soportaban dos sistemas de sensor. El RBV (Return Beam Vidicon) que consiste de 3 cámaras que usan filtros de color para proveer bandas multiespectrales centradas en azul-verde, amarillo-rojo, y rojo IR. El otro instrumento es el MSS (Multi-Spectral Scanner), utiliza un espejo de “scan” oscilante que se desplaza en un ángulo de +/- 2.89 grados. La luz reflejada recogida por este “scan” pasa a través de un tren óptico donde es particionada en 4 filtros que producen las bandas espectrales. Luego la luz de cada filtro alcanza su conjunto de 6 detectores electrónicos que subdividen el “scan” en 6 líneas paralelas, cada una equivalente a un ancho de suelo de 79 m.

#### **Landsat: The Thematic Mapper**

Es un sensor de imagen multiespectral más sofisticado, llamado Thematic Mapper (TM). Se agregó a los Landsat 4, 5 y 6. Tiene una semejanza en los modos operacionales al MSS, el TM consiste de 7 bandas que tienen las siguientes características:

Banda No.	Intervalo longitud de onda (µm)	Respuesta Espectral	Resolución (m)
1	0.45 - 0.52	Azul-Verde	30
2	0.52 - 0.60	Verde	30
3	0.63 - 0.69	Rojo	30
4	0.76 - 0.90	Cercano Infrarrojo	30
5	1.55 - 1.75	Medio Infrarrojo	30
6	10.40 - 12.50	Infrarrojo Termal	120
7	2.08 - 2.35	Medio Infrarrojo	30

Las seis bandas de reflectancia obtienen su resolución efectiva a una altitud de órbita nominal de 705 km. (438 millas), a través de un IFOV de 0.043 mrad. La séptima banda es el canal termal, el cual tiene un IFOV de 0.172 mrad.

### **SPOT y otros sistemas de satélite**

Los “scanners” MSS y TM fueron los primeros en observar la tierra durante los 70’ a los 80’. Pero estos instrumentos contienen partes que se mueven como los espejos oscilantes que están sujetos a fallas. Se desarrolló luego otro enfoque para sensar la radiación y se llamó Pushbroom Scanner (o “scanner” escobillón). Este utiliza un CCD (“Charged Coupled Devices”) como detector. Un CCD es un chip pequeño el cual es sensible a la luz. Las cargas electrónicas son desarrolladas en un CCD cuyas magnitudes son proporcionales a las intensidades de radiación impregnada durante un intervalo de tiempo instantáneo (tiempo de exposición). Una línea de estos chips se dispone como un arreglo de una o dos dimensiones. El número de elementos por unidad de longitud determinan la resolución espacial de la cámara. Usando filtros para seleccionar los intervalos de longitud de onda, cada uno asociado con su arreglo CCD, se puede obtener el sensado multibanda. La única desventaja de los sistemas CCD actuales es su limitación para los intervalos visibles y cercano infrarrojo del espectro electromagnético.

Estos satélites se volvieron herramientas muy importantes para el estudio de la Tierra. Como en la fotografía convencional, el nivel de gris de las imágenes indica diferencias en las propiedades ópticas y esto lleva a una diferenciación de los materiales. Mejor aún, resultaron las imágenes obtenidas usando distintos filtros color, que permiten estudiar la atmósfera, los océanos, etc. Esto define el nacimiento de las imágenes multiespectrales que se remontan a los primeros satélites Landsat. Los sensores ya vistos como el Landsat TM o Spot, producen imágenes corregistradas de varios colores discretos o bandas espectrales.

El siguiente avance surge de extender este concepto a cientos de bandas angostas. Estas imágenes reciben el nombre de **hiperespectrales**, y consisten de muestreos continuos de intervalos anchos del espectro. Permiten mejorar la determinación de la

composición a nivel subpixel. Esto significa que aún si un objeto no se puede resolver espacialmente en una escena, su contribución espectral puede ser detectada y mapeada. Las aplicaciones ambientales de sensado remoto como el monitoreo de la deforestación, son mejoradas por las altas resoluciones espectrales que proveen las imágenes hiperespectrales. Las imágenes hiperespectrales nacieron a principios de los 80' con el espectrómetro de imágenes aéreas (Airborne Imaging Spectrometer) y más tarde con el AVIRIS (Advanced Visible and InfraRed Imaging Spectrometer). El salto de imágenes multi a hiperespectrales para sensado remoto requirió de una tecnología diferente de instrumentos.

El primer sensor hiperespectral fue lanzado en 1997 a bordo del satélite Lewis de la NASA. Conteníá 384 bandas que cubrían desde los 0.4 a los 2.5  $\mu\text{m}$ . Pero desafortunadamente, tuvo problemas de control y calló de la órbita a los pocos meses.

### **Naval Earth Map Observer (NEMO)**

Se prevé que para fines del 2001 será lanzado el primer satélite que producirá imágenes hiperespectrales. El NEMO (Naval EarthMap Observer) será capaz de proveer imágenes hiperespectrales y pancromáticas.

Los sistemas de sensado remoto pueden ser categorizados de acuerdo a diferentes criterios:

- Cobertura/ resolución espacial y radio de repetición
- Rango espectral
- Tecnología del sensor

### **Cobertura/ resolución espacial y radio de repetición**

Esto representa el mejor punto de vista del usuario, el cual está mucho más centrado en la variabilidad espacial y temporal del fenómeno a ser observado que en aspectos tecnológicos del proceso de observación.

Los sensores de muy alta resolución espacial se caracterizan por:

- Resolución espacial: tamaño de pixel  $< 10$  m.;
- Cobertura espacial moderada: 10 a 100 km. de ancho de barrido;
- Cobertura temporal moderada: ciclo de repetición de 1 a 3 semanas
- Son principalmente usados en aplicaciones que requieren una observación a escalas locales

Los sensores de resolución espacial baja o sensores de monitoreo se caracterizan por:

- Resolución espacial: tamaño de pixel  $> 2$  km.;
- Cobertura espacial alta: más de 500 km. de ancho de barrido;
- Cobertura temporal alta: ciclos de repetición de menos de tres días.
- Son usados operacionalmente en aplicaciones relacionadas con los procesos altamente dinámicos a escalas continentales a globales, por ejemplo para climatología/meteorología, oceanografía, cambio global terrestre, etc.

### **Rango espectral: sistemas ópticos vs sistemas de radar:**

Las longitudes de onda ópticas se sitúan en el rango que va del espectro visible al infrarrojo. Las longitudes de onda de radar están situadas en el rango de ondas denominadas microondas

Un sensor óptico es un sistema pasivo, que mide la radiancia reflejada por el sol y la radiación emitida por los objetos observados.

Un radar es un sensor activo, el cual emite un flujo de radiación electromagnética (en el rango de las microondas) y detecta las ondas reflejadas por los objetos.

Los sensores pasivos en el rango visible no pueden ver a través de las nubes, mientras que esto es posible para el rango de las microondas. Las imágenes de radar pueden entonces observar la superficie de la Tierra en áreas con cobertura permanente de nubes, y a la noche. Resultan más apropiadas para aplicaciones de los trópicos húmedos.

## ANEXO B:

### Presentación del desarrollo del algoritmo RED

Para el desarrollo del presente algoritmo se utilizó, como se mencionó en capítulos anteriores, el paquete de desarrollo ENVI+IDL. Envi es un sistema de procesamiento de imágenes diseñado para proveer análisis de imágenes pancromáticas, multiespectrales, e hiperspectrales de datos de sensado remoto obtenidos desde satélites o desde aviones. El sistema también incluye un conjunto de herramientas para análisis de imágenes de radar. Está construido con IDL (Interactive Data Language), que es un lenguaje de programación estructurado, y basado en arreglos, que incluye herramientas de análisis de imágenes flexibles. ENVI puede ser extendido utilizando IDL como lenguaje de implementación.

La implementación de RED desarrollada permite incorporar las fuentes y clases con las que se trabaja, capturar las muestras para conformar la base de conocimiento, calcular la frecuencia de distribución, y soporte para las distintas muestras de cada fuente y clase y realizar la clasificación usando el proceso de aprendizaje, clasificar y evaluar los resultados.

A continuación se presenta un pseudocódigo del algoritmo de clasificación:

*Apertura de la imagen a clasificar*

*Visualización de la imagen a clasificar*

*Selección de una región de interés a clasificar*

*Si (el usuario posee conocimiento a priori de la pertenencia de la región a una clase)*

*entonces realizar clasificación RED con proceso de aprendizaje*

*sino realizar clasificación RED*

**{ Clasificación RED con Proceso de Aprendizaje }**

*Asignación de la región o regiones a clasificar a la clase a la que pertenecen*

*Realizar clasificación RED*

*Armar matriz de confusión*

*Calcular el valor de precisión general*

*Si (cant. de regiones > 1)*

*entonces calcular valor del indicador KHAT*

*sino KHAT = precisión general*

*Si (khat < Parámetro de Precisión (**a**))*

*entonces Aprender*

*Mostrar matriz de confusión y resultados*

Parámetro de Precisión = **valor que permite controlar el proceso de aprendizaje, en el caso particular de esta aplicación se quiere tener un valor de khat superior o igual a 0.90, es decir se admite hasta un 10% de error.**

**{ Clasificación RED }**

***Para cada pixel de la región***

*Tomar valor en cada banda*

*Calcular rasgos espectrales*

*Tomar rasgos de textura para el pixel actual*

*Tomar fuente 1*

*Tomar fuente 2*

***Para cada fuente*** tomar los soportes para la muestra en cada clase

*Combinar fuentes usando suma ortogonal de Dempster (fc)*

***Por cada una de las fuentes de información restante***

*Tomar fuente combinada (fc) y soportes resultantes de la misma*

*Tomar primer fuente de la lista de fuentes restantes*

*Combinar fuentes usando suma ortogonal de Dempster (fc)*

*Aplicar **regla de decisión** sobre la última combinación obtenida*

*Devolver la **clase final resultante***

**{ Aprender }**

***Por cada pixel de la región***

*Calcular la información otorgada por cada fuente*

*Buscar en la base de conocimiento la fuente con el valor de muestra correspondiente*

*Si (el valor no existe)*

*entonces incorporar valor a la base*

*sino incrementar la frecuencia de ocurrencia de la muestra*

*recalcular tamaño de muestras para la clase y fuente*

*recalcular soportes*