

# 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. ◆