



Institución Universitaria

Extracción de características de forma para la identificación de firmas espectrales en el procesamiento de imágenes hiperespectrales para aplicaciones de percepción remota

Lina Maria Torres Quiñones

Instituto Tecnológico Metropolitano

Facultad de Ingenierías

Medellín, Colombia

2017

Extracción de características de forma para la identificación de firmas espectrales en el procesamiento de imágenes hiperespectrales para aplicaciones de percepción remota

Lina Maria Torres Quiñones

Tesis o trabajo de investigación presentada(o) como requisito parcial para optar al título
de:

Magister en Automatización y Control Industrial

Directora:

Ph.D. Maria Constanza Torres Madroñero

Línea de Investigación:

Maquinas Inteligentes y Reconocimiento de Patrones

Grupo de Investigación:

Automática, Electrónica y Ciencias Computacionales

Instituto Tecnológico Metropolitano

Facultad de Ingenierías

Medellín, Colombia

2017

Se lo dedico a mis padres por enseñarme la importancia de crecer cada día.

“El único modo de lograr lo imposible es convencerse de que es posible.”

Anónimo

Agradecimientos

Gracias a Dios, porque la oración es el arma más poderosa para volver a retomar fuerzas cuando no las hay. Gracias a mis padres por el apoyo incondicional que me ofrecen día a día. Gracias a mi maestra Phd. Maria Constanza Torres Madroñero por guiarme y orientarme en cada momento, ella me hizo creer que a pesar de todos los títulos también existe la educación. Gracias a todas y cada una de las personas que han estado apoyando dentro y fuera de este ámbito.

Resumen

La percepción remota es un campo de interés en aplicaciones como: observación de la tierra, monitoreo ambiental, minería, agricultura, seguridad y defensa. El creciente interés en este campo ha impulsado el desarrollo de sensores y sistemas remotos con diferentes resoluciones espaciales y espectrales. Ejemplo de estos sistemas son los sensores hiperespectrales, los cuales capturan la energía reflejada y disipada por una superficie a lo largo de cientos de bandas continuas en el espectro electromagnético. En este tipo de imágenes, un pixel es una firma espectral, cuya forma permite la identificación remota de materiales. Sin embargo, la alta resolución espectral de las imágenes hiperespectrales son un gran reto para su procesamiento y análisis a través de técnicas de reconocimiento de patrones, dado la alta correlación de las bandas espectrales. Por esta razón, se hace necesario usar técnicas de reducción de dimensiones en el procesamiento de imágenes hiperespectrales. Las técnicas de reducción de dimensiones encontradas en la literatura, como análisis de componentes principales -PCA, no tienen en cuenta la información proporcionada por la forma de la firma espectral. En este proyecto se exploró el uso de descriptores de forma para obtener un espacio de representación de más baja dimensión para los datos hiperespectrales, teniendo en cuenta la forma de las firmas espectrales. Los descriptores de forma son ampliamente usados en el procesamiento de imágenes digitales para el reconocimiento de objetos. En este proyecto se estudió el uso de los descriptores de Fourier y Wavelet para mejorar la clasificación espectral de imágenes hiperespectrales. Los descriptores fueron evaluados a través de la clasificación de tres imágenes hiperespectrales reales usando clasificadores de máquinas de soporte vectorial (SVM) y análisis discriminante lineal (LDA). La clasificación usando los descriptores de forma se compararon con los obtenidos con PCA. Los resultados muestran que el uso de los descriptores de forma de Fourier y Wavelet permiten mejorar la precisión de clasificación de las imágenes hiperespectrales.

Palabras clave: Imágenes hiperespectrales, percepción remota, clasificación espectral, clasificación espacial-espectral, descriptores de forma.

Abstract

Remote sensing is a field of interest for applications such as: earth observation, environmental monitoring, mining, agriculture, security and defense. The growing interest in this field has promoted the development of remote sensors and systems with several spatial and spectral resolutions. Some of these systems are the hyperspectral sensors, that collect the reflected and emitted energy by a surface along of hundred narrow bands of the electromagnetic spectrum. In these images, a pixel is a spectral signature and its shape allows the remote identification of materials. However, the high spectral resolution of hyperspectral imagery poses a great challenge for its processing and analysis using pattern recognition techniques, due to the high correlation among spectral bands. Thus, it is necessary to use dimensional reduction techniques for hyperspectral image processing. The dimensional reduction techniques, such as principal component analysis (PCA), do not take into consideration the shape of the spectral signatures. This project explores the use of shape descriptors to obtain lower representation space for hyperspectral data taking into account the shape of spectral signatures. Shape descriptors such as Fourier or Wavelet descriptors are widely used in image processing for object recognition, however, their use in hyperspectral image processing has been limited. This project studied the use of Fourier and Wavelet shape descriptors to improve the spectral classification of hyperspectral imagery. Shape descriptors are evaluated by classifying three real hyperspectral images using support vector machine (SVM) and linear discriminant analysis (LDA); Classification results obtained using the shape descriptors are compared with those obtained when PCA is applied. The results show that the Fourier and Wavelet shape descriptors help to improve the classification accuracy of the hyperspectral image.

Keywords: hyperspectral imagery, remote sensing, spectral classification, spatial-spectral classification, shape descriptor

Contenido

1. Introducción	1
1.1 Descripción del problema	2
1.2 Objetivos	3
1.2.1 Objetivo General.....	3
1.2.2 Objetivos Específicos.....	4
1.3 Producción científica y actividades de divulgación	4
1.4 Organización del documento.....	4
2. Estado del arte.....	7
2.1 Percepción remota	7
2.2 Imágenes hiperespectrales	8
2.3 Procesamiento de imágenes hiperespectrales	9
2.3.1 Detección de objetivo	10
2.3.2 Desmezclado.....	10
2.3.3 Clasificación	11
2.4 Clasificación de imágenes hiperespectrales	12
2.4.1 Clasificación espectral	12
2.4.2 Clasificación espacial-espectral	14
2.5 Recomendaciones.....	16
3. Marco Experimental	19
3.1 Bases de datos	19
3.1.1 Indian Pines.....	19
3.1.2 Cuprite.....	21
3.1.3 Kennedy Space Center -KSC	22
3.2 Métodos	23
3.2.1 Descriptores de Fourier	23
3.2.2 Transformada Wavelet.....	26
3.3 Metodología de Clasificación.....	28
4. Resultados y discusión	33
4.1 Clasificación Indian Pines.....	33
4.1.1 Clasificación con SVM	33
4.1.2 Clasificación con LDA.....	37
4.1.3 Discusión	41
4.2 Clasificación Espectral Cuprite.....	42
4.2.1 Clasificación con SVM	42
4.2.2 Clasificación con LDA.....	46
4.2.3 Discusión	49
4.3 Clasificación Kennedy Space Center.....	50

4.3.1	Clasificación con SVM.....	50
4.3.2	Clasificación con LDA.....	54
4.3.3	Discusión.....	57
5.	Conclusiones y recomendaciones	59
5.1	Conclusiones	59
5.2	Recomendaciones	60

1.Introducción

El campo de la percepción remota reúne un conjunto de técnicas no destructivas, no contaminantes y rápidas para el estudio, monitoreo y observación de la Tierra. Utilizando este tipo de tecnología se pueden realizar estudios para: determinar los efectos del cambio climáticos, clasificar la geografía de una región, determinar el comportamiento de cultivos, establecer la presencia de poblaciones y uso de contaminantes, entre otras aplicaciones [1, 2]. Una de las aplicaciones más estudiadas de la percepción remota se encuentra en la agricultura. La agricultura de precisión emplea tecnologías de percepción remota para: clasificar la cubierta vegetal, identificar estrés y estado de salud de plantas, estudiar la erosión de una región a lo largo del tiempo, así como, el estado de lagos, ríos y mares. En general, existe un gran interés en las aplicaciones de percepción remota relacionadas con la calidad del medio ambiente, uso de suelo, urbanismo, seguridad y defensa [3].

La percepción remota obtiene información de objetos o regiones sobre la superficie terrestre utilizando sensores instalados en plataformas aéreas o satelitales. Los sensores remotos pueden ser sensores pasivos o activos [1, 2]. Los sensores activos emiten una señal que, al reflejarse en la superficie terrestre, permite medir ciertas propiedades físicas. Por otra parte, los sensores pasivos miden la energía reflejada o emitida por los objetos en la superficie terrestre a lo largo del espectro electromagnético. Dentro de los sensores pasivos, encontramos los sensores multiespectrales e hiperespectrales. Los sensores multiespectrales adquieren información en decenas de bandas espectrales; en cambio, los sensores hiperespectrales capturan la radiación en cientos de bandas continuas a lo largo del espectro electromagnético. El concepto de imagen hiperespectral se presenta en la Figura 1-1. Estas imágenes se pueden ver como un cubo, con dos dimensiones espaciales y una dimensión espectral. Por lo tanto, cada pixel de la imagen es un vector n -dimensional, donde n es el número de bandas espectrales. Un pixel o vector espectral se puede estudiar como una señal unidimensional denominada firma espectral [4]. Las formas

de las firmas espectrales permiten la identificación del material presente en la superficie sensada.

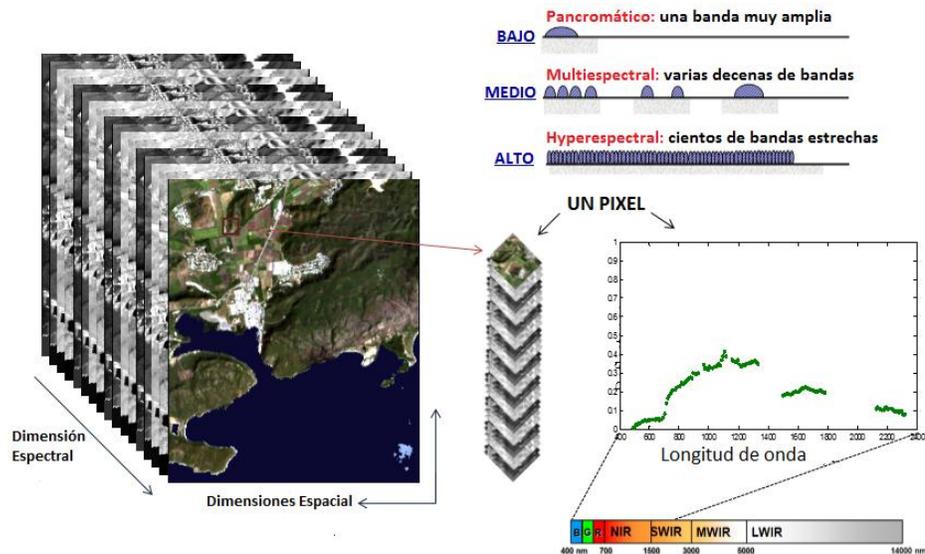


Figura 1-1: Concepto de imagen hiperespectral [5].

El incremento de sensores de percepción remota, su alta variabilidad de características espaciales, espectrales y temporales, y su amplio uso en sectores tan diversos como la agricultura, minería, cartografía, vulcanología, seguridad y vigilancia entre otros, establece varios retos para los investigadores en este campo [6]. Uno de estos retos es la generación de técnicas confiables para la extracción de información a partir de las imágenes de una forma automatizada, que facilite el uso de esta tecnología en los diferentes campos de aplicación.

1.1 Descripción del problema

Un paso importante para la extracción de información de la superficie terrestre desde imágenes hiperespectrales es la clasificación [4, 7]. La clasificación de imágenes identifica los diferentes tipos de materiales asignando etiquetas a cada pixel. La clasificación se puede basar en reglas aprendidas desde un conjunto de muestras etiquetadas (clasificación supervisada) o desde un proceso iterativo basado en criterios de similitud (clasificación no supervisada). La clasificación de imágenes hiperespectrales se puede llevar a cabo usando clasificadores tales como máquinas de soporte vectorial [8].

Particularmente, las imágenes hiperespectrales presentan varios retos para el desarrollo de algoritmos eficientes y confiables de clasificación. Uno de estos retos es la alta dimensionalidad de los datos. Dada la alta resolución espectral de los sensores hiperespectrales, existe una alta correlación entre bandas continuas, lo que dificulta el procesamiento de este tipo de imágenes con técnicas tradicionales de reconocimiento de patrones [1].

Debido a la alta dimensionalidad de los datos hiperespectrales es común emplear técnicas de reducción de dimensiones como un paso previo a la clasificación [9-11]. Una técnica ampliamente usada para reducir el espacio de representación de los datos hiperespectrales es el análisis de componentes principales (PCA) [4, 11]. PCA transforma el espacio de representación de los datos a un nuevo espacio tal que sus componentes no están correlacionadas. La principal ventaja de PCA es que preserva la varianza de una imagen usando pocas dimensiones [2]. Sin embargo, PCA, como la mayoría de técnicas de reducción de dimensiones, no tienen en cuenta la forma de las firmas espectrales. Lo que hace el Análisis de Componentes Principales (PCA) es buscar un nuevo espacio de representación de los datos donde las bandas no están correlacionadas entre ellas, y la mayoría de información va a estar contenida en las primeras bandas.

Dado que es la forma de las firmas espectrales las que permiten la identificación y discriminación remota de materiales, se espera que una técnica de reducción de dimensiones que considere la forma de la firma mejore los resultados de clasificación. Por esta razón, este trabajo explora el uso de descriptores de forma para obtener un nuevo espacio de representación para las imágenes hiperespectrales, donde además de reducir la dimensión de los datos, se preserven las características discriminantes de la forma de la firma espectral. Los descriptores de forma se emplean en el procesamiento de imágenes digitales para la caracterización de siluetas o fronteras en dos dimensiones para el reconocimiento de objetos [12]. En este trabajo se extiende su uso a la representación de firmas hiperespectrales.

1.2 Objetivos

1.2.1 Objetivo General

Desarrollar una metodología para la clasificación de imágenes hiperespectrales teniendo en cuenta tanto la información espacial como la información proporcionada por la forma de las firmas espectrales.

1.2.2 Objetivos Específicos

- Proponer e implementar una metodología para la extracción de descriptores de forma de las firmas espectrales que permitan discriminar de manera más precisa los materiales capturados por imágenes hiperespectrales.
- Diseñar y validar una metodología para incorporar descriptores de forma espectrales en la clasificación de imágenes hiperespectrales.

1.3 Producción científica y actividades de divulgación

A partir de este trabajo de grado se han realizado las siguientes publicaciones:

- Lina M. Torres-Quiñonez, Maria C. Torres-Madronero. Exploration of Fourier Shape Descriptor for Classification of Hyperspectral Imagery. Primer Congreso Internacional de Ciencias de la Tierra y Percepción Remota. 2-4 nov, 2016.

Adicionalmente, se están preparando los siguientes artículos:

- Lina M. Torres-Quiñonez, Maria C. Torres-Madronero. Shape Descriptors for Hyperspectral Image Classification. Para la Revista Tecno Lógicas.

1.4 Organización del documento

En el Capítulo 2 se presenta la revisión del estado del arte en el campo de la percepción remota, haciendo especial énfasis en la clasificación de imágenes hiperespectrales y técnicas de reducción de dimensiones. En el Capítulo 3 se plantea la metodología para el uso de descriptores de forma para la reducción de dimensiones de imágenes hiperespectrales. En el Capítulo 4 se evalúa la metodología de clasificación propuesta con los descriptores de forma a través de la clasificación de tres imágenes hiperespectrales. El

Capítulo 5 presenta las conclusiones de este proyecto y recomendaciones para trabajos futuros.

2.Estado del arte

La percepción remota para aplicaciones de observación de la tierra tuvo un desarrollo significativo a partir del lanzamiento del sensor LANDSAT en 1997 [2]. A partir de ese momento, la percepción remota ha encontrado diferentes campos de aplicación y el desarrollo acelerado de sistemas, técnicas y algoritmos para la adquisición y procesamiento de datos remotos. A continuación, se presenta una revisión del estado del arte sobre la percepción remota, con especial énfasis en la clasificación de imágenes hiperespectrales y la reducción de dimensiones.

2.1 Percepción remota

La percepción remota, o teledetección, consiste en adquirir información de un objeto a través de un dispositivo que no está en contacto directo con dicho objeto [13]. Existen parámetros importantes en un sistema de percepción remota, como lo son: la resolución espectral, espacial, temporal y radiométrica [14]. La resolución espectral se refiere al número de canales que cubren diferentes regiones del espectro electromagnético y su ancho de banda. Por su parte, la resolución temporal se relaciona al tiempo que demora un satélite para pasar por el mismo punto. La resolución espacial se refiere al espacio que cubre cada pixel (tamaño de pixel) de la imagen sobre la superficie terrestre. La resolución radiométrica se relaciona a la sensibilidad del sensor para poder detectar la magnitud mínima de energía electromagnética, esto quiere decir que entre mayor sea la resolución radiométrica, mayor será la capacidad del sensor para poder detectar diferencias de energías entre los objetos captados [14].

En la actualidad podemos encontrar una gran diversidad de sensores remotos tanto activos como pasivos. Los sensores activos usan una fuente de energía interna para generar una señal, midiendo la interacción de la señal con el entorno. Por su parte, los sensores pasivos

detectan señales emitidas por la radiación electromagnética que genera la superficie terrestre o el mismo entorno. Los sensores pasivos tienen la capacidad de poder medir parámetros expresados en diferentes longitudes de onda en extensas áreas espaciales [15].

Dentro de los sensores pasivos encontramos los sensores multiespectrales e hiperespectrales. Los sensores multiespectrales tienen la capacidad de recoger datos en decenas de bandas electromagnéticas. Estas mediciones ayudan a extraer información sobre el medio ambiente. Por ejemplo, los sensores multiespectrales son utilizados para medir los niveles de ozono a través de radiación ultravioleta, estudiar la vegetación como los cultivos y los bosques a través de bandas visibles e infrarrojas, y observar la superficie de los mares con radiación infrarroja [13]. Por otra parte, los sensores hiperespectrales se convirtieron en una herramienta muy importante para el desarrollo de investigaciones sobre la superficie terrestre iniciando la década de los 90. Este tipo de sensores son dispositivos que permiten captar imágenes con cientos de bandas espectrales [13].

2.2 Imágenes hiperespectrales

Cada pixel de la imagen hiperespectral se puede observar como una señal unidimensional, esta señal nos proporciona la firma espectral, la forma de estas firmas espectrales son las que permiten la identificación de los materiales en la superficie que se está censando.

Los sensores hiperespectrales permiten adquirir imágenes digitales en una gran cantidad de bandas, muy cercanas entre sí, a lo largo del espectro electromagnético, capturando en cada pixel una firma espectral [15]. Las firmas espectrales capturadas con sensores hiperespectrales facilitan la identificación y cuantificación de los materiales presentes en el campo de visión del sensor [1, 2]. Con el procesamiento de imágenes hiperespectrales es posible analizar la nieve, los corales, el agua, la vegetación, los ríos, así como fenómenos atmosféricos.

La Tabla 1 presenta ejemplos de sensores hiperespectrales ampliamente usados en aplicaciones de percepción remota. AVIRIS (Airbone Visible/Infra-Red Imaging Spectrometer) es un sensor hiperespectral de la NASA usado principalmente sobre

plataformas áreas; este sensor permite capturar imágenes de 224 bandas espectrales desde la región visible (350nm) hasta el infrarrojo cercano (2500 nm). Los sensores CASI y AISA son sistemas comerciales que capturan datos entre los 400 a 950 nm. Por su parte, el sensor HyPERION es el único sistema hiperespectral sobre una plataforma satelital. Este se encuentra sobre el satélite EO-1 de la NASA. Aunque ya finalizó su ciclo de vida útil, actualmente las imágenes capturadas por este sensor se encuentran disponibles de forma gratuita en la web.

Tabla 2-1: Ejemplo de sensores hiperespectrales

Sensor	Resolución Espacial	Bandas	Referencias
AVIRIS	5.5 m	224 bandas 350 – 2500 nm	Veraverbeke et al. (2014) [16]
HYPERION	30 m	220 bandas 400 – 2500 nm	Pearlman et al. (2003) [17]
CASI	0.5m a 5m	288 bandas 400 – 950 nm	Babey and Anger (1989) [18]
AISA	3.3 m	244 bandas. 400 – 970 nm	Goodenough et al. (2008) [19]

2.3 Procesamiento de imágenes hiperespectrales

En el procesamiento de imágenes hiperespectrales encontramos tres corrientes fundamentales para la extracción de información y análisis de los datos: detección de objetivos, clasificación de imágenes y desmezclado lineal. Cada una de ellas permite extraer información de las imágenes hiperespectrales a diferentes niveles de abstracción [4].

La Figura 2-1 presenta un esquema con la metodología más usada para el procesamiento de imágenes hiperespectrales. La etapa de pre-procesamiento de imágenes hiperespectrales incluye las técnicas para realizar las correcciones atmosféricas, geométricas y radiométricas, así como técnicas de reducción de ruido [2]. La segunda etapa consiste en la reducción de dimensiones, dada la alta correlación que existe entre bandas. Aunque esta etapa es opcional, varios trabajos han demostrado la importancia de la reducción de dimensiones en el procesamiento de imágenes hiperespectrales [1, 2]. La última etapa incluye una de las corrientes de procesamiento: detección de objetivos,

clasificación o desmezclado [4]. A continuación, se describe brevemente cada uno de estos procesos.

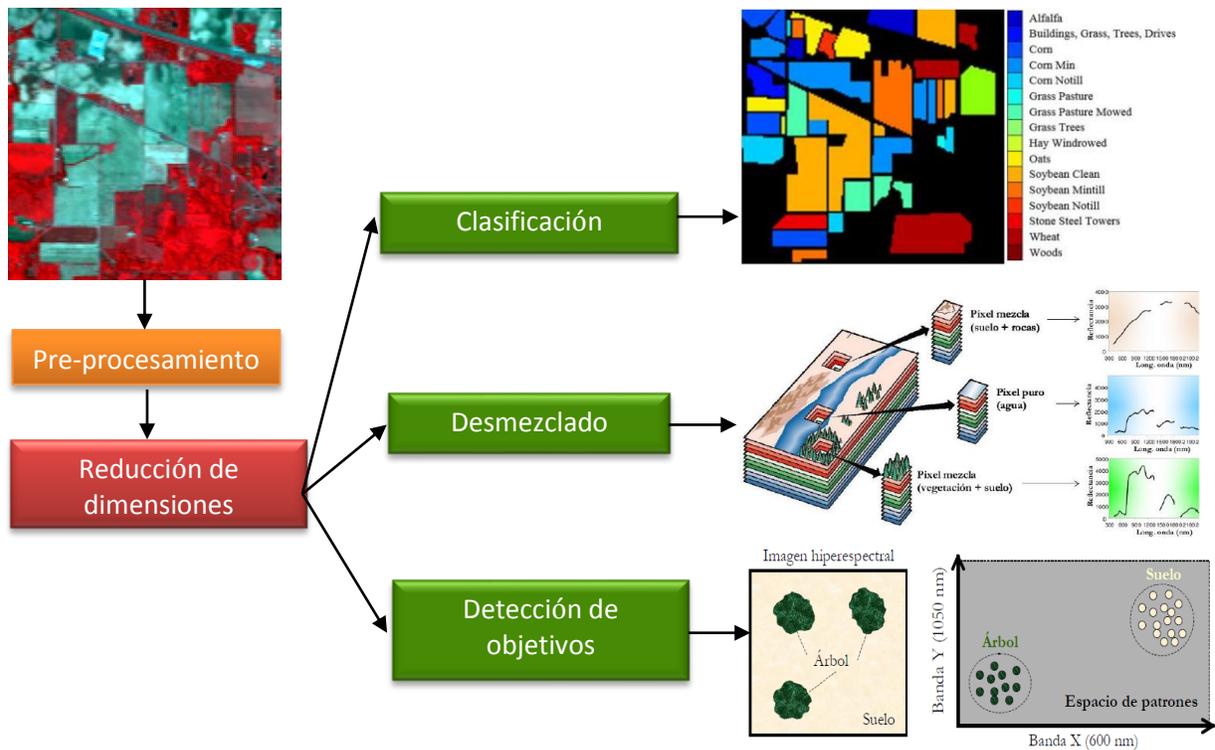


Figura 2-1: Procesamiento imágenes hiperespectrales (Fuente propia).

2.3.1 Detección de objetivo

La detección de objetivos (*target detection*) busca identificar los píxeles de la imagen con una característica espectral específica. Este problema se puede ver como un problema de clasificación binaria, en el cual se tienen la clase *target*, conformada por los píxeles con la firma espectral de interés, y la clase *background*, formada por todos los píxeles con firmas espectrales diferentes al target [20]. Lo ideal en este tipo de problemas es cuando existe una clara separación entre el objeto que se quiere diferenciar (target) y el fondo (background) [4].

2.3.2 Desmezclado

En una imagen hiperespectral podemos encontrar tanto píxeles puros como píxel mezclados. Los píxeles puros corresponden a firmas espectrales de un único material. Los píxeles mezclados son el resultado de la combinación de diferentes materiales, debido a la resolución espacial, características ópticas del sensor o el sensado de superficies no homogénea. Este tipo de píxeles son los más comunes en imágenes hiperespectral. Los píxeles mezclados se pueden descomponer en un conjunto de espectros “puros” denominados *endmembers*. Los modelos de mezclado para imágenes hiperespectrales que se encuentran en la literatura se dividen en dos corrientes: modelos lineales y modelos no lineales. El modelo lineal asume que el píxel mezclado es el resultado de la suma proporcional de los *endmembers* [21-23]. Por su parte, el modelo no lineal de mezcla tiene en cuenta las interacciones que ocurren entre los materiales sensados y la luz [21, 24, 25]. Los algoritmos de desmezclado buscan estimar desde una imagen hiperespectral: el número de *endmembers* o componentes “puros”, las firmas espectrales que representa cada *endmember*, y la proporción de los *endmembers* en cada píxel.

2.3.3 Clasificación

La clasificación asigna una etiqueta a cada píxel de la imagen; esta etiqueta se relaciona con el material u objetos presentes en la imagen. En la literatura se encuentran algoritmos de clasificación que se pueden dividirse en dos grupos [26]: algoritmos de clasificación no supervisada y algoritmos de clasificación supervisada. Los algoritmos de clasificación no supervisado se caracterizan por no usar conocimiento a priori sobre las clases existentes. El objetivo de estas técnicas consiste en identificar, de una manera automatizada, clases o agrupaciones de píxeles, utilizando para ello medidas de similitud [26]. Dentro de los algoritmos de clasificación no supervisados se destacan técnicas como K-means [27]. Por su parte, los algoritmos supervisados se basan en el conocimiento a priori sobre las clases existentes para entrenar un clasificador [26]. Algunas de las técnicas de clasificación supervisadas, que se destacan más por su sencillez y mejor desempeño, son las técnicas como el vecino más cercano (nearest neighbor) [28], distancia mínima (minimum distance) [29] y máxima probabilidad (maximum likelihood ML) [30]. Sin embargo, varios estudios han demostrado la efectividad de clasificadores basados en máquinas de soporte vectorial para la clasificación de imágenes hiperespectrales [8]. En la siguiente sección se presenta en detalle una revisión sobre clasificación de imágenes hiperespectrales.

2.4 Clasificación de imágenes hiperespectrales

La forma como se realiza la clasificación de las imágenes hiperespectrales varía no únicamente con el tipo de clasificador utilizado, sino también con el tipo de información empleada para el proceso de clasificación. Los datos hiperespectrales proporcionan información desde la dimensión espectral, donde cada pixel puede verse como una señal unidimensional con n características espectrales, pero también proporciona información desde la dimensión espacial, donde entra a jugar un papel importante los conceptos de textura, objeto y regiones. Las técnicas de clasificación utilizan de forma independiente o combinada esta información. Por lo cual, en la literatura encontramos clasificadores espectrales y espacial-espectrales [7].

2.4.1 Clasificación espectral

La clasificación espectral toma en consideración únicamente las firmas espectrales que contiene cada pixel de la imagen. Son los métodos más empleados y de mayor desarrollo, debido al auge de técnicas de reconocimiento de patrones para datos multivariados. En este tipo de clasificación no se tiene en cuenta la información espacial; es decir, cada pixel se analiza como una muestra independiente sin relación con sus vecinos. Este tipo de clasificación se caracteriza por incluir una etapa de reducción de dimensiones previa a la clasificación debido al fenómeno de Hughes [31-33]. Métodos de clasificación como ML nos son capaces de clasificar con precisión los datos hiperespectrales dada su alta dimensionalidad. Esto ocurre principalmente porque el número de datos de entrenamiento es pequeño en comparación con el número de bandas espectrales resultando en una mala estimación de medias y varianzas [34]

Dada la alta dimensionalidad de los datos hiperespectrales, es común encontrar en la literatura el uso de técnicas de reducción de dimensiones como una etapa previa a la clasificación [34-44]. Una de las técnicas más representativas en esta etapa es el análisis de componentes principales -PCA [10]. PCA permite obtener una representación compacta

donde las bandas espectrales se encuentran no correlacionadas [10]. Otro método empleado en el pre-procesamiento es la fracción mínima de ruido –MNF [35]. MNF emplea tanto la matriz de covarianza de la señal como la matriz de covarianza del ruido. MNF realiza una descripción más detallada de la cantidad de información presente en la imagen y la cantidad de ruido, al mismo tiempo esta técnica es más robusta y menos sensible a píxeles ruidosos [35]. Por otra parte, se ha explorado el uso de análisis de componentes independientes (*independent component analysis* -ICA) para la reducción de dimensiones de imágenes hiperespectrales. Wang and Chang [36] demuestran su efectividad en comparación con PCA y MNF. A diferencia de PCA y MNF que usan la magnitud de los valores propios para organizar las componentes, ICA no presenta un criterio único. Wang and Chang [36] usan la dimensión virtual (*virtual dimensionality* -VD) propuesta en [37] para ordenar las componentes independientes y seleccionar un espacio de baja dimensión. También se ha explorado el uso de la transformada Wavelet para extracción de características de los datos hiperespectrales [38-39]. Bruce et al. [39] presentan un estudio para la extracción de características de imágenes hiperespectrales usando diferentes familias de wavelets; en este trabajo concluyen que los coeficientes en las escalas más altas logran mejorar la discriminación de las clases, sin embargo, los resultados dependen de la selección de la familia de wavelets.

En la literatura, también se encuentran métodos de reducción de dimensiones que usan conocimiento a priori sobre los datos para encontrar un nuevo espacio de representación donde las clases sean más separables, es decir, métodos de reducción de dimensiones supervisados. Entre los primeros métodos que siguen este enfoque para el procesamiento de imágenes hiperespectrales se encuentra la técnica de proyección a un sub-espacio ortogonal (OSP, por las siglas en inglés de orthogonal subspace projection) introducida por Harsanyi & Chang [9]. En la literatura también se encuentran extensiones de métodos como LDA (Linear Discriminant Analysis) para la reducción de dimensiones y clasificación de imágenes hiperespectrales [40], así como derivaciones de esta técnica. Por ejemplo, Li et al. [41] introducen el análisis discriminante de Fisher local (LFDA) que permite la reducción de dimensiones de datos hiperespectrales asumiendo que cada firma espectral es el resultado de una mezcla de Gaussianas. Recientemente, se han introducido técnicas de reducción de dimensiones basadas en aprendizaje de manifold [40]. Estos métodos de reducción de dimensiones buscan un espacio de representación de baja dimensión tal que las clases en la imagen sean más separables, teniendo en cuenta una relación local lineal

de los píxeles enmarcada en un manifold no lineal global [40]. Algunos métodos basados en aprendizaje de manifold son: ISOMAP [42], LLE (locally linear embedding) [42], LE (Laplacian eigenmap) [44] y DML (discriminative manifold learning) [40].

Adicionalmente, se encuentran en la literatura el uso de métodos de selección de características para la reducción de dimensiones de datos hiperespectrales. Pal et al. [34] demostró que el número de características empleadas para la clasificación de imágenes hiperespectrales es importante. Las técnicas de selección de características más empleada en el procesamiento de imágenes hiperespectrales son los métodos basados en la selección de un subconjunto de bandas (BSS, *band subset selection*). Esta técnica selecciona el subconjunto de bandas que maximiza la separabilidad de las clases [45].

Una vez realizada la etapa de pre-procesamiento, es posible emplear las técnicas de clasificación de datos multivariantes en el procesamiento de imágenes hiperespectrales. En este tipo de clasificación se asume que cada pixel es un dato n-dimensional, donde cada dimensión corresponde a una banda espectral. Los métodos más empleados para la clasificación de imágenes hiperespectrales son los basados en máquinas de soporte vectorial (*Support vector machines* o SVM) [8, 46], por su facilidad para trabajar con datos de alta dimensión. SVM consiste en construir un hiperplano tal que maximice la distancia de separación de dos conjuntos de datos. SVM se basa en un proceso de optimización que busca obtener los vectores de soporte para definir límites en las clases. Una característica importante de este método es su facilidad para adaptarse a problemas no lineales a través de funciones kernel [8].

2.4.2 Clasificación espacial-espectral

La necesidad de métodos de clasificación que usen tanto la información espacial como espectral se ha establecido por varios investigadores [47-49, 7]. Para la clasificación espectral-espacial de las imágenes hiperespectrales existen diferentes métodos que se pueden agrupar en métodos basados en morfología [50-52], kernels espaciales [53-55], segmentación [56-59] y representación multiescala [60, 61], las cuales se describen con más detalle a continuación.

La morfología matemática es una herramienta de procesamiento digital de imágenes empleada para la representación y descripción de regiones [12]. Las operaciones básicas para la morfología matemática son la dilatación y la erosión, inicialmente definidas para imágenes binarias. A través de estas técnicas se obtiene un conjunto de características que son usualmente empleadas en procesos de clasificación. Con el desarrollo de los perfiles morfológicos se logró extender el uso de estas técnicas para la clasificación de imágenes remotas [50]. Por ejemplo, en [50] se emplea un conjunto de componentes principales de una imagen hiperespectral para obtener los perfiles morfológicos, estos perfiles se obtienen al aplicar varias operaciones de apertura y cierre con diferentes tipos y tamaños de elementos estructurales. Una vez se construyen los perfiles morfológicos, estos son empelados en la clasificación de los datos hiperespectrales usando métodos como redes neuronales [50] y SVM [51].

Jimenez-Rodriguez y Rivera-Medina [53] introducen el contexto espacial de un pixel para mejorar los resultados de clasificación espectral. Este método emplea un vecindario para medir el grado de homogeneidad de los resultados de clasificación. Por otra parte, en [54] se introduce el uso de kernel espaciales para la clasificación de imágenes hiperespectrales. Camps-Valls y Gomez-Chova [54] exploran el uso de múltiples kernels para mejorar la clasificación de imágenes hiperespectrales. Adicional a la información espectral del pixel se incluye en la clasificación características relacionadas con la textura. En [55] la información espacial de un pixel es modelada como un conjunto de componentes conectado y caracterizada por el valor promedio; esta información se introduce a un clasificador SVM usando métodos kernel. En [54] logran obtener una mejora del 4% empleando esta técnica.

Otra forma de tener en cuenta la información espacial en la clasificación de imágenes hiperespectrales es a través de la segmentación, la cual consiste en separar o partir la imagen en partes homogéneas y disjuntas en términos de un conjunto de características de los píxeles de la imagen que permitan discriminar unas regiones de otras [12]. Métodos como crecimiento de regiones [53], agrupamiento [57] y árboles de partición binario [58] son empleados para la segmentación de imágenes hiperespectrales y su clasificación.

Otra de las técnicas para la clasificación espacial-espectral es la representación multiescala. Duarte et al. [60] introducen el uso de una representación multiescala obtenida

por la solución sistemática de una ecuación diferencial parcial no lineal. En [61] se realiza una comparación de este método de clasificación y la obtenida por los árboles binarios de partición propuestos en [58], y se logra demostrar que la representación multiescala incrementa la precisión de la clasificación de imágenes hiperespectrales.

2.5 Descriptores de forma

La forma digital ha tomado gran importancia y esto no es ajeno en las imágenes, de las cuales se ha investigado y se ha ido recolectando cierta variedad de base de datos, en las imágenes se tienen en cuenta diferentes características, como la forma. Podemos encontrar en la literatura gran variedad de información sobre técnicas de descripción de forma [64].

Una de las características claves para poder conocer e identificar el contenido de una imagen es por su forma. No obstante, no es fácil la descripción de la forma de una imagen, esto ocurre debido a que cuando un objeto es proyectado en tres dimensiones reales a un plano de dos dimensiones, una dimensión de la información del objeto se pierde [64]. Debido a esto la forma que se extrajo de esa imagen, representa solo una parte del objeto que se proyectó, en ocasiones también influye la distorsión y el ruido del medio en donde se esté trabajando. Por lo mencionado anteriormente, un Descriptor de forma, debe de tener ciertas propiedades para lograr la mayor eficacia en los resultados que se quieren conseguir, como lo son: una buena precisión en la obtención de los datos.

Dentro de las técnicas de descripción y representación de forma, encontramos dos clases de métodos de descriptores: basados en contornos y en regiones, dentro de cada clase podemos localizar métodos estructurales y métodos globales, cuando hablamos de métodos estructurales nos basamos solamente en partes o segmentos, cuando se habla de métodos globales, es cuando la forma representa un todo de la imagen [64].

2.6 Recomendaciones

Dada la importancia de la etapa de reducción de dimensiones para la clasificación de imágenes hiperespectrales, se evidencia en la literatura la necesidad de proponer nuevos

métodos, robustos y eficientes, para encontrar espacios de representación de baja dimensión, donde los clasificadores obtengan un mejor desempeño. Como se presentó en la sección anterior, la mayoría de técnicas de reducción de dimensiones empleadas en imágenes hiperespectrales son técnicas propuestas en el campo de reconocimiento de patrones, y, por tanto, no tienen en cuenta la naturaleza de las imágenes hiperespectrales. En este trabajo se propone una nueva metodología de reducción de dimensiones de imágenes hiperespectrales teniendo en cuenta la forma de la firma espectral, ya que es desde la forma que un sistema de percepción remota puede discriminar e identificar materiales sobre la superficie terrestre.

3. Marco Experimental

La reducción de dimensiones se reconoce como un paso importante para la clasificación de imágenes hiperespectrales, dado la alta correlación de las bandas. Sin embargo, se estableció en la revisión de literatura que no existen métodos de reducción que tengan en cuenta la información proporcionada por la forma de las firmas espectrales. Por esta razón este proyecto de tesis exploró el uso de descriptores de forma para obtener un espacio de representación de baja dimensión que mejore la clasificación de imágenes hiperespectrales. A continuación, se describen las imágenes hiperespectrales reales usadas para el desarrollo experimental de este proyecto, así como la fundamentación teórica de los dos descriptores de forma empleados: descriptores de Fourier y Wavelet; finalmente, se presenta la metodología de clasificación empleada para evaluar los descriptores de forma.

3.1 Bases de datos

Para el desarrollo de la investigación se emplearon las imágenes hiperespectrales que se presentan a continuación. Estas imágenes se seleccionaron porque: (1) son ampliamente usadas por la comunidad de percepción remota para la validación de métodos de clasificación; y (2) estas imágenes, así como sus mapas de clasificación de referencia, se encuentran disponibles en internet de forma gratuita, lo cual permite realizar un análisis cuantitativo del desempeño de la metodología propuesta.

3.1.1 Indian Pines

Indian Pines es una imagen hiperespectral capturada por el sensor AVIRIS el 12 de junio de 1992, sobre un área agrícola que se encuentra a 6 km al oeste de West Lafayette. La Figura 3-1 muestra una composición RGB de la imagen Indian Pines usando las bandas 47, 24 y 14. Esta imagen contiene 145 x 145 píxeles y 220 bandas espectrales en el rango

de 400-2500 nm. Para este trabajo se usaron 200 bandas que resulta de eliminar las bandas de absorción de agua: 104 a 108, 150 a 163 y la banda espectral 220. El mapa de clasificación de esta imagen se muestra en la Figura 3-2. El mapa de clasificación incluye 16 clases con diferentes cultivos de maíz y soya. Los datos hiperespectrales y el mapa de clasificación se encuentran disponibles en la página web: <https://engineering.purdue.edu/~biehl/MultiSpec/hyperspectral.html>.

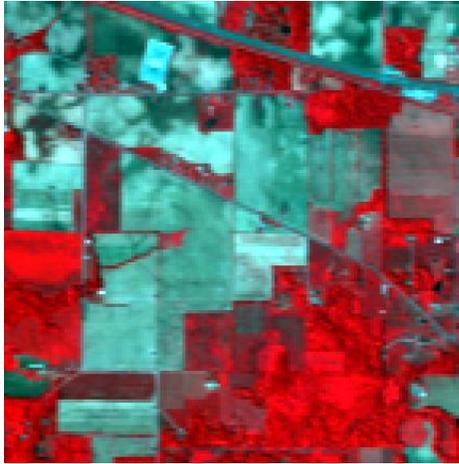


Figura 3-1: Composición RGB Indian Pines (bandas de 47, 24 y 14)

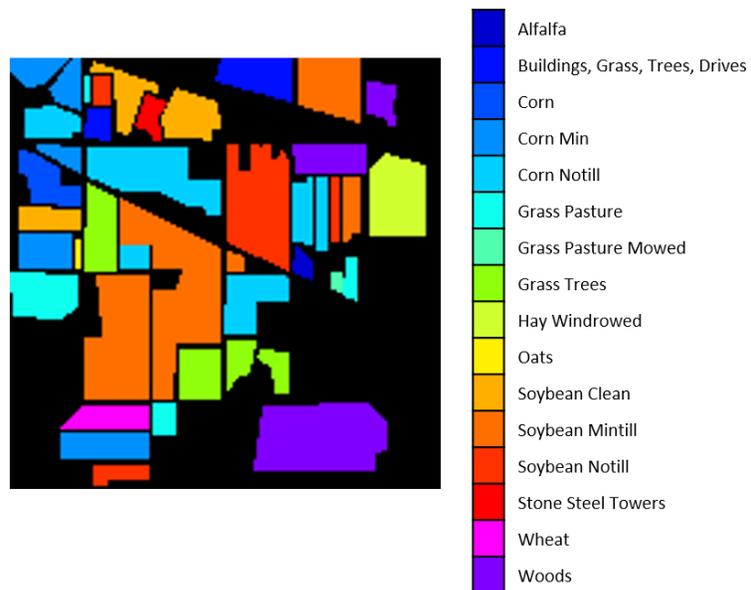


Figura 3-2: Mapa de clasificación Indian Pines

3.1.2 Cuprite

La imagen Cuprite fue capturada sobre el distrito minero a 2 km al norte de Nevada (USA), con el sensor AVIRIS, en 1995. Los datos se encuentran disponibles online (<ftp://ftpext.cr.usgs.gov/pub/cr/co/denver/speclab/pub/cuprite/>). La imagen tiene 224 bandas y una resolución espacial de 20 metros. La Figura 3.3(a) muestra una composición RGB de la imagen empleando las bandas 183, 193 y 207. El mapa de clasificación reportado por el USGS se muestra en la Figura 3.3(b). Para este trabajo se utilizaron 138 bandas y 400x400 píxeles. Las bandas entre 400 a 1300 nm y 2009 a 2507 nm (bandas 4 a 90 y 174 a 224 respectivamente) son usadas en este trabajo. Se ha demostrado que estas longitudes de onda permiten la identificación de minerales y este estudio fue realizado en (<http://speclab.cr.usgs.gov/map.intro.html>). Para la clasificación de la imagen Cuprite se usaron 10 clases, las cuales se muestran en la Figura 3-4.

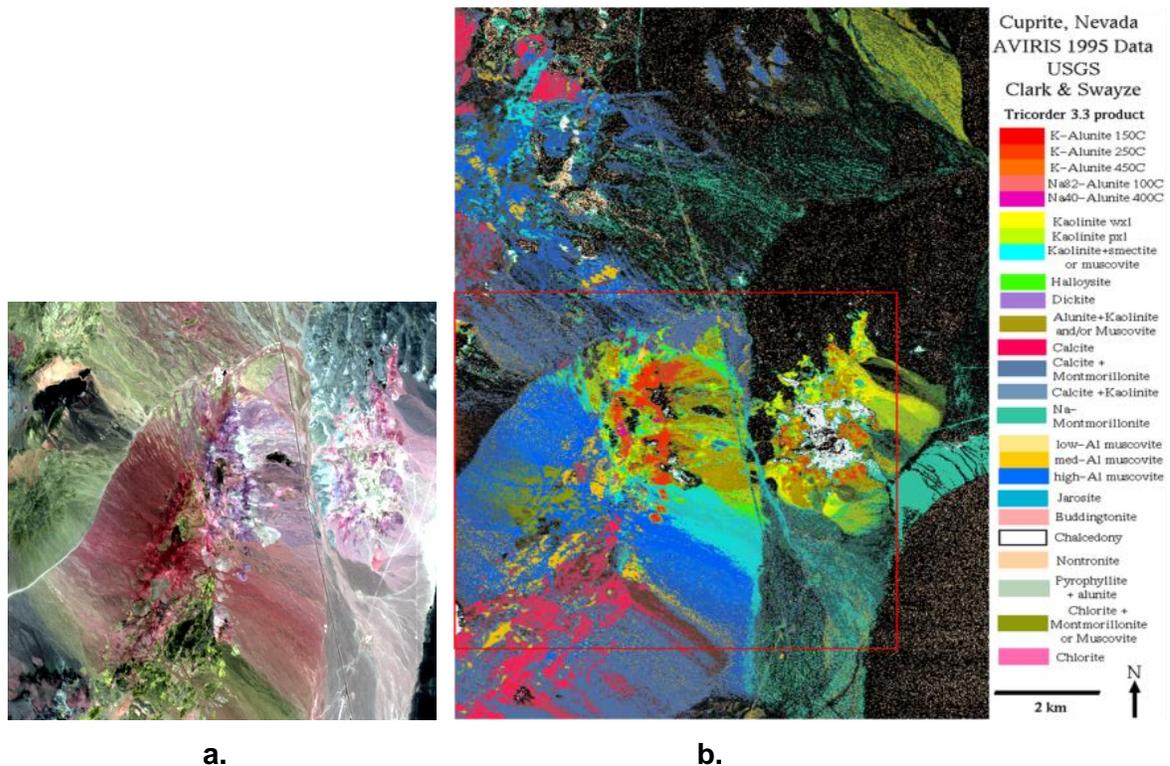


Figura 3-3: Imagen Cuprite (a) Composición RGB (bandas de 183, 193, y 207) y (b) Mapa de Clasificación Cuprite.

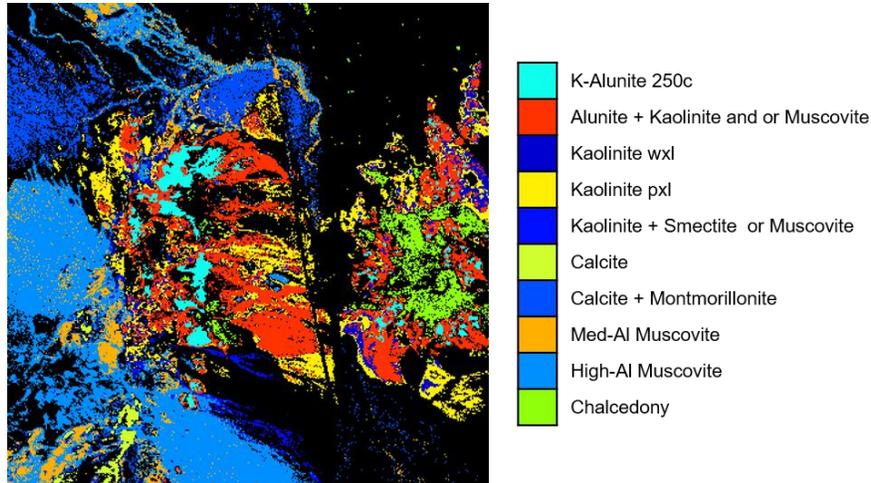


Figura 3-4: Mapa de Clasificación Cuprite 10 clases.

3.1.3 Kennedy Space Center -KSC

La imagen KSC fue capturada sobre el Centro Espacial Kennedy, Florida (USA), por el sensor AVIRIS, el 23 de marzo de 1996. La imagen fue capturada a una altitud de 20 km, permitiendo una resolución espacial de 18 metros. La imagen KSC está disponible online (http://www.ehu.eus/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes) y tiene 176 bandas obtenidas después de remover las bandas de absorción y 512x614 píxeles. La Figura 3-5 presenta la composición RGB de la imagen usando las bandas 30, 20 y 9; la Figura 3-6 muestra su mapa de clasificación.

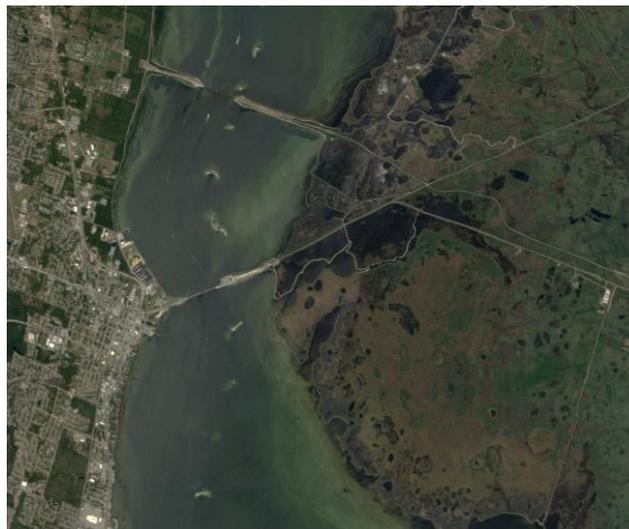


Figura 3-5: Composición RGB (bandas de 30, 20, y 9) Imagen KSC.

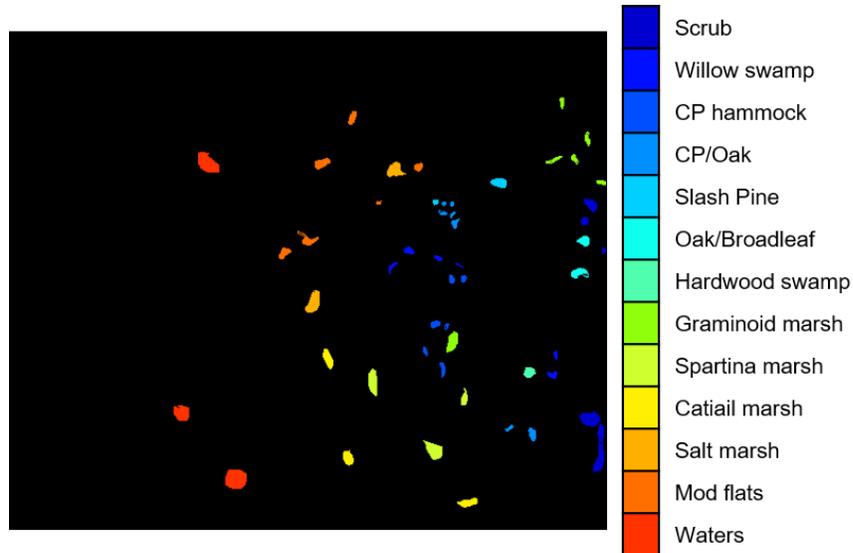


Figura 3-6: Mapa de Clasificación KSC 13 clases.

3.2 Métodos

El reconocimiento de objetos en visión por computador hace uso de representaciones de forma que son invariantes a transformaciones de traslación, rotación y escalamiento. Los descriptores de forma se clasifican en dos categorías: descriptores basados en la frontera y basados en las regiones [62, 63]. Entre los descriptores basados en la frontera se destaca los descriptores de forma [63], los cuales emplean la transformada de Fourier de la frontera como descriptor. En este proyecto se extiende el concepto de descriptores de forma para proponer una metodología de reducción de dimensiones de imágenes hiperespectrales teniendo en cuenta la forma de las firmas espectrales, dado que es la forma la que permite la discriminación de los materiales presentes en una superficie u objeto. En la siguiente sección se describe la extensión de descriptores de Fourier para firmas espectrales. De igual forma, se explora el uso de la transformada Wavelet como descriptor de forma de las firmas espectrales.

3.2.1 Descriptores de Fourier

Dado que la forma de una firma espectral permita la identificación remota de materiales y los descriptores de Fourier caracterizan las formas de siluetas en dos dimensiones, se

espera que al usar descriptores de Fourier se pueda encontrar un espacio de representación de baja dimensión donde se preserve la información de la firma espectral relacionada con su forma.

Para calcular los descriptores de forma de Fourier de una firma espectral se asume que esta firma es una silueta en dos dimensiones. Por tanto, cada punto de la firma espectral se puede ver como un par de coordenadas (x, y) , donde el eje x corresponde al número de las bandas y el eje y a la reflectancia. Esta interpretación de la firma espectral se ilustra en la Figura 3-7.

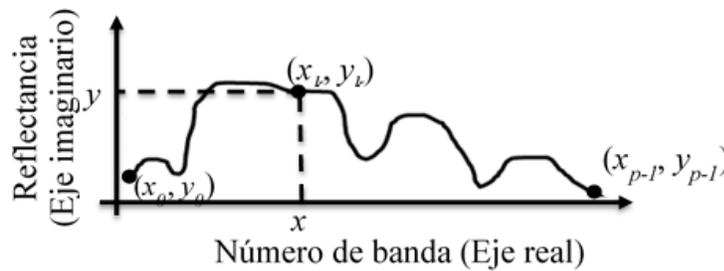


Figura 3-7: Concepto descriptores de Fourier para firmas espectrales.

Cada par de coordenadas (x, y) se puede representar como un número imaginario $z = x + yi$. De esta manera, a partir de un pixel con p bandas espectrales se forma una secuencia de números complejos $s = \{(x_0, y_0), \dots, (x_k, y_k)\}$ donde $k = 0, 1, \dots, p-1$. Para obtener los descriptores de forma de Fourier se calcula la transformada discreta de Fourier -DFT de la secuencia compleja s [12].

Dado p puntos consecutivos s_k , $0 \leq k \leq p-1$, la transformada discreta de Fourier -DFT S_l , $0 \leq l \leq p-1$, está definida como:

$$S_l = \sum_{k=0}^{p-1} S_k e^{-j \frac{2\pi}{p} kl}$$

Los descriptores de forma de Fourier se definen como la magnitud de los coeficientes $|S_l|$ [12].

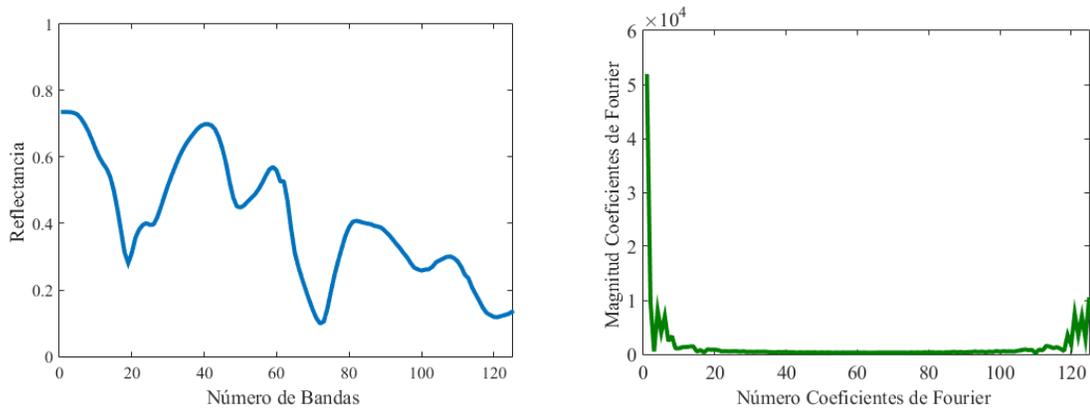


Figura 3-8: Concepto descriptores de Fourier: (a) firmas espectrales y (b) coeficientes de Fourier.

En la Figura 3-8 se presenta un ejemplo de los coeficientes de Fourier (Figura 3-8b) para una firma espectral (Figura 3-8a). La magnitud de estos coeficientes es simétrica, por lo que se obtienen magnitudes mayores a cero al principio y al final de la Figura 3-8b. Se observa que los primeros coeficientes de Fourier son los que van a tener la mayor amplitud. Por lo tanto, en este trabajo suponemos que esos coeficientes son los que van a guardar la información suficiente para representar la forma de la firma espectral.

Es importante anotar que, aunque los descriptores de forma de Fourier son ampliamente usados para el reconocimiento de objetos en visión por computador, no se conoce hasta el momento su uso en imágenes hiperespectrales. En este proyecto se extiende su uso para encontrar un espacio de representación de baja dimensión para datos hiperespectrales. Este espacio de representación se obtiene al seleccionar los primero m descriptores de Fourier.

En el Capítulo 4 se presentan experimentos con imágenes reales que demuestran la capacidad de los descriptores de Fourier para representar datos espectrales y mejorar la clasificación, de igual forma, en el Capítulo 4 se estudia el efecto del número de descriptores sobre la precisión de clasificación de datos hiperespectrales.

3.2.2 Transformada Wavelet

El análisis espectral de una señal por medio de la transformada de Fourier proporciona una descripción de las frecuencias en la forma de onda, pero no proporciona información sobre el tiempo en el cual ocurren esas frecuencias. La transformada Wavelet – WT (*Wavelet Transform*) obtiene una representación multiresolución en tiempo y frecuencia que facilita el análisis de señales unidimensionales.

Dada una firma espectral s , el primer nivel de la transformada Wavelet se obtiene aplicando un filtro pasa baja ($h(n)$) y un filtro pasa altas ($g(n)$). Después del filtro, cada señal queda con la mitad de la frecuencia por eso se puede sub-muestreadas a la mitad se realiza con Nyquist. Por tanto, en este nivel se tiene dos señales, los datos que resultan del filtro pasa altas se denominan coeficientes de detalle y los datos que resultan del filtro pasa bajas se denominan coeficientes de aproximación. La Figura 3-8 presenta gráficamente el procedimiento para calcular la transformada Wavelet discreta. A partir de los coeficientes de aproximación se obtienen otros niveles de representación, repitiendo sucesivamente el mismo procedimiento.

En este trabajo, usamos la WT para obtener una nueva representación de los datos hiperespectrales. Esta transformación se calcula para cada pixel de la imagen, es decir, no se emplea la información espacial, se analiza cada pixel como una señal unidimensional. Los coeficientes de detalle de una firma espectral proporcionan información sobre los componentes de alta frecuencia y los coeficientes de aproximación capturan la información sobre componentes de baja frecuencia.

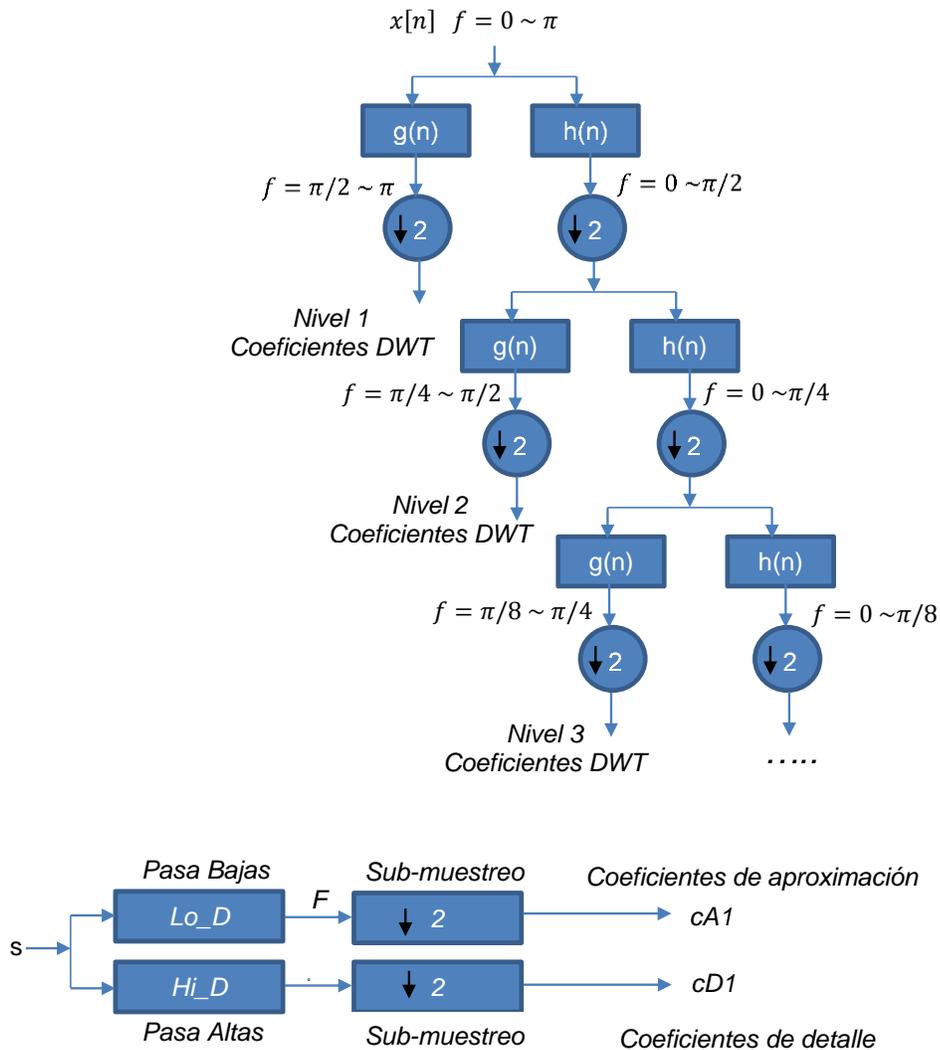


Figura 3-9: Transforma Wavelet discreta.

En este proyecto extendemos el uso de la transformada Wavelet para obtener un descriptor de forma de las firmas espectrales. Trabajos previos han empleado WT en el procesamiento de imágenes hiperespectrales, principalmente para la extracción de características. Por ejemplo, en [38,39] obtienen la transformada Wavelet de cada pixel y luego usan un algoritmo de selección de características para determinar que coeficientes permiten una mejor discriminación de las clases. En este trabajo, usamos las características capturadas en los coeficientes de aproximación para describir la forma de las firmas espectrales. Dado que es en los coeficientes de aproximación que se captura la información de los componentes de baja frecuencia, por tanto, se puede usar estos

coeficientes como una representación de la forma en una baja dimensión. En el siguiente capítulo exploramos esta suposición usando dos tipos de familia de wavelets y tres niveles de descomposición.

3.3 Metodología de Clasificación

La metodología que se propone para la clasificación de imágenes hiperespectrales usando los descriptores de Fourier se presenta en la Figura 3-9. Desde una imagen hiperespectral I se obtiene la representación en coordenadas (x, y) , donde x es el número de las bandas y y es la reflectancia. Para obtener esta representación se organiza la imagen en una matriz de dos dimensiones, con el número de píxeles por el número de bandas. Cada firma espectral corresponde a y en las coordenadas (x, y) , y x es un vector con el número de bandas. A partir de estas coordenadas se construye el conjunto de números complejos y se calcula su respectiva transformada discreta de Fourier. Para obtener los descriptores se requiere definir cuantos coeficientes se usarán en la etapa de reducción de dimensiones. Para este proyecto se evaluó el nuevo espacio de representación con diferentes números de descriptores de Fourier. Para las tres imágenes se compararon las representaciones obtenidas a partir de 5 a 50 descriptores de Fourier, en incrementos de 5. Una vez se obtienen la representación de las imágenes por los descriptores de Fourier se procede con la etapa de clasificación (ver Figura 3-9). Para el cálculo de los descriptores de Fourier se usó el algoritmo rápido de la transformada de Fourier (fft) disponible en Matlab.

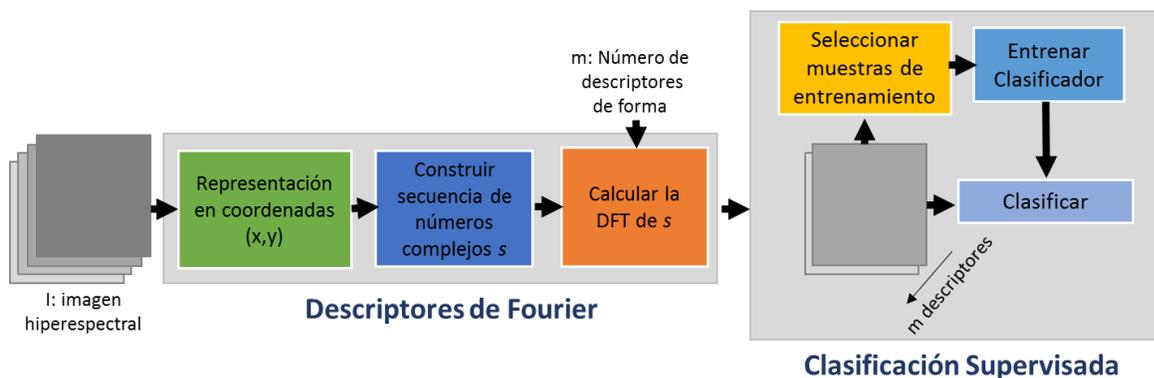


Figura 3-10: Metodología de clasificación usando descriptores de Fourier.

La metodología que se emplea para la clasificación de imágenes hiperespectrales usando los descriptores de forma Wavelet se presenta en la Figura 3-10. En este caso, se calcula

la transformada discreta Wavelet -WT para cada pixel de la imagen hiperespectral. Esta transformada corresponde a la transformada unidimensional. Una vez se obtienen los coeficientes de aproximación y de detalle, se emplean los coeficientes de aproximación en el último nivel como los descriptores de forma (m descriptores) (ver Figura 3-10). Para este trabajo se exploró el uso de dos familias de Wavelet: Daubechies y Coiflets y se realizaron experimentos con 1, 2 y 3 niveles de descomposición. También se realizaron experimentos con 4 y 5 niveles de descomposición, pero la señal se perdía no obteniendo ningún coeficiente. Para el cálculo de los descriptores de forma de Wavelet se usó la función `wavedec` disponible en Matlab. Una vez calculado los coeficientes Wavelet se seleccionan únicamente los coeficientes de aproximación en el último nivel para construir el nuevo espacio de representación y proceder con la etapa de clasificación.

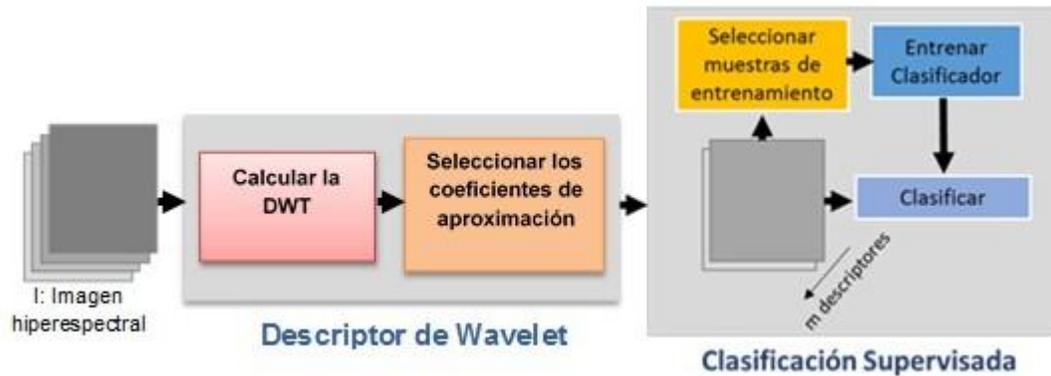


Figura 3-11: Metodología de clasificación usando descriptores Wavelet.

Para evaluar el nuevo espacio de representación para imágenes hiperespectrales a partir de descriptores de forma se usó una clasificación supervisada. Se realizó la clasificación tanto de la imagen original y las imágenes obtenidas a partir de los métodos de reducción de dimensiones basados en análisis de componentes principales (PCA), descriptores de Fourier, y transformada Wavelet. Para la clasificación de las imágenes se usó un clasificador discriminante lineal (*linear discriminant analysis* – LDA) y un clasificador de máquinas de soporte vectorial (*support vector machine* -SVM) con un kernel polinomial de segundo grado. El primer clasificador se seleccionó debido a su simplicidad y dado que varios trabajos han demostrado que el desempeño de este clasificador es afectado por la alta dimensionalidad de los datos hiperespectrales. El clasificador SVM se seleccionó dado que es la técnica de preferencia para el procesamiento de imágenes hiperespectrales. Los

parámetros de los clasificadores se seleccionaron experimentalmente. Es importante anotar, en este trabajo se usa los clasificadores como herramientas para comparar los métodos de reducción de dimensiones propuestos. Por tanto, la optimización de estos parámetros se puede considerar como un trabajo futuro.

Por su parte, los descriptores de forma propuestos en este trabajo se comparan con PCA, dado que es la técnica no supervisada de más amplio uso para la reducción de dimensiones de imágenes hiperespectrales. Para el clasificador discriminante lineal se usó la función `classify` disponible en el toolbox de estadística y aprendizaje de máquinas de Matlab. Para el clasificador SVM se usaron las funciones `fitcecoc` y `predict` también disponibles en Matlab. Por último, para el cálculo de las componentes principales se empleó la función `princomp`. El número de componentes principales para reducir las dimensiones de las imágenes hiperespectrales se varió de la misma manera que el número de descriptores de forma.

Para el entrenamiento de los clasificadores se usó el 10% de las muestras disponibles de cada clase. Se definió este porcentaje dado el bajo número de muestras de entrenamiento a la cual se tiene acceso en el procesamiento de imágenes hiperespectrales. Las Tablas 3-1 a 3-3 presentan el número de muestras de entrenamiento por clase para cada imagen hiperespectral. Se puede observar que Indian Pines tiene un bajo número de muestras etiquetadas para las clases *alfalfa*, *grass pasture mowed* y *soybean notill*. En el caso de la imagen Cuprite, todas las clases tiene un número considerable de muestras de entrenamiento. Por su parte, para la imagen KSC tiene un bajo número de píxeles etiquetados, sin embargo, en la mayoría de las clases se usan más de 20 muestras de entrenamiento, excepto para las clases *Harwood Swamp* y *Slash Pine*. Las Tablas 3-1 a 3-3 también presentan la etiqueta con las cuales se referenciarán cada clase en la presentación de resultados. Para observar el desempeño del clasificador se usó el 90% de píxeles restantes como muestras de evaluación y se calcularon las matrices de confusión. En el siguiente capítulo se presentan los resultados obtenidos al clasificar la imagen original, la imagen obtenida desde PCA, descriptores de Fourier (DF) y descriptores Wavelet (WT).

Tabla 3-1: Número de muestras de entrenamiento para Indian Pines.

	Etiqueta	Clase	Muestras de entrenamiento	Total de muestras de evaluación
1	A	Alfalfa	5	54
2	B	Corn-notill	38	380
3	C	Corn-min	23	234
4	D	Corn	83	834
5	E	Grass pasture	143	1434
6	F	Grass trees	50	497
7	G	Grass pasture mowed	3	26
8	H	Hay windrowed	75	747
9	I	Oats	49	489
10	J	Soybeans notill	2	20
11	K	Soybeans min	61	614
12	L	Soybean clean	247	2468
13	M	Wheat	97	968
14	N	Woods	10	95
15	O	Bldg grass trees drives	21	212
16	P	Stone Steel towers	129	1294

Tabla 3-2: Número de muestras de entrenamiento para Cuprite.

	Etiqueta	Clase	Muestras de entrenamiento	Muestras de evaluación
1	A	K-Alunite 250 c	351	3513
2	B	Alunite+Kaolinite or muscovite	1424	14236
3	C	Kaolinite wxl	271	2706
4	D	Kaolinite pxl	886	8856
5	E	Kaolinite + Smectite or muscovite	168	1677
6	F	Calcite	91	913
7	G	Calcite + Montmorillonite	828	8276
8	H	Med-al Muscovite	570	5702
9	I	High-al Muscovite	2256	22560
10	J	Chalcedony	355	3552

Tabla 3-3: Número de muestras de entrenamiento para Kennedy Space Center -KSC.

	Etiqueta	Clase	Muestras de entrenamiento	Muestras de evaluación
1	A	Scrub	76	761
2	B	Willow swamp	24	243
3	C	CP Hammock	26	256
4	D	CP/Oak	25	252
5	E	Slash Pine	16	161
6	F	Oak/Broadleaf	23	229
7	G	Hardwood swamp	11	105
8	H	Graminoid marsh	43	431
9	I	Spartina marsh	52	520
10	J	Catiai marsh	40	404
11	K	Salt marsh	42	419
12	L	Mod flats	50	503
13	M	Water	93	927

4. Resultados y discusión

En este capítulo se presentan los resultados de clasificación de las imágenes Indian Pines, Cuprite y KSC usando un clasificador discriminante lineal (LDA) y un clasificador de máquinas de soporte vectorial (SVM). En estos experimentos buscamos validar la metodología propuesta en las Figuras 3-9 y 3-10. Se presentan los resultados de clasificación tanto de los datos originales, es decir datos sin ningún tipo de reducción de dimensiones, como desde las representaciones en dimensiones más bajas obtenidas por PCA, los descriptores de Fourier (FD) y la transformada Wavelet (WT). Como se mencionó anteriormente, PCA se emplea como un método de referencia dado que es la técnica más empleada para la reducción de dimensiones de datos hiperespectrales.

4.1 Clasificación Indian Pines

4.1.1 Clasificación con SVM

La tabla 4-1 muestra la precisión general de clasificación de la imagen Indian Pines calculado desde los resultados del clasificador SVM. Se usó un clasificador SVM polinomial de segundo orden entrenado con el número de muestras detalladas en la Tabla 3-1. Una vez entrenado el clasificador, se clasificaron todos los píxeles de la imagen. Para calcular los porcentajes de precisión general se usaron los píxeles etiquetados para cada clase. La Tabla 4-1 incluye los porcentajes de clasificación general obtenidos para Indian Pines desde la imagen original (sin ningún proceso de reducción de dimensiones), usando de 5 a 50 componentes principales (parámetro m en la tabla 4-1), usando de 5 a 50 descriptores de Fourier (FD) (parámetro m en la tabla 4-1) y usando los coeficientes de aproximación obtenidos con la familia wavelet Daubechies (DB1) y Coiflets (COIF1) con tres niveles de representación (parámetro m en la tabla 4-1). En la tabla 4-1 se resaltan los mejores porcentajes de precisión obtenidos para cada técnica.

Tabla 4-1: Precisión general de clasificación de Indian Pines usando SVM.

		Imagen Original			76.12		
m	PCA (%)	FD (%)	WT				
5	77.13	73.39	nivel	m	COIF 1(%)	m	DB1 (%)
10	77.13	83.05	1	102	76.23	100	77.31
15	74.83	82.66	2	53	78.65	50	81.21
20	72.78	81.35	3	29	80.35	25	84.18
25	70.31	78.48					
30	66.56	75.12					
35	63.13	73.63					
40	59.98	72.25					
45	58.08	72.15					
50	55.73	69.07					

Como se puede observar en la Tabla 4-1, para la imagen original se obtuvo una precisión del 76.12% usando el clasificador SVM. Usando la técnica de reducción de dimensiones PCA se obtuvieron precisiones entre el 55% y 77% variando de acuerdo al número de componentes principales. El mejor resultado se obtuvo con 10 componentes, con una precisión del 77.13%. Por su parte, usando los descriptores de Fourier propuestos en este trabajo se obtuvieron precisiones entre los 69% y 83%; el mejor resultado se obtuvo con 10 descriptores, con una precisión del 83.05%. Para el descriptor de forma basado en Wavelet (WT) se obtuvieron precisiones entre el 76% y el 84%, variando de acuerdo a la familia Wavelet empleada, así como al nivel de descomposición. Para la familia Coiflets (COIF1), el mejor resultado se obtuvo con 3 niveles de descomposición, alcanzando una precisión del 80.35%; en este nivel, el descriptor de forma obtenido tiene solo 29 componentes. Por otro lado, para la familia wavelet Daubechies (DB1) el mejor resultado también se obtuvo con 3 niveles de descomposición, con 84.18% de precisión, logrando el mejor resultado de clasificación de este experimento. En el tercer nivel de representación y usando DB1 se obtiene una representación de 25 componentes.

La Tabla 4-2 presenta la precisión de clasificación por clase para la imagen Indian Pines usando SVM. Se presenta la precisión para 5, 10, 15 y 20 componentes principales y descriptores de Fourier (FD), dado que después de 20 la precisión general de clasificación decrece. Adicionalmente, la tabla incluye la precisión de clasificación por clase para la imagen original (IO) sin ningún método de reducción de dimensiones y las diferentes configuraciones para los descriptores de forma Wavelet (WT).

Tabla 4-2: Precisión de clasificación por clase de Indian Pines usando SVM.

	IO	Wavelet													
		PCA (%)				FD (%)				COIF1			DB1		
		5	10	15	20	5	10	15	20	1	2	3	1	2	3
A	44.4	49.0	44.9	6.1	10.2	38.8	46.9	55.1	53.1	42.9	38.8	38.8	44.9	42.9	42.9
B	37.9	45.9	55.6	47.4	48.5	42.7	53.2	62.0	56.7	42.1	43.0	45.9	45.9	53.5	53.2
C	50.0	50.2	43.1	35.5	32.2	55.0	58.3	58.3	61.1	51.7	59.2	55.5	56.4	59.2	67.3
D	63.4	71.5	65.6	59.0	51.0	45.7	75.4	73.2	72.7	66.3	70.3	70.2	67.4	73.1	76.0
E	67.2	62.5	73.5	69.3	67.3	47.8	77.7	76.9	77.5	69.2	75.3	80.2	71.3	78.5	83.2
F	82.5	82.3	85.7	82.1	79.9	78.5	91.1	91.7	91.7	82.6	82.8	82.8	83.2	88.4	88.1
G	53.8	65.2	60.9	60.9	69.6	78.3	73.9	56.5	52.2	47.8	56.5	30.4	43.5	47.8	56.5
H	91.8	94.0	93.0	90.3	88.7	91.8	93.5	96.3	94.6	91.4	91.8	91.8	91.8	92.7	92.6
I	98.8	96.4	97.7	99.3	98.4	99.3	98.6	99.3	99.3	98.9	99.1	99.1	98.6	98.9	98.9
J	20.0	22.2	38.9	22.2	16.7	0.0	50.0	61.1	72.2	11.1	16.7	16.7	11.1	22.2	22.2
K	51.0	58.0	69.1	61.5	52.3	56.8	70.5	70.0	70.2	55.9	64.9	71.1	62.4	70.9	78.1
L	82.6	86.2	79.8	76.9	79.7	87.9	86.8	84.9	81.4	79.2	80.0	82.8	79.9	82.4	86.9
M	66.3	58.8	63.3	68.3	57.4	61.3	74.1	73.0	73.2	69.1	72.4	75.8	67.4	74.3	78.0
N	82.1	91.8	90.6	82.4	67.1	91.8	89.4	87.1	87.1	84.7	88.2	90.6	88.2	88.2	91.8
O	98.6	98.4	96.9	99.5	93.7	90.6	99.0	99.5	99.5	96.3	95.3	95.3	97.9	97.9	98.4
P	95.5	95.2	87.9	92.1	94.2	97.2	97.0	95.9	93.6	93.6	93.1	90.7	93.0	93.2	93.5

En la Tabla 4-2 se puede observar, en general, que la representación que obtiene los mejores resultados de clasificación por clase corresponde a los descriptores Wavelet usando DB1 y 3 niveles de descomposición; para esta configuración, 7 de las 16 clases presenta los mejores resultados de clasificación. Entre estas 7 clases se destaca el desempeño de la metodología para identificar la clase K (Soybeans min) el cual alcanza una precisión del 78.1%, comparado con un 51% de precisión obtenido desde la imagen original y con máximo un 73.9% para los otros métodos de reducción de dimensiones evaluados. Un similar mejoramiento del desempeño de clasificación se logra en las clases C (Corn-min), D (Corn) y E (Grass pasture). Por otra parte, la Tabla 4-2 permite analizar el desempeño de las metodologías propuestas cuando se tienen pocos datos etiquetados. En el caso de la clase A (Alfalfa), de la cual solo se tienen 54 muestra y se usaron 5 para entrenamiento (ver Tabla 3-1), la mejor clasificación se obtiene con 15 descriptores de Fourier. Por su parte, la clase G (Grass pasture mowed), de la cual se tienen 26 muestras

etiquetadas, se logra una mejora en la identificación desde 53% en la imagen original hasta un 80% usando los descriptores de Fourier.

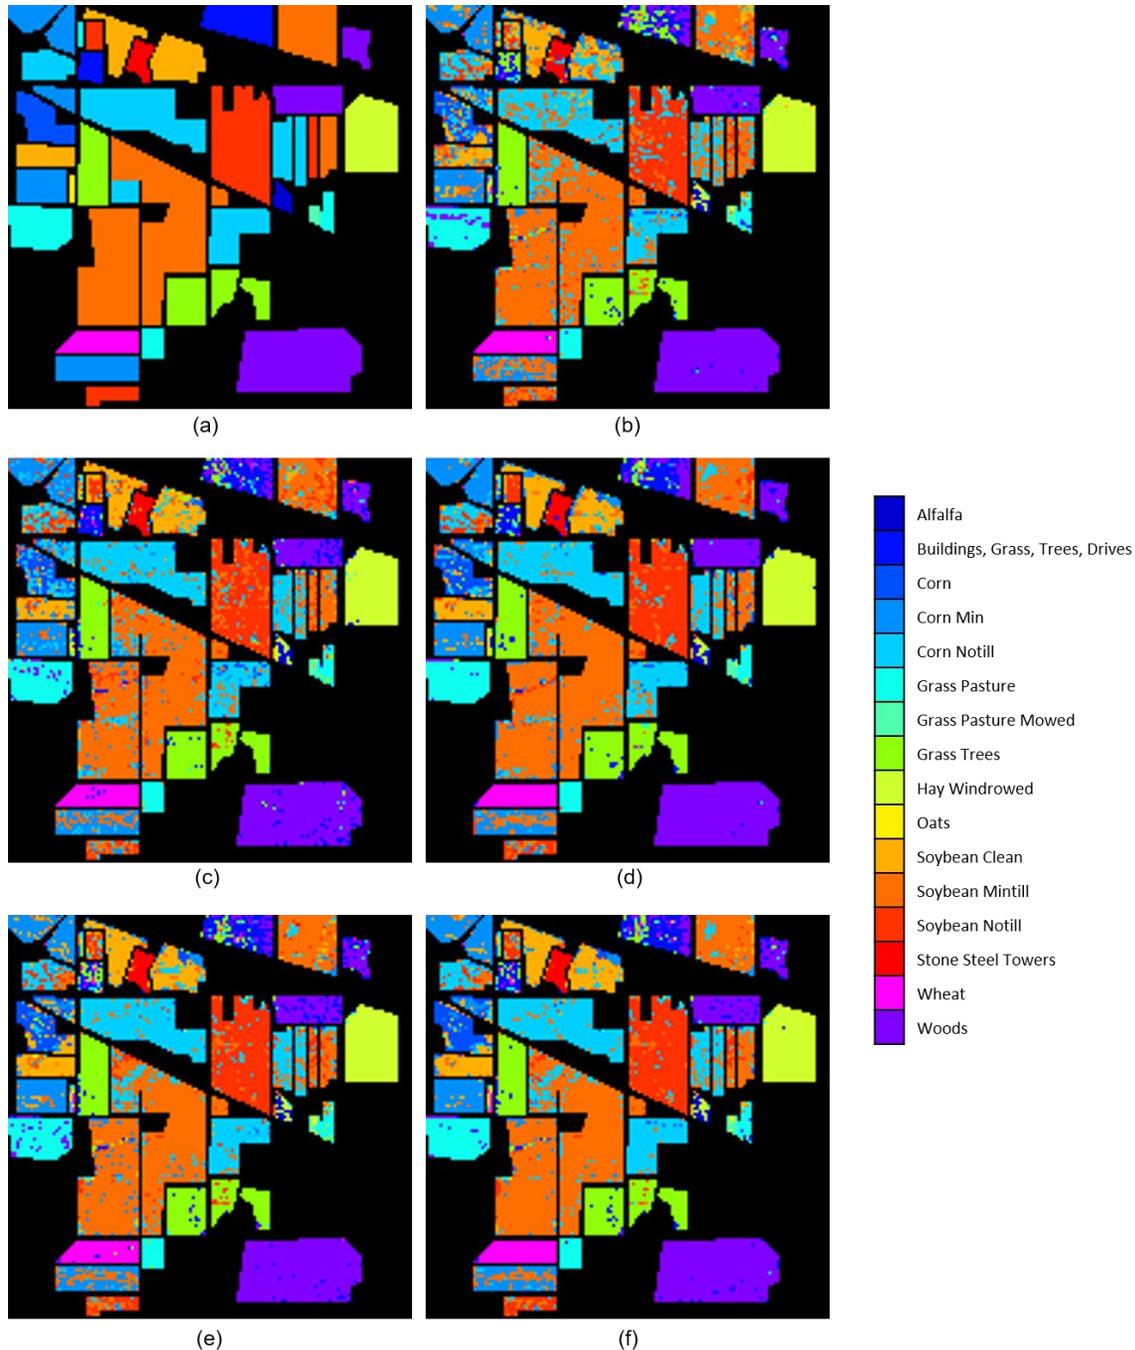


Figura 4-1: Mapas de clasificación para Indian Pines: (a) Mapa de Referencia y Mapas obtenidos con SVM desde: (b) imagen original, (c) 10 PCA, (d) 10 descriptores de Fourier, (e) 29 descriptores Wavelet (3 niveles Coif1) y (f) 25 descriptores Wavelet (3 niveles Db1).

La Figura 4-1 presenta los mapas de clasificación obtenidos desde la imagen original y las imágenes con reducción de dimensiones de 10 componentes principales, 10 descriptores de Fourier y 3 niveles de descomposición para las Wavelet Daubechies (DB1) y Coiflets (COIF1). La Tabla 4-3 se presenta la matriz de confusión para el mejor resultado de clasificación obtenido por Wavelet Daubechies (DB1) con 3 niveles de descomposición.

Tabla 4-3: Matriz de confusión para Wavelet DB1 3 niveles de descomposición con SVM.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	TOTAL
A	31	0	0	0	0	2	0	0	18	0	1	0	1	0	1	0	54
B	0	255	6	3	5	2	2	10	1	14	0	12	0	0	5	65	380
C	0	1	164	13	28	0	3	1	0	1	11	12	0	0	0	0	234
D	1	0	42	689	24	0	3	0	0	1	14	56	4	0	0	0	834
E	1	1	19	40	1084	2	28	2	1	6	9	165	64	7	3	2	1434
F	1	25	5	0	8	434	2	8	4	0	2	1	3	0	0	4	497
G	0	0	0	0	0	2	17	2	5	0	0	0	0	0	0	0	26
H	0	14	2	0	0	2	0	697	0	6	0	8	10	0	3	5	747
I	2	0	0	0	0	0	0	0	481	0	3	0	1	0	1	1	489
J	0	0	1	0	0	1	0	0	0	17	0	0	0	0	0	1	20
K	5	0	10	17	11	4	1	5	0	2	508	42	7	2	0	0	614
L	12	6	12	89	169	18	19	1	4	1	32	1979	113	1	11	1	2468
M	2	0	0	4	47	2	4	4	2	4	6	99	789	3	2	0	968
N	0	0	0	0	11	4	2	0	0	0	9	2	3	64	0	0	95
O	0	4	0	0	0	0	0	0	0	0	0	22	0	0	185	1	212
P	0	39	0	0	0	2	0	5	0	0	0	0	0	0	1	1247	1294
TOTAL	55	345	261	855	1387	475	81	735	516	52	595	2398	995	77	212	1326	

4.1.2 Clasificación con LDA

La Tabla 4-4 presenta los resultados de clasificación de la imagen Indian Pines usando el clasificador discriminante lineal -LDA. La tabla incluye los porcentajes de clasificación general obtenidos para Indian Pines desde la imagen original (sin ningún proceso de reducción de dimensiones), usando de 5 a 50 componentes principales y descriptores de Fourier (FD) respectivamente, y usando los coeficientes de aproximación obtenidos por la transformada Wavelet usando las familias Daubechies (DB1) y Coiflets (COIF1) con tres niveles de descomposición. Adicionalmente, se incluye el porcentaje de clasificación general para 199 componentes y descriptores dado que la precisión no logro un punto significativo usando solo de 5 a 50 componentes y descriptores.

Tabla 4-4: Precisión general de clasificación de Indian Pines usando LDA.

			Imagen Original				75.51	
m	PCA (%)	FD (%)	WT					
			nivel	m	COIF 1(%)	M	DB1 (%)	
5	52.52	55.33	1	102	75.42	100	75.16	
10	60.61	68.39	2	53	75.53	50	75.06	
15	70.56	71.71	3	29	73.50	25	73.35	
20	72.09	73.83						
25	72.71	73.92						
30	72.38	74.03						
35	72.93	74.59						
40	72.82	74.75						
45	73.59	74.43						
50	74.05	74.53						
199	73.72	76.96						

En la Tabla 4-4 se resaltan los mejores porcentajes de clasificación general obtenidos para cada técnica. Para la imagen original se obtuvo un porcentaje de precisión de clasificación del 75.51%. Usando la técnica de reducción de dimensiones PCA, el mejor resultado se obtuvo con 50 componentes alcanzado una precisión del 74.05%. Por su parte, usando los descriptores de Fourier se logró mejorar la precisión de clasificación a un 76.96%. Sin embargo, este resultado se obtuvo con 199 descriptores de Fourier.

Por otro lado, usando los descriptores Wavelet se mejora la clasificación usando ambas familias de Wavelet: Daubechies (DB1) y Coiflets (COIF1). Para Coiflets, el mejor porcentaje de precisión se obtiene usando 2 niveles de descomposición; en esta configuración se logra una precisión general de 75.53%. En el caso de la familia Daubechies, se logra el mejor resultado de clasificación con un 75.16% en 1 nivel de descomposición.

La Tabla 4-5 presenta la precisión de clasificación por clase para la imagen Indian Pines. Se incluyen los porcentajes de precisión para la clasificación obtenida desde la imagen original (IO), con 50 y 199 componentes principales (PCA), 50 y 199 descriptores de Fourier (FD), y las diferentes configuraciones para los descriptores Wavelet.

Tabla 4-5: Precisión de clasificación por clase de Indian Pines usando LDA.

	IO	WAVELET									
		PCA (%)		FD (%)		COIF1			DB1		
		50	199	50	199	1	2	3	1	2	3
A	46.3	73.5	42.9	53.1	55.1	67.3	81.6	81.6	69.4	79.6	77.6
B	71.3	71.1	67.8	66.7	64.9	71.1	71.1	74.3	71.3	71.1	71.6
C	62.8	74.9	56.4	85.3	70.6	67.3	75.8	75.4	70.1	77.7	75.8
D	63.4	61.7	61.4	65.8	64.2	64.2	63.0	63.1	63.4	64.0	60.5
E	75.7	76.8	74.9	65.5	73.6	77.8	78.5	76.5	76.2	78.0	74.9
F	82.5	70.7	80.1	85.2	86.1	81.4	77.4	72.3	79.4	77.4	70.5
G	34.6	87.0	21.7	91.3	60.9	43.5	82.6	95.7	69.6	91.3	100
H	97.5	95.5	97.5	95.1	92.0	97.9	98.1	98.2	98.5	98.1	97.8
I	99.4	98.2	99.3	99.1	99.3	98.6	97.5	97.7	99.1	97.7	97.5
J	15.0	55.6	5.6	72.2	44.4	27.8	61.1	94.4	11.1	44.4	94.4
K	75.9	81.0	74.7	78.3	77.0	79.7	80.5	80.5	79.7	80.5	81.6
L	61.7	57.2	59.1	61.6	67.8	58.1	56.8	50.5	59.0	54.0	50.3
M	67.9	70.0	64.9	67.4	68.0	70.3	73.1	73.1	67.4	73.6	76.7
N	88.4	89.4	91.8	87.1	88.2	91.8	92.9	91.8	91.8	94.1	91.8
O	100	99.5	100	100	100	99.5	100	100	100	99.5	100
P	92.0	86.2	91.2	89.1	94.3	90.2	89.3	87.5	90.0	9.0	88.7

En la Tabla 4-5 se puede observar que usar los descriptores Wavelet y los descriptores de Fourier permiten mejorar la precisión de clasificación. Sin embargo, los mejores resultados de reducción de dimensiones se obtienen con Wavelet, dado que para mejorar la clasificación usando Fourier se requiere usar todos los descriptores. Similar a los resultados obtenidos con SVM, la Tabla 4-5 resalta el mejoramiento en la identificación de ciertas clases. Por ejemplo, la clase A (Alfalfa) pasa de un 46.3% de precisión a un 81.6% usando el segundo o tercer nivel de descomposición de Wavelet con la familia Coiflets. Similarmente, las clases G (Grass pasture mowed) y J (Soybeans notill) presentan una mejora significativa con los descriptores de forma Wavelet. Para la clase G se obtiene un 100% de precisión de clasificación usando Wavelet con DB1 y 3 niveles de descomposición, comparado con el 34.6% obtenido desde la imagen original. Por su parte, para la clase J se obtiene un 94.4% usando el nivel 3 de descomposición tanto para COIF1 como DB1.

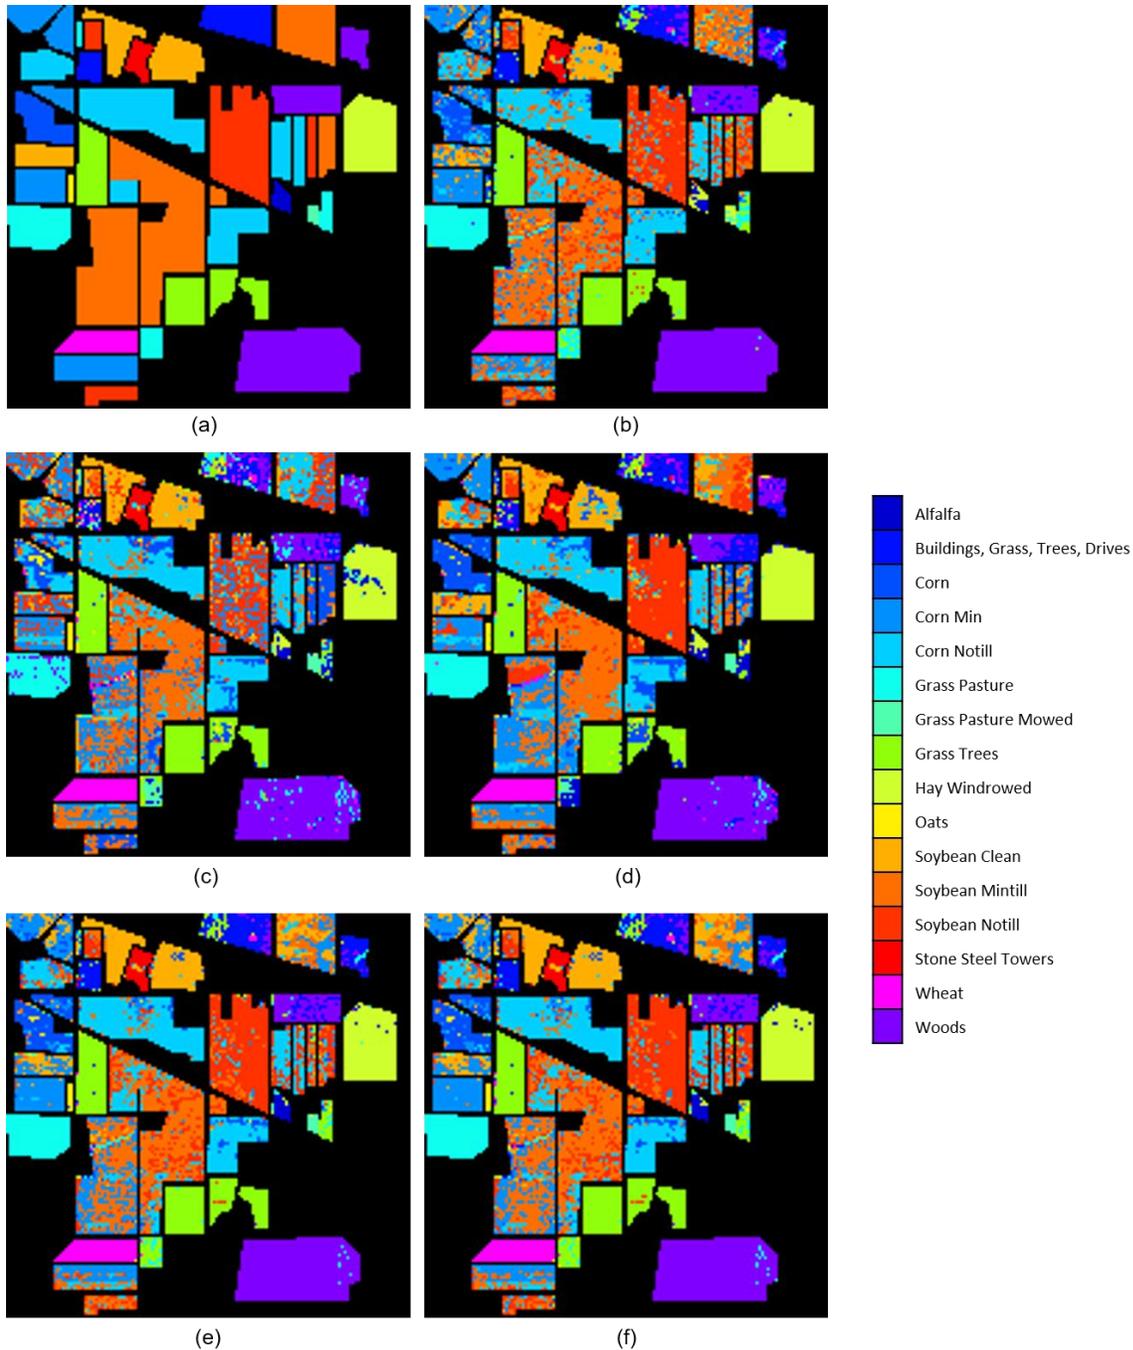


Figura 4-2: Mapas de clasificación para Indian Pines: (a) Mapa de Referencia y Mapas obtenidos con LDA desde: (b) imagen original, (c) 199 PCA, (d) 199 descriptores de Fourier, (e) 29 descriptores Wavelet (3 niveles Coif1) y (f) 25 descriptores Wavelet (3 niveles Db1).

La Figura 4-2 presenta los mapas de clasificación obtenidos desde la imagen original y las imágenes con reducción de dimensiones de 199 componentes principales, 199 descriptores de Fourier y 3 niveles de descomposición para las Wavelet Daubechies (DB1) y Coiflets (COIF1).

4.1.3 Discusión

De los resultados de clasificación de Indian Pines presentados en las secciones 4.1.1 y 4.1.2 se puede observar que los descriptores de Fourier y Wavelet permiten mejorar los resultados de clasificación. Por ejemplo, los resultados de clasificación con SVM y el descriptor Wavelet con COIF 1 y 3 niveles de descomposición fue el mejor, alcanzando un porcentaje general de clasificación del 84.18%. Para el clasificador LDA, los mejores resultados se logran con los descriptores de Fourier con una precisión del 76.96% con 199 componentes principales. Adicionalmente, se puede ver en los resultados presentados en la Tabla 4-1 los descriptores de forma de Fourier y Wavelet obtienen mejores porcentajes de precisión de clasificación que PCA, siendo este método uno de los más empleados para reducción de dimensiones.

Para el clasificador SVM, con un número de descriptores variando entre 10 y 25 se logran precisiones superiores al 80%, comparado a el 76.12% que se obtiene desde la imagen original que tiene 200 bandas. A su vez, los descriptores de forma Wavelet en el segundo y tercer nivel de descomposición, tanto para la familia Daubechies (DB1) y Coiflets (COIF1) logran precisiones de clasificación superior al 80%. Usando el segundo nivel de descomposición se obtiene una representación con alrededor de los 50 componentes; por su parte, usando el tercer nivel de descomposición se obtiene una representación entre los 25 y 29 componentes de acuerdo a la familia wavelet empleada. Esto representa una reducción significativa de la dimensión de los datos hiperespectrales.

En el caso de los resultados de clasificación obtenidos con LDA, la mejora que se obtiene desde la representación con los descriptores de Fourier no es significativo; dado que los mejores resultados se obtienen al usar 199 descriptores. Por su parte, usando los descriptores Wavelet se logra una precisión de clasificación del 79.58% comparado con el 75.51% de la imagen original y un 75.98% obtenido desde PCA. Aquí cabe resaltar que,

aunque el incremento de precisión solo es del 4%, este resultado se obtiene al usar un espacio de representación con solo 25 componentes (ver Tabla 4-4).

Los resultados de precisión de clasificación por clase presentados en las Tablas 4-2 y 4-5 muestran que la mayoría de clases se identifican con mayor precisión al usar uno de los espacios de representación propuestos: descriptores de Fourier y descriptores Wavelet. En estos resultados se ve un incremento significativo de precisión para clases como Alfalfa (clase A), Grass pasture mowed (clase G), y Soybeans notill (J).

4.2 Clasificación Espectral Cuprite

4.2.1 Clasificación con SVM

La tabla 4-6 muestra la precisión general de clasificación de la imagen Cuprite calculado desde los resultados del clasificador SVM. Para este experimento, se usó un clasificador SVM polinomial de segundo orden, como en el experimento con Indian Pines. El clasificador fue entrenado con el número de muestras detalladas en la Tabla 3-2. Una vez entrenado el clasificador, se clasificaron todos los píxeles de la imagen. Para calcular los porcentajes de precisión general se usaron los píxeles etiquetados para cada clase. La

Tabla 4-6: Precisión general de clasificación de Cuprite usando SVM.

		Imagen Original					89.31	
m	PCA (%)	FD (%)	WT					
			nivel	M	COIF 1(%)	M	DB1 (%)	
5	79.57	75.15	1	71	89.39	69	89.66	
10	85.41	84.97	2	38	90.02	35	90.05	
15	87.83	86.73	3	21	86.70	18	87.74	
20	87.83	86.73						
25	86.18	86.57						
30	86.83	85.93						
35	86.43	85.96						
40	85.20	85.48						
45	84.12	85.33						
50	83.17	85.37						

Tabla 4-6 incluye los porcentajes de clasificación general obtenidos para Cuprite desde la imagen original (sin ningún proceso de reducción de dimensiones), usando de 5 a 50 componentes principales, usando de 5 a 50 descriptores de Fourier (FD) y usando los

coeficientes de aproximación obtenidos con las familias wavelet Daubechies (DB1) y Coiflets (COIF1) y con tres niveles de representación. En la tabla 4-5 se resaltan los mejores porcentajes de precisión obtenidos para cada técnica.

Para la imagen original, sin ningún tipo de reducción de dimensiones, se obtuvo un porcentaje de precisión del 89.31 usando un clasificador SVM. Para el caso de la reducción de dimensiones con PCA, el mejor resultado se obtuvo con 20 y 15 componentes con una precisión del 87.83%. Al igual que PCA, usando la reducción de descriptores de Fourier logró el mejor resultado para 20 y 15 componentes, con una precisión de clasificación de 86.73%. Sin embargo, para el caso de la imagen de Cuprite, tanto los resultados de clasificación obtenidos con PCA como con los descriptores de Fourier no superan la precisión de clasificación obtenido desde la imagen original. Pero, en el caso de los descriptores Wavelet, los resultados de clasificación desde los descriptores obtenido en el primer y segundo nivel de descomposición, para ambas wavelets, son mejores que los resultados desde la imagen original, PCA y descriptores de Fourier. Para el caso de Coiflets (COIF1), el mejor resultado se obtiene en el segundo nivel de descomposición con 38 componentes y una precisión de 90.02%. Por su parte, para Daubechies (DB1), el mejor resultado se obtiene en el primer nivel de descomposición con 69 componentes y 90.05% de precisión; este es el mejor porcentaje de clasificación obtenido para Cuprite en este experimento.

Tabla 4-7: Precisión de clasificación por clase de Cuprite usando SVM.

	IO	Wavelet													
		PCA (%)				FD (%)				COIF1			DB1		
		5	10	15	20	5	10	15	20	1	2	3	1	2	3
A	91.8	78.8	89.7	89.9	88.0	83.9	90.9	90.9	89.2	93.9	94,5	93,7	94,1	94,8	93,6
B	91.8	85.7	91.6	90.8	90.3	83.5	89.5	90.5	89.7	92.1	92,6	91,8	91,9	92,2	92,0
C	65.3	25.3	56.0	63.1	64.3	31.5	53.2	58.9	61.7	70.0	67,4	61,2	71,3	66,1	60,9
D	88.0	80.3	89.8	90.4	90.4	74.0	88.0	89.3	88.6	90.7	92,3	90,6	91,0	92,2	92,2
E	82.2	73.8	77.9	77.4	80.1	31.2	76.1	76.7	76.7	80.1	82,5	77,2	81,0	82,3	80,1
F	91.5	70.6	90.8	96.8	95.5	54.3	93.7	94.2	93.8	93.9	94,3	94,6	94,2	94,4	96,2
G	90.5	84.6	88.1	90.9	90.3	83.6	90.1	91.4	93.2	92.0	93,0	92,0	92,1	92,8	92,7
H	72.5	10.0	24.7	53.5	58.3	0.4	27.7	40.0	48.0	63.8	59,2	30,3	65,3	61,7	35,0
I	93.5	96.0	95.3	93.8	93.1	93.2	94.9	93.7	92.9	93.2	95,1	94,7	93,4	95,1	95,6
J	99.0	95.9	98.4	98.8	98.7	80.6	96.8	98.3	97.6	99.3	99,2	99,0	99,3	99,3	98,7

La Tabla 4-7 presenta la precisión de clasificación para las 10 clases de la imagen Cuprite usando SVM. Se presenta la precisión para 5, 10, 15 y 20 componentes principales y descriptores de Fourier (FD), dado que después de 20 la precisión general de clasificación decrece (ver Tabla 4-6). Adicionalmente, la tabla incluye la precisión de clasificación por clase para la imagen original (IO) sin ningún método de reducción de dimensiones y las diferentes configuraciones para los descriptores de forma Wavelet (WT).

En la Tabla 4-7 se puede observar que los descriptores de forma basados en la transformada Wavelet obtienen los mejores resultados de clasificación para la mayoría de las clases. Por ejemplo, la clase D (Kaolinite pxl) se clasifica con un 92.3% de precisión usando la wavelet Coiflets (COIF1) con 2 niveles de descomposición. Similarmente, la clase C (Kaolinite wxl) se clasifica con un 71.3% de precisión usando Wavelet con Daubechies (DB1) y 1 nivel de descomposición. Por su parte, los resultados obtenidos con los descriptores de forma de Fourier son comparables con los obtenidos desde la imagen original, por lo tanto, no representan un cambio significativo del desempeño del clasificador.

La Tabla 4-8 presenta la matriz de confusión para el mejor resultado de clasificación obtenido por Wavelet Daubechies (DB1) con 2 niveles de descomposición.

Tabla 4-8: Matriz de confusión para Wavelet DB1 2 niveles de descomposición con SVM.

	A	B	C	D	E	F	G	H	I	J	TOTAL
A	2997	165	0	0	0	0	0	0	0	0	3162
B	245	11819	311	437	0	0	0	0	0	0	12812
C	0	561	1610	264	0	0	0	0	0	0	2435
D	0	341	251	7349	27	0	1	0	1	0	7970
E	0	0	0	39	1242	0	0	27	201	0	1509
F	0	0	0	0	0	776	46	0	0	0	822
G	0	0	0	1	1	4	6910	192	340	0	7448
H	0	0	0	2	11	0	292	3166	1661	0	5132
I	0	0	0	1	90	0	153	760	19300	0	20304
J	0	0	0	1	0	1	17	4	0	3174	3197
TOTAL	3242	12886	2172	8094	1371	781	7419	4149	21503	3174	

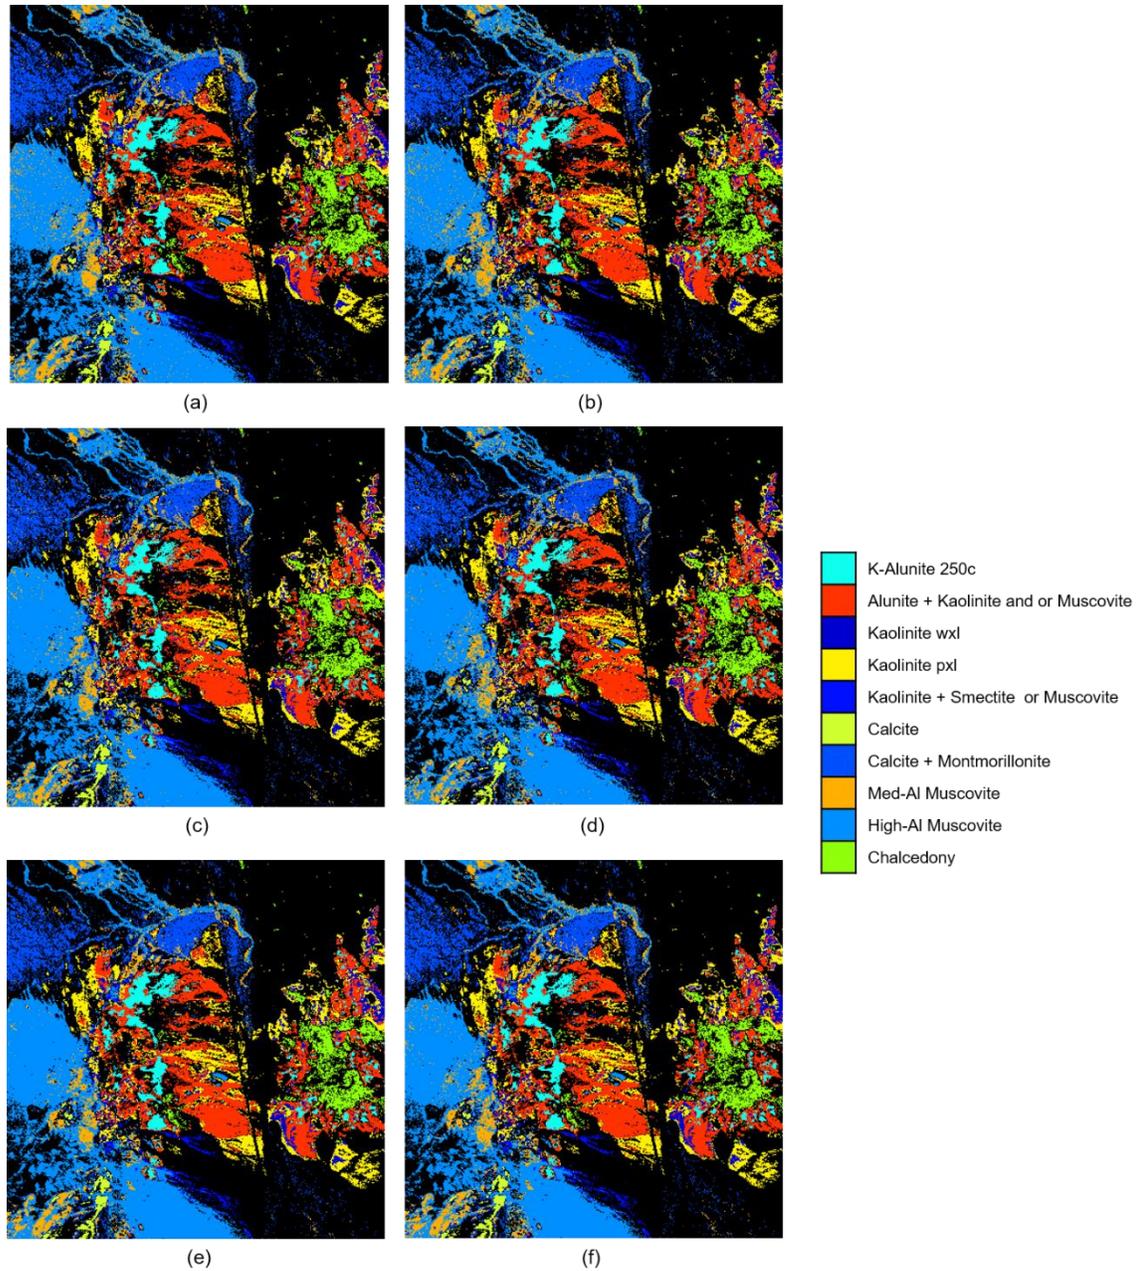


Figura 4-3: Mapas de clasificación para Cuprite: (a) Mapa de Referencia y Mapas obtenidos con SVM desde: (b) imagen original, (c) 20 PCA, (d) 20 descriptores de Fourier, (e) 38 descriptores Wavelet (2 niveles Coif1) y (f) 69 descriptores Wavelet (1 nivel Db1).

La Figura 4-3 presenta los mapas de clasificación obtenidos desde la imagen original y las imágenes con reducción de dimensiones de 20 componentes principales, 20 descriptores de Fourier, 2 niveles de descomposición para Coiflets (COIF1) y 1 nivel de descomposición

para Daubechies (DB1). Se presentan estos mapas de clasificación porque corresponden a los mejores porcentajes generales de clasificación de acuerdo a la Tabla 4-6.

4.2.2 Clasificación con LDA

Tabla 4-9 incluye los porcentajes de clasificación general obtenidos para la imagen hiperespectral Cuprite desde la imagen original (sin ningún proceso de reducción de dimensiones), usando de 5 a 50 componentes principales, usando de 5 a 50 descriptores de Fourier (FD) y usando los coeficientes de aproximación obtenidos con las familias wavelet Daubechies (DB1) y Coiflets (COIF1) con tres niveles de representación. En la tabla 4-9 se resaltan los mejores porcentajes de precisión obtenidos para cada técnica.

Tabla 4-9: Precisión general de clasificación de Cuprite usando LDA.

Imagen Original			84.34				
m	PCA (%)	FD (%)	WT				
5	65.57	59.39	nivel	m	COIF 1(%)	M	DB1 (%)
10	73.12	71.94	1	71	83.83	69	83.93
15	78.46	74.75	2	38	82.68	35	82.79
20	80.11	77.17	3	21	76.95	18	78.52
25	82.23	78.28					
30	83.74	78.80					
35	84.04	79.17					
40	84.18	79.30					
45	84.20	79.39					
50	84.46	79.54					
138	84.03	83.04					

Para la imagen original se obtuvo un porcentaje de precisión del 84.34% en la clasificación. Por su parte, usando la técnica de reducción de dimensiones PCA, el mejor resultado se obtuvo con 50 componentes alcanzado una precisión del 84.46%. Usando los descriptores de Fourier se logró una precisión del 83.04% al usar todos los descriptores. Sin embargo, para el caso de la clasificación de Cuprite con LDA, el análisis de componentes principales presentó un mejor resultado. Adicionalmente, para los descriptores Wavelet, los mejores resultados se obtienen con 1 nivel de descomposición para ambas familias de wavelet. En este caso se logra un 83.83% y 83.93% para Coiflets (COIF1) y Daubechies (DB1) respectivamente.

La Tabla 4-10 presenta la precisión de clasificación para las 10 clases de la imagen Cuprite usando LDA. Se presenta la precisión para 50 y 138 componentes principales y descriptores de Fourier (FD), dado que no se logra un mejor resultado con pocos componentes (ver Tabla 4-9). Adicionalmente, la tabla incluye la precisión de clasificación por clase para la imagen original (IO) sin ningún método de reducción de dimensiones y las diferentes configuraciones para los descriptores de forma Wavelet (WT).

Tabla 4-10: Precisión de clasificación por clase de Cuprite usando LDA.

	IO	WAVELET									
		PCA (%)		FD (%)		COIF1			DB1		
		50	138	50	138	1	2	3	1	2	3
A	93.8	94.0	93.4	94.8	92.8	94.5	94.5	95.9	94.6	94.1	95.0
B	80.6	80.8	80.3	76.0	79.6	81.3	80.0	77.1	81.4	79.0	76.5
C	74.8	70.8	73.8	70.1	74.0	71.4	70.6	71.7	72.4	69.4	70.6
D	84.8	84.0	84.5	81.2	84.5	84.3	84.6	81.0	84.4	84.0	83.2
E	89.7	89.7	89.6	88.1	90.9	90.3	90.7	91.5	91.3	89.9	88.9
F	99.9	100	99.9	95.3	95.1	100	100	99.9	100	99.9	99.9
G	94.5	94.5	94.8	92.9	93.9	94.0	93.9	93.1	94.0	93.7	94.4
H	75.2	74.8	74.3	66.4	76.2	70.6	68.0	52.3	72.1	69.3	55.2
I	81.4	82.5	81.0	74.3	78.5	81.1	78.9	67.7	80.8	80.2	71.6
J	99.2	99.4	99.2	96.6	98.6	99.2	99.3	99.0	99.2	99.2	98.4

En la Tabla 4-10 se puede observar que varias clases se identifican con mejores porcentajes de precisión usando el descriptor de Wavelet basado en Coiflets (COIF1). Entre estas clases se encuentran B (Alunite + Kaolinite or muscovite) con un 81.4% y F (Calcite) con 100% para 1 nivel de descomposición; las clases F (Calcite) con 100% y J (Chalcedony) con 99.4% con 50 componentes principales; y las clases A (K-Alunite 250c) con 95.9% y E (Kaolinite + Smectite or muscovite) con 91.5% para 3 niveles de descomposición. Adicionalmente, clases como D (Kaolinite pxl) e I (High-al Muscovite) obtienen porcentajes de precisión comparables a los obtenidos con 50 componentes principales. Por otra parte, los resultados obtenidos con los descriptores de Fourier son también comparables con los resultados obtenidos con componente principales, e incluso para las clases D (Kaolinite pxl), E (Kaolinite + Smectite or muscovite) y H (Med-al Muscovite) se obtiene los mejores resultados de clasificación por clase usando 138

descriptores de Fourier con porcentajes de precisión iguales a 84.6, 91.5 y 76.2 respectivamente.

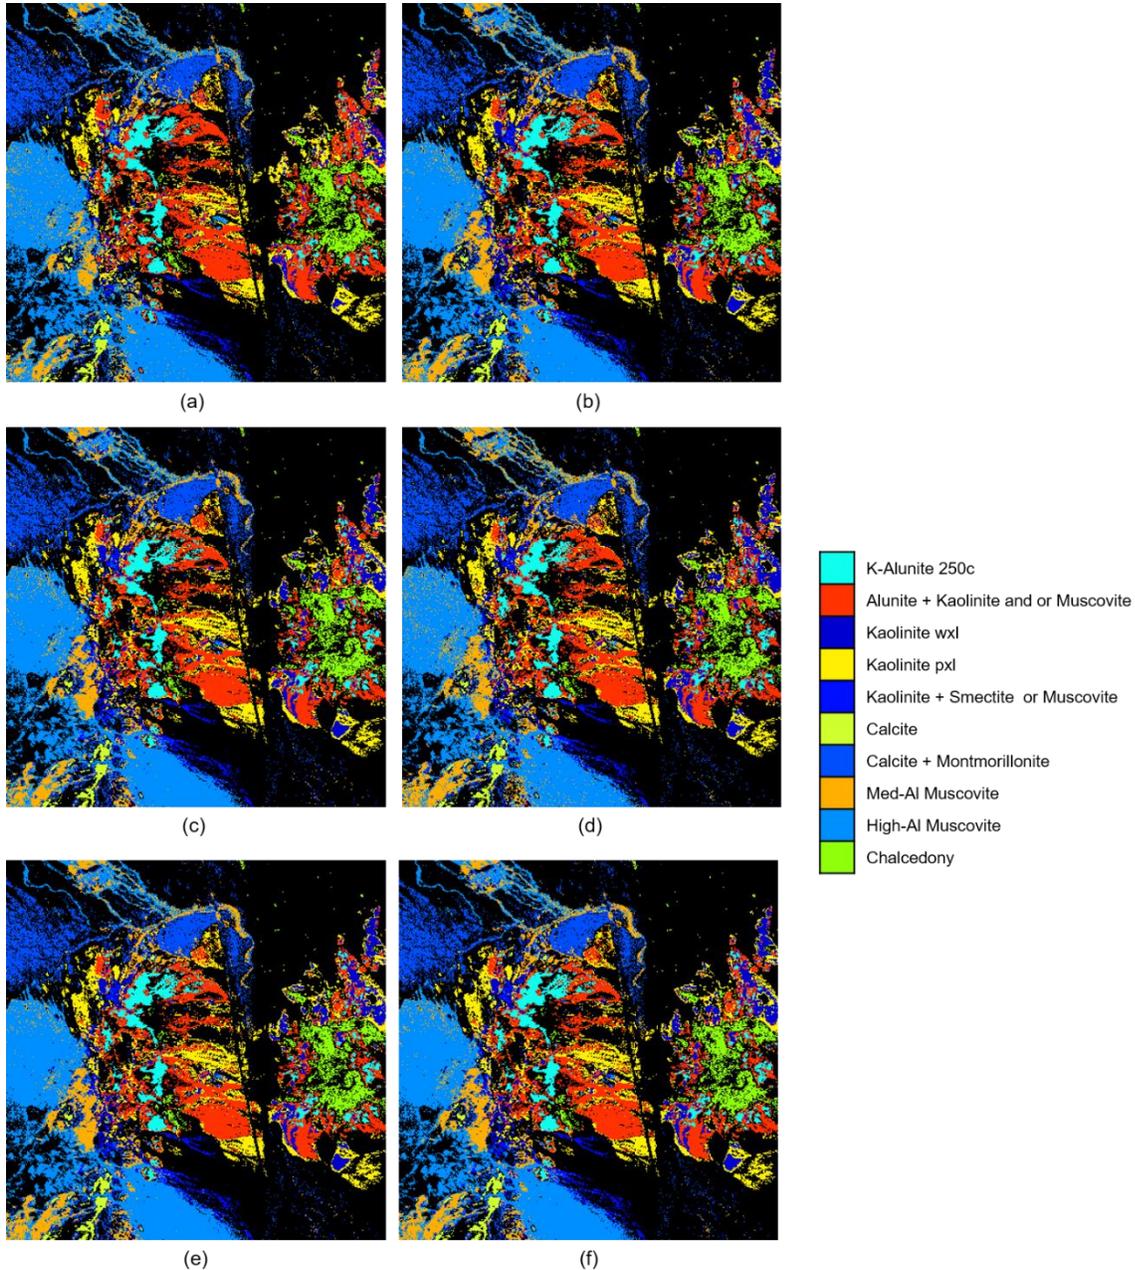


Figura 4-4: Mapas de clasificación para Cuprite: (a) Mapa de Referencia y Mapas obtenidos con LDA desde: (b) imagen original, (c) 50 PCA, (d) 138 descriptores de Fourier, (e) 71 descriptores Wavelet (1 nivel Coif1) y (f) 69 descriptores Wavelet (1 nivel Db1).

La Figura 4-4 presenta los mapas de clasificación para Cuprite obtenidos con LDA desde la imagen original y las imágenes con reducción de dimensiones de 50 componentes

principales, 138 descriptores de Fourier y 1 nivel de descomposición para las Wavelet Daubechies (DB1) y Coiflets (COIF1). Se presenta estos mapas porque, de acuerdo a los resultados presentados en la Tabla 4-9, son los mejores resultados para cada técnica comparada.

4.2.3 Discusión

En comparación con los resultados obtenidos para la imagen Indian Pines, no se obtuvo un incremento significativo en el desempeño de los clasificadores con la imagen Cuprite y los descriptores de forma propuestos. Sin embargo, los resultados muestran que usando estos descriptores no se disminuye el desempeño de clasificación. Por ejemplo, usando SVM, los mejores resultados se obtienen con los descriptores Wavelet con DB1 con un nivel de descomposición, donde el número de dimensiones es de 69 componentes (ver Tabla 4-6). De acuerdo a la Tabla 4-7, usando esta configuración de clasificación, se logra mejorar en hasta un 6% la clasificación de clases en comparación a la imagen original; por ejemplo, la clase C pasa de 65.3% de precisión a 71.3%. Por su parte, los descriptores de Fourier no representaron un cambio significativo a los resultados obtenidos desde la imagen original y PCA; solo en la clase H (Med-al Muscovite) los descriptores de Fourier disminuyen la precisión de clasificación de SVM significativamente; de un 72.5% de precisión en la imagen original se alcanzan porcentajes por debajo de 48% con los descriptores de Fourier.

Para el caso del clasificador LDA, los mejores resultados generales de clasificación de la imagen Cuprite se obtienen con 50 componentes principales. Sin embargo, los descriptores de forma Wavelet usando la familia Coiflets logra mejorar en un 2% la clasificación de clases como A (K-Alunite 250c) y E (Kaolinite + Smectite or muscovite); otras clases obtienen resultados comparables con la imagen original y PCA (ver Tabla 4-10). De manera similar, los resultados con los descriptores de Fourier y LDA son comparables a los resultados obtenidos con la imagen original y PCA.

Se puede concluir que para el caso de la imagen hiperespectral Cuprite no es necesaria una reducción de dimensiones, dado los resultados presentados con PCA y los descriptores de forma propuestos. Los buenos resultados de clasificación obtenidos con la

imagen original, sin ningún tipo de reducción de dimensiones, se puede justificar dado que solo se usan 138 bandas de las 224 bandas proporcionadas por el sensor. De acuerdo a la literatura, estas 138 bandas corresponden a las longitudes de onda donde se pueden identificar minerales.

4.3 Clasificación Kennedy Space Center

4.3.1 Clasificación con SVM

La Tabla 4-11 presenta los porcentajes de precisión general de clasificación de la imagen hiperespectral Kennedy Space Center (KSC) calculados desde los resultados del clasificador SVM. Se usó un clasificador SVM polinomial de segundo orden entrenado con el número de muestras detalladas en la Tabla 3-3. Una vez entrenado el clasificador, se clasificaron todos los píxeles de la imagen. Para calcular los porcentajes de precisión general se usaron los píxeles etiquetados para cada clase. La Tabla 4-11 incluye los porcentajes de clasificación general obtenidos para la imagen KSC desde los datos originales (sin ningún proceso de reducción de dimensiones), usando de 5 a 50 componentes principales, usando de 5 a 50 descriptores de Fourier (FD) y usando los coeficientes de aproximación obtenidos con la familia wavelet Daubechies (DB1) y Coiflets (COIF1) con tres niveles de representación. En la Tabla 4-11 se resaltan los mejores porcentajes de precisión obtenidos para cada técnica.

Tabla 4-11: Precisión general de clasificación de KSC usando SVM.

			Imagen Original			88.54	
m	PCA (%)	FD (%)	WT				
			nivel	m	COIF1 (%)	M	DB1 (%)
5	59.70	80.49					
10	65.14	81.51	1	90	88.76	88	88.64
15	65.88	79.42	2	47	89.53	44	89.49
20	68.17	80.51	3	26	89.34	22	89.28
25	70.94	79.51					
30	73.50	79.55					
35	73.56	78.59					
40	73.22	77.16					
45	72.86	76.16					
50	73.41	75.80					

En la Tabla 4-11 se puede observar que, aunque los descriptores de Fourier no logran una representación que permitan discriminar con mayor precisión las clases que la imagen original, si presenta esta técnica propuesta un mejor desempeño que análisis de componentes principales. Con 10 descriptores de Fourier se obtiene un 81.51% de precisión general de clasificación comparado con 73.56% con 50 componentes principales. Por su parte, y similar a los resultados obtenidos con Indian Pines, los mejores resultados de clasificación general para la imagen KSC se obtienen con los descriptores de forma Wavelet. Para 2 niveles de descomposición, se obtiene 89.53% y 89.49% de precisión para las wavelets Coiflets (COIF1) y Daubechies (DB1) respectivamente; en este nivel de descomposición se obtiene espacios de representación de 47 y 44 componentes.

Tabla 4-12: Precisión de clasificación por clase de KSC usando SVM.

	IO	WAVELET											
		PCA (%)		FD (%)				COEF1 (%)			DB1 (%)		
		20	50	5	10	15	20	1	2	3	1	2	3
A	93.0	89.3	84.2	93.3	92.3	89.2	88.0	94.5	95.3	93.6	92.1	93.9	93.0
B	83.5	63.0	67.1	76.3	78.5	76.3	79.9	84.9	81.3	80.8	84.9	83.1	79.0
C	90.2	36.1	43.9	80.9	75.7	78.7	83.0	89.6	91.7	90.0	89.1	90.9	89.6
D	73.0	30.4	21.6	47.6	55.5	53.3	63.9	71.8	72.7	67.0	73.6	70.0	69.2
E	51.6	40.7	37.2	36.6	44.8	44.8	46.2	49.7	47.6	46.2	46.9	48.3	44.8
F	45.9	21.4	9.7	58.3	58.3	52.4	51.5	48.5	57.3	64.6	43.7	45.1	51.5
G	64.8	37.2	29.8	83.0	85.1	57.4	63.8	75.5	83.0	83.0	81.9	88.3	90.4
H	87.0	55.2	59.0	65.2	71.4	70.1	71.1	85.3	85.8	85.3	86.9	87.4	86.9
I	98.3	78.0	88.5	95.1	94.2	92.3	92.7	97.9	98.5	98.3	98.9	99.1	99.8
J	92.6	69.2	82.1	58.5	62.9	61.0	60.7	91.2	90.1	90.9	92.9	94.0	94.2
K	95.7	91.0	96.3	93.9	93.6	94.7	95.0	95.8	96.8	97.9	96.0	96.6	98.4
L	91.5	36.6	75.9	76.2	75.1	70.9	72.0	92.1	93.4	93.8	91.8	94.9	92.7
M	98.3	98.0	98.1	97.6	97.6	97.6	97.6	98.2	98.0	98.2	98.0	98.2	98.3

La Tabla 4-12 presenta la precisión de clasificación para las 13 clases de la imagen KSC usando SVM. Se presenta la precisión para 20 componentes principales (para comparar con los resultados obtenidos con los descriptores de Fourier), así como 50 componentes principales donde se obtiene la más alta precisión para esta técnica de reducción de dimensiones. Adicionalmente, se presenta los resultados por clase para 5, 10, 15 y 20 descriptores de Fourier (FD), dado que después de 20 la precisión general de clasificación decrece (ver Tabla 4-11). También se incluye la precisión de clasificación por clase para

la imagen original (IO) sin ningún método de reducción de dimensiones y las diferentes configuraciones para los descriptores de forma Wavelet (WT).

En este experimento se obtuvo los más altos porcentajes de precisión de clasificación usando los descriptores de forma Wavelet. Se logró un incremento significativo, es decir mayor al 20%, para las clases F (Oak/Broadleaf) y G (Hardwood swamp); en la imagen original estas clases se identifican con una precisión del 45.9% y 64.8%, en cambio usando descriptores Wavelet se logra una precisión del 64.6% para la clase F (Oak/Broadleaf) usando COEF1 y del 90.4% usando DB1, ambas con 3 niveles de descomposición. Comparando los resultados obtenidos por los descriptores de Fourier y PCA, se puede notar que la mayoría de las clases obtienen una mejora precisión de clasificación usando los descriptores en vez de PCA; por ejemplo, la clase B (Willow swamp) se identifica con una precisión del 63% usando 20 componentes principales, por su parte, usando la misma cantidad de descriptores de Fourier se logra un 81.5% de precisión. También se destacan las clases D (CP/Oak), F (Oak/Broadleaf), G, (Hardwood swamp), H (Graminoid marsh) y L (Mod flats) cuya precisión en la clasificación mejora entre 20% y 60% usando los 20 descriptores de Fourier en vez de componentes principales. La Tabla 4-13 presenta la matriz de confusión para el mejor resultado de clasificación obtenido por Wavelet Coiflets (COIF1) con 2 niveles de descomposición.

Tabla 4-13: Matriz de confusión para Wavelet COIF1 2 niveles de descomposición SVM.

	A	B	C	D	E	F	G	H	I	J	K	L	M	TOTAL
A	653	3	0	6	0	22	0	0	1	0	0	0	0	685
B	0	178	1	11	1	4	15	0	4	2	0	3	0	219
C	0	0	211	6	5	0	0	0	8	0	0	0	0	230
D	1	2	11	165	12	31	0	3	1	1	0	0	0	227
E	1	1	1	60	69	9	0	1	3	0	0	0	0	145
F	38	0	2	31	4	118	4	0	9	0	0	0	0	206
G	0	11	0	3	0	2	78	0	0	0	0	0	0	94
H	6	4	1	2	0	5	0	333	37	0	0	0	0	388
I	0	0	0	0	0	0	0	5	461	2	0	0	0	468
J	1	1	0	0	0	0	0	2	9	328	0	23	0	364
K	0	0	0	0	0	0	0	4	0	4	365	4	0	377
L	0	0	0	0	0	0	0	3	1	6	10	423	10	453
M	0	0	0	0	0	0	0	0	0	9	1	7	817	834
TOTAL	700	200	227	284	91	191	97	351	534	352	376	460	827	

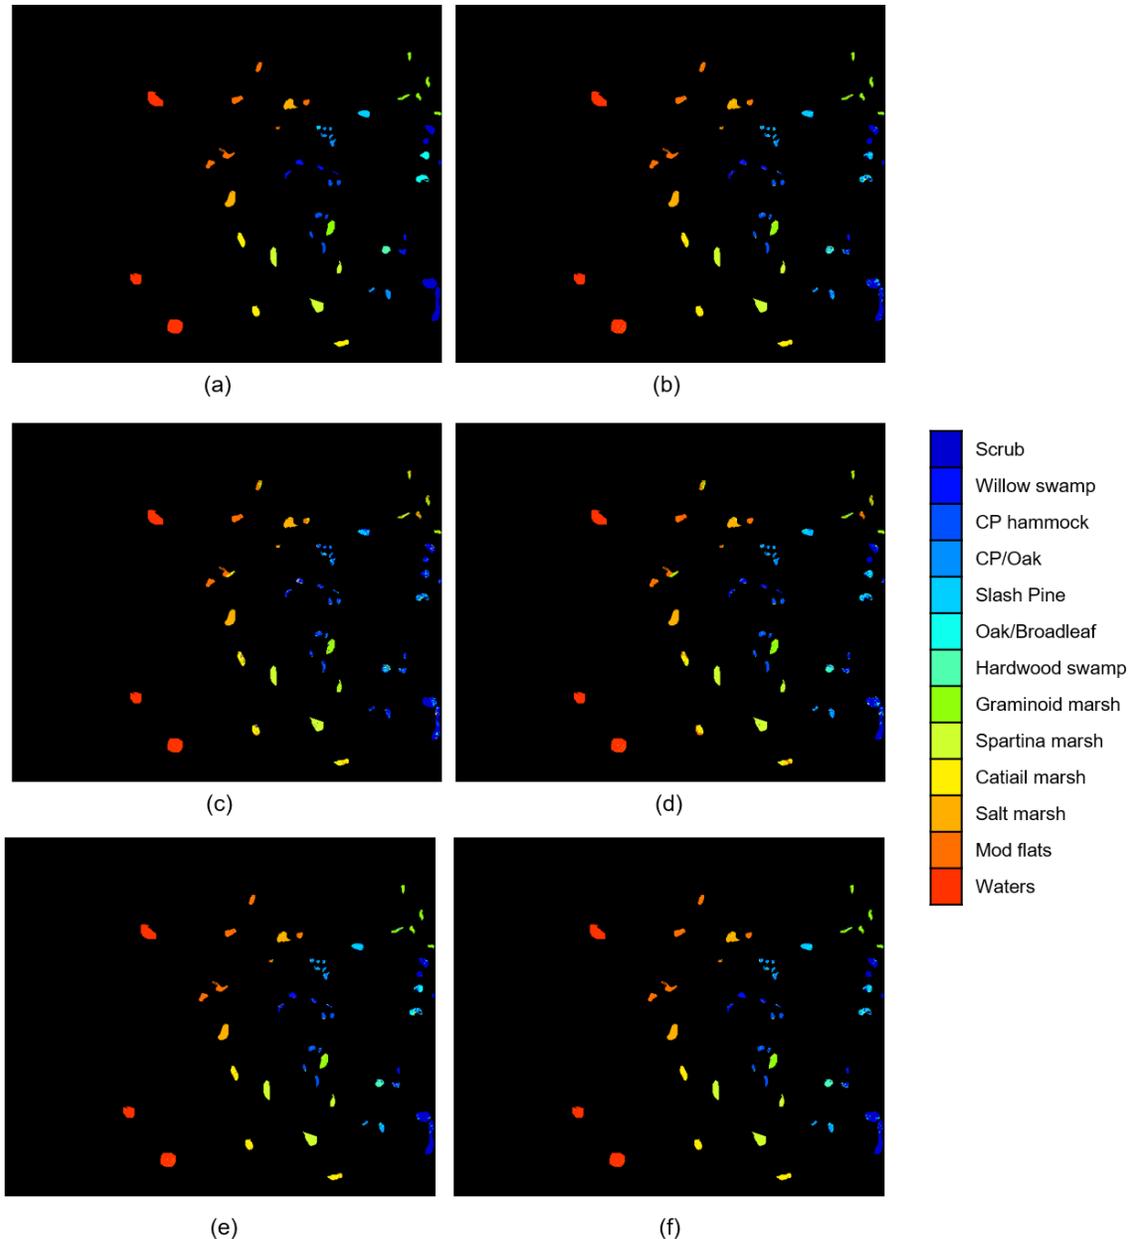


Figura 4-5: Mapas de clasificación para KSC: (a) Mapa de Referencia y Mapas obtenidos con SVM desde: (b) imagen original, (c) 50 PCA, (d) 20 descriptores de Fourier, (e) 47 descriptores Wavelet (1 nivel Coif1) y (f) 44 descriptores Wavelet (1 nivel Db1).

La Figura 4-5 presenta los mapas de clasificación para la imagen del Kennedy Space Center (KSC) obtenidos con SVM desde la imagen original y las imágenes con reducción de dimensiones de 50 componentes principales, 20 descriptores de Fourier y 2 nivel de descomposición para las Wavelet Daubechies (DB1) y Coiflets (COIF1). Se presenta estos

mapas porque, de acuerdo a los resultados presentados en la Tabla 4-11, son los mejores resultados para cada técnica comparada.

4.3.2 Clasificación con LDA

La Tabla 4-14 incluye los porcentajes de clasificación general obtenidos para la imagen hiperespectral KSC desde la imagen original (sin ningún proceso de reducción de dimensiones), usando de 5 a 50 componentes principales, usando de 5 a 50 descriptores de Fourier (FD) y usando los coeficientes de aproximación obtenidos con las familias wavelet Daubechies (DB1) y Coiflets (COIF1) con tres niveles de representación. En la tabla 4-11 se resaltan los mejores porcentajes de precisión obtenidos para cada técnica.

Tabla 4-14: Precisión general de clasificación de KSC usando LDA.

			Imagen Original				90.12	
m	PCA (%)	FD (%)	WT					
			nivel	m	COIF 1(%)	m	DB1 (%)	
5	36.84	63.01	1	90	91.54	88	91.43	
10	57.91	78.53	2	47	91.24	44	91.47	
20	70.45	83.28	3	26	90.19	22	89.77	
25	72.49	84.46						
30	73.58	84.07						
35	73.80	84.78						
40	74.01	85.01						
45	74.09	85.69						
50	75.88	85.74						

En la Tabla 4-14 se muestra que para la imagen original se obtuvo una precisión del 90.12% usando el clasificador LDA. Por su parte, usando la técnica de reducción de dimensiones PCA y descriptores de Fourier, el mejor resultado se obtuvo con 50 componentes alcanzado una precisión del 75.88% y el 85.74% respectivamente; ninguno de estos métodos supero la clasificación de la imagen sin ningún tipo de reducción de dimensiones. Adicionalmente, para los descriptores Wavelet, los mejores resultados se obtienen con 1 nivel de descomposición para ambas familias de wavelet. En este caso se logra un 91.54% y 91.47% para Coiflets (COIF1) y Daubechies (DB1) respectivamente.

Tabla 4-15: Precisión de clasificación por clase de KSC usando LDA.

	IO	PCA (%)	FD (%)	WAVELET					
				COIF1			DB1		
				50	50	1	2	3	1
A	91.9	86.4	88.2	92.1	91.2	90.4	91.8	91.1	91.1
B	84.0	71.2	77.6	82.2	78.5	75.8	80.4	80.8	81.3
C	81.3	52.2	77.8	90.0	90.0	84.8	89.1	90.0	88.7
D	67.5	31.7	59.9	64.8	67.8	61.7	63.9	67.8	61.7
E	62.1	40.7	63.4	64.8	65.5	71.7	66.2	65.5	65.5
F	70.7	30.6	66.0	80.6	83.0	82.5	83.0	82.5	80.1
G	83.8	53.2	93.6	95.7	96.8	94.7	95.7	97.9	94.7
H	87.7	72.7	80.7	88.4	87.1	88.1	87.1	87.1	90.2
I	94.2	87.6	88.0	97.4	96.6	94.7	97.4	96.6	89.1
J	96.3	80.8	95.6	95.9	95.3	93.4	96.2	95.1	93.1
K	96.9	90.5	90.2	97.1	96.8	95.0	96.3	96.3	95.2
L	94.6	66.9	84.5	94.9	94.7	94.9	96.0	96.9	91.8
M	99.9	98.0	98.3	100	99.9	100	100	99.9	100

La Tabla 4-15 presenta la precisión de clasificación para las 13 clases de la imagen hiperespectral KSC usando LDA. Se presenta la precisión para 50 componentes principales y descriptores de Fourier (FD), dado que no se logra un mejor resultado con pocos componentes (ver Tabla 4-14). Adicionalmente, la tabla incluye la precisión de clasificación por clase para la imagen original (IO) sin ningún método de reducción de dimensiones y las diferentes configuraciones para los descriptores de forma Wavelet (WT). En la Tabla 4-15 se puede observar que varias clases se identifican con mejores porcentajes de precisión usando los descriptores Wavelet. Por ejemplo, para las clases C (CP Hammock), E (Slash Pine), F (Oak/Broadleaf) y G (Hardwood swamp) se mejora en más de 10% la precisión de clasificación usando los descriptores Wavelet en vez de la imagen original. Por su parte, los descriptores de Fourier proporcionan mejores resultados de precisión que PCA; sin embargo, los resultados usando 50 descriptores de Fourier son comparables al usar la imagen original.

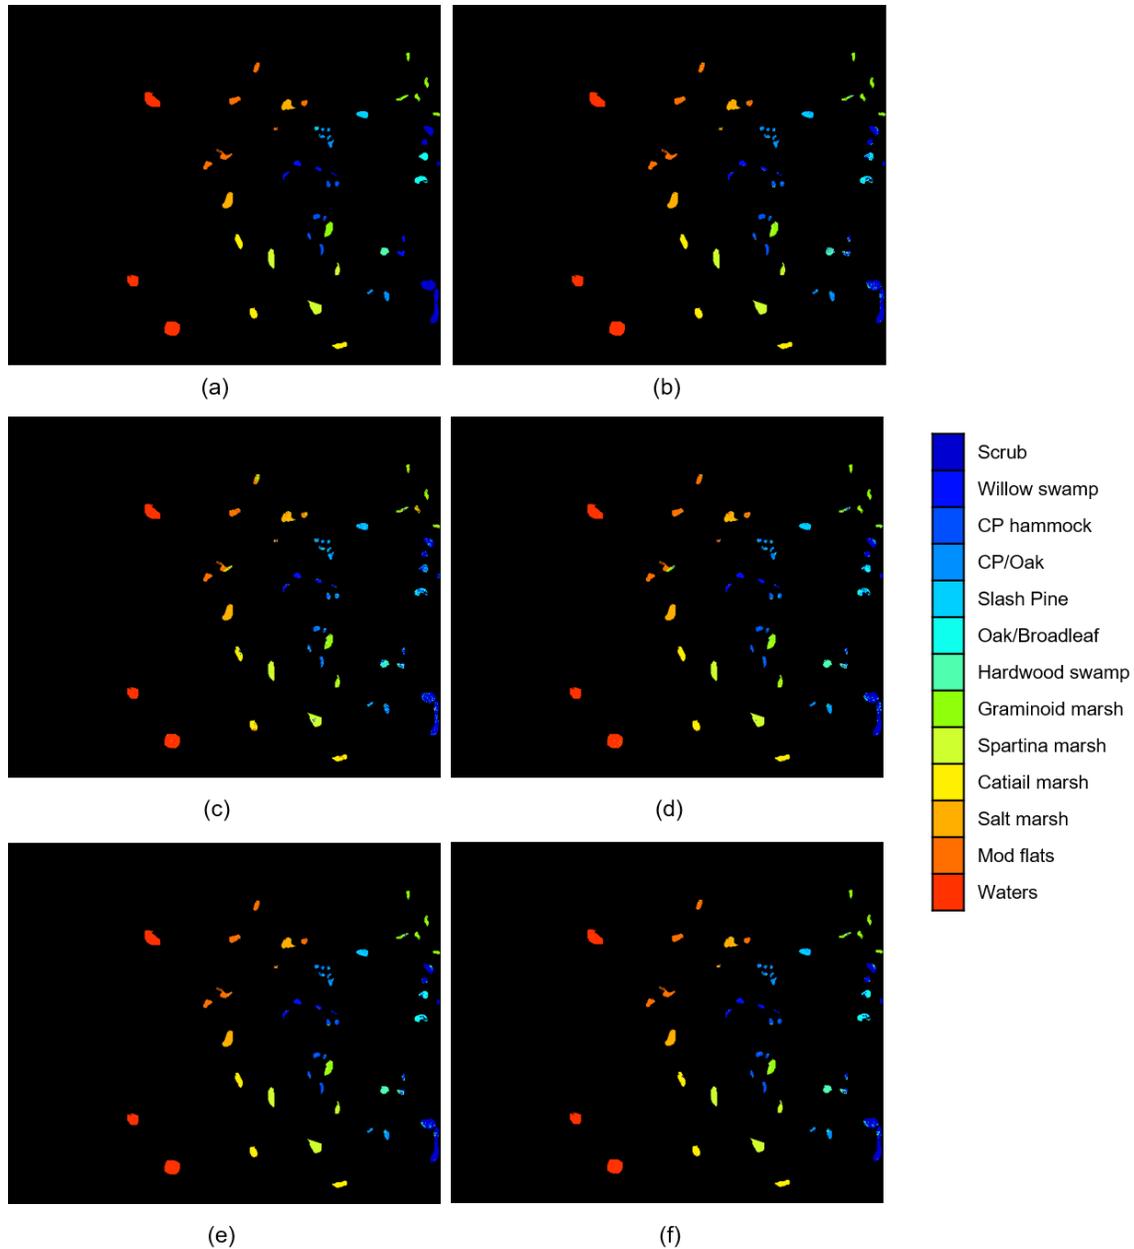


Figura 4-6: Mapas de clasificación para KSC: (a) Mapa de Referencia y Mapas obtenidos con LDA desde: (b) imagen original, (c) 50 PCA, (d) 50 descriptores de Fourier, (e) 90 descriptores Wavelet (1 nivel Coif1) y (f) 87 descriptores Wavelet (1 nivel Db1).

La Figura 4-6 presenta los mapas de clasificación para la imagen del Kennedy Space Center (KSC) obtenidos con LDA desde la imagen original y las imágenes con reducción de dimensiones de 50 componentes principales, 50 descriptores de Fourier y 1 nivel de descomposición para las Wavelet Daubechies (DB1) y Coiflets (COIF1). Se presenta estos

mapas porque, de acuerdo a los resultados presentados en la Tabla 4-14, son los mejores resultados para cada técnica comparada.

4.3.3 Discusión

De acuerdo a los resultados de clasificación obtenidos para la imagen hiperespectral capturada sobre el Kennedy Space Center (KSC) se puede notar la capacidad de los descriptores de forma Wavelet para encontrar un espacio de representación de más baja dimensión que mejora la identificación de los diferentes materiales. Tanto con el clasificador SVM como con LDA, el primer nivel de descomposición con COIF1 y DB1 mejoran los resultados de clasificación.

A pesar de que para la imagen KSC, los descriptores de Fourier no logran mejorar los resultados de clasificación de la imagen original, si presenta un mejor desempeño al compararse con el análisis de componentes principales. Al ser PCA una de las técnicas más empleadas para la reducción de dimensiones, los descriptores de Fourier se sugieren como una alternativa que proporciona una mejora en la representación.

Es importante anotar que para las diferentes imágenes los descriptores de forma Wavelet permiten incrementar el desempeño de los clasificadores. Aunque el porcentaje en que se mejora la precisión depende de la imagen y del clasificador. Con los resultados presentados anteriormente, se evidencia que SVM proporciona mejores resultados que LDA, por tanto, se puede recomendar el uso de SVM en conjunto con los descriptores de forma.

5. Conclusiones y recomendaciones

5.1 Conclusiones

El propósito principal de esta investigación fue diseñar una metodología para mejorar la clasificación de imágenes hiperespectrales, empleando una técnica de reducción de dimensiones que considere la forma de la firma espectral. Dado que es la forma de las firmas espectrales las que permiten discriminar los materiales en una superficie desde una imagen remotamente adquirida, se partió de la suposición que, al diseñar una nueva técnica de reducción de dimensiones, teniendo en cuenta la forma de la firma, se puede obtener un espacio de representación con menos dimensiones y que permita una mejora en la identificación de las clases.

Como técnica de reducción de dimensiones se propuso el uso de descriptores de forma. Los descriptores de forma son ampliamente usados para la representación de siluetas en 2 dimensiones. En este trabajo se extendió el uso de descriptores de forma de Fourier y Wavelet para caracterizar la forma de las firmas espectrales de una imagen.

Para evaluar el desempeño de estos descriptores para la clasificación de imágenes hiperespectrales se emplearon tres imágenes capturadas sobre diferentes escenarios. La primera de ellas, Indian Pines, es una imagen ampliamente usada para la comparación de métodos de clasificación que fue capturada sobre una zona agrícola. La segunda imagen fue Cuprite, capturada sobre una zona minera se caracteriza por una alta complejidad espacial y espectral. Por último, se usó una imagen capturada sobre el Centro Espacial Kennedy (KSC) que incluye diferentes tipos de pantanos y vegetación. Para realizar la evaluación de la reducción de dimensiones usando los descriptores de forma propuestos se emplearon dos clasificadores supervisados: LDA y SVM; adicionalmente, los resultados fueron comparados con los resultados de clasificación obtenidos desde la imagen original

sin ningún tipo de reducción de dimensiones y usando análisis de componentes principales.

Los resultados demuestran que los descriptores de forma basados en la transformada Wavelet mejoran la clasificación de los datos hiperespectrales. El porcentaje en que incrementa la precisión de clasificación varía de acuerdo a la imagen y el clasificador usado. Por su parte, los descriptores de forma de Fourier obtuvieron mejores resultados que PCA para Indian Pines y KSC; en el caso de Cuprite, los resultados fueron comparables. En la imagen Cuprite se evidencio que no era necesario la reducción de dimensión, dado que solo se emplean 138 de las 224 bandas capturadas por el sensor; estas bandas corresponden a las longitudes de ondas, que trabajos previos, han demostrado permiten la identificación de minerales.

5.2 Recomendaciones

Como trabajo futuro se plantea:

- Explorar otros descriptores de forma para la reducción de dimensiones de las firmas espectrales.
- Combinar los descriptores propuesto con descriptores espaciales para mejorar la identificación de materiales desde imágenes hiperespectrales.
- Realizar una comparación de los métodos propuestos con otras técnicas de reducción de dimensiones que se encuentran en la literatura; aunque PCA es la técnica de más amplio uso, se puede encontrar en la bibliografía técnicas más robustas.
- La optimización de los parámetros de los clasificadores como herramientas para comparar los métodos de reducción de dimensiones propuestos.
- Analizar el tiempo computacional de los descriptores de forma comparados con los métodos de reducción de dimensiones.
- Explorar métodos automáticos para seleccionar el número de descriptores de forma.
- Explorar el desempeño de los descriptores de forma para discriminar variabilidad de un tipo de material, ejemplo diferentes tipos de vegetación.

Bibliografía

- [1] J. Richards and X. Jia, *Remote Sensing Digital Image Analysis*. Springer, 2006.
- [2] R. A. Schowengerdt, *Remote Sensing: Methods and Models for Image Processing*. Academic Press, 2007.
- [3] L. Dale, A. Thewis, C. Boudry, I. Rotar, P. Dardenne, V. Baeten, and J. Pierna. "Hyperspectral imaging applications in agriculture and agro-food product quality and safety control: a review," *Applied Spectroscopy Reviews*, vol. 48, no. 2, pp. 142-159, 2013.
- [4] D. Manolakis and G. Shaw. "Detection algorithms for hyperspectral imaging applications". *IEEE Signal Processing Magazine*, vol. 19, no 1, p. 29-43, 2002.
- [5] M. Torres-Madronero. "Unsupervised unmixing analysis based on multiscale representation," Ph.D. dissertation, Department of Electrical and Computer Engineering, University of Puerto Rico, Mayaguez, PR, 2013.
- [6] M. Montalvo-Martinez. "Técnicas de visión artificial para la segmentación y detección de líneas de cultivo en imágenes agrícolas," PhD. Dissertation, Departamento de Arquitectura de Computadores y Automatica, Universidad Complutense de Madrid, España, 2015.
- [7] A. Plaza, J. Benediktsson, J. Boardman, J. Brazile, L. Bruzzone, G. Camps-Valls, J. Chanussot, M. Fauvel, P. Gamba, A. Gualtieri, M. Marconcini, J. Tilton, G. Trianni. "Recent advances in techniques for hyperspectral image processing," *Remote Sensing of Environment*, vol. 113, no. 1, pp. s110-s122, 2009.

- [8] G. Camps-Valls and L. Bruzzone. "Kernel-based methods for hyperspectral image classification," *IEEE Transactions on Geoscience and Remote Sensing*, 2005, vol. 43, no 6, p. 1351-1362.
- [9] J. Harsanyi and C. Chang. "Hyperspectral image classification and dimensionality reduction: an orthogonal subspace projection approach," *IEEE Trans. Geoscience and Remote Sensing*, vol.32, no. 4, pp. 779-785, 1994.
- [10] A. Ifarraguerri and C. Chang. "Multispectral and hyperspectral image analysis with projection pursuit," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 38, pp. 2529-2538, 2000.
- [11] C. Rodarmel, and J. Shan. "Principal component analysis for hyperspectral image classification," *Surveying and Land Information Science*, vol. 62, no. 2, pp. 115-122, 2002.
- [12] R. C. Gonzales and R. Woods. *Digital image processing*. Prentice Hall, 2002.
- [13] E. Posada. "Consideraciones en la selección de imágenes satelitales para los estudios ambientales," *Análisis geográficos*, no. 44, pp. 31, 2009.
- [14] A. Roman-Gonzalez and N. I. Vargas-Cuentas. "Análisis de imágenes hiperespectrales," *Revista Ingeniería & Desarrollo*, vol. 9, no. 35, pp. 14-17, 2013.
- [15] D. Landgrebe. "Hyperspectral Image Data Analysis," *IEEE Signal Processing Magazine*, vol. 19, no. 1, pp. 17-28, 2002.
- [16] S. Veraverbeke, E. N. Stavros and S. J. Hook, S. J. Assessing fire severity using imaging spectroscopy data from the Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) and comparison with multispectral capabilities. *Remote Sensing of Environment*, vol. 154, pp. 153-163, 2014.

- [17] J. S. Pearlman, P. S. Barry, C.C. Segal, J. Shepanski, D. Beiso, and S. L. Carman. "Hyperion, a space-based imaging spectrometer," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 41, no. 6, pp. 1160-1173, 2003.
- [18] S. K. Babey and C. D. Anger. "A compact airborne spectrographic imager (casi)," In *Quantitative Remote Sensing: An Economic Tool for the Nineties*, vol. 1, pp. 1028-1031, 1989.
- [19] D. G. Goodenough, K.O. Niemann, A. Dyk, G. Hobart, P. Gordon, M. Loisel and H. Chen. "Comparison of AVIRIS and AISA airborne hyperspectral sensing for above-ground forest carbon mapping," In *IGARSS 2008-2008 IEEE International Geoscience and Remote Sensing Symposium*, vol, 2, pp. II-128, 2008.
- [20] S. S. Chiang, C. I. Chang and I. W. "Unsupervised target detection in hyperspectral images using projection pursuit," *IEEE Transactions on Geoscience and Remote Sensing*, 39(7), 1380-1391, 2001.
- [21] N. Keshava and J. F. Mustard. "Spectral unmixing," *IEEE signal processing magazine*, 19(1), 44-57, 2002.
- [22] M. Faraklioti and M. Petrou. "Illumination invariant unmixing of sets of mixed pixels". *IEEE Transactions on Geoscience and Remote Sensing*, vol. 39, pp. 2227- 2234, 2001.
- [23] Y. H. Hu, H. B. Lee and F. L. Scarpace. "Optimal Linear Spectral Unmixing", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 37, pp. 639–644, 1999.
- [24] C. C. Borel and S. A. Gerstl. "Nonlinear spectral mixing models for vegetative and soil surfaces," *Remote Sensing of Environment*, vol. 47, pp. 403-416, 1994.
- [25] F. J. García-Haro and S. Sommer. "A fast canopy reflectance model to simulate realistic remote sensing scenarios," *Remote Sensing of Environment*, vol. 81, pp. 205-227, 2002.

- [26] S. V. Stehman. "Selecting and Interpreting Measures of Thematic Classification Accuracy," *Remote Sensing of Environment*, vol. 62, pp. 77-89, 1997.
- [27] J. Theiler and G. Gisler. "A contiguity-enhanced k-means clustering algorithm for unsupervised multispectral image segmentation," *Proc. SPIE*, vol. 3159, pp. 108-118, 1997.
- [28] K. Fukunaga and M.A. Narendra. "Branch and Bound Algorithm for Computing k-Nearest Neighbors," *IEEE transactions on Computers*, 750-753, 1975.
- [29] R. Duda and P. Hart. *Pattern classification and scene analysis*. Wiley, 1973.
- [30] H.E. Daniels, "The asymptotic efficiency of a maximum likelihood estimator," *Proceedings of the Fourth Berkeley Symposium on Mathematical Statistics and Probability*, vol. 1, pp. 151-163, 1961.
- [31] G. F. Hughes, "On the mean accuracy of statistical pattern recognizers," *IEEE Transactions on Information Theory*, IT-14, pp. 55-63, 1968.
- [32] S. Lu, K. Oki, Y. Shimizu, and K. Omasa, "Comparison between several feature extraction/classification methods for mapping complicated agricultural land use patches using airborne hyperspectral data," *International Journal of Remote Sensing*, vol. 28, no. 5, pp. 963-984, Jan. 2007.
- [33] S. Tadjudin and D. A. Landgrebe, "A decision tree classifier design for highdimensional data with limited training samples," *IEEE Geoscience and Remote Sensing Symposium*, Vol. 1, pp. 790-792, 27-31 May 1996.
- [34] M. Pal and G. Foody. "Feature selection for classification of hyperspectral data by SVM," *IEEE Trans. Geoscience and Remote Sensing*, vol. 48, no. 5, pp. 2297-2307, 2010.
- [35] P. J. Curran and J. L. Dungan. "Estimation of Signal-to-Noise: A New Procedure Applied to AVIRIS Data," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 27, pp. 620-628, 1989.

- [36] J. Wang and C. Chang. "Independent component analysis-based dimensionality reduction with applications in hyperspectral image analysis," *IEEE Trans. Geoscience and Remote Sensing*, vol. 44, no. 6, pp. 1586-1600, 2006.
- [37] C.-I Chang and Q. Du, "Estimation of number of spectrally distinct signal sources in hyperspectral imagery," *IEEE Trans. Geosci. Remote Sens.*, vol. 42, no. 3, pp. 608–619, Mar. 2004.
- [38] S. Kaewpijit, J. Le Moigne and T. El-Ghazawi. "Automatic reduction of hyperspectral imagery using wavelet spectral analysis," *IEEE Trans. Geoscience and Remote Sensing*, vol. 41, no. 4, pp. 863-871, 2003.
- [39] L. M. Bruce, C. H. Koger and J. Li. "Dimensionality reduction of hyperspectral data using discrete wavelet transform feature extraction," *IEEE Transactions on geoscience and remote sensing*, vol. 40, no. 10, pp- 2331-2338, 2002.
- [40] B. Du, L. Zhang, L. Zhang, T. Chen and K. Wu. "A discriminative manifold learning based dimension reduction method for hyperspectral classification," *International Journal of Fuzzy Systems*, vol. 14, no. 2, pp. 272-277, 2012.
- [41] W. Li, S. Prasad, J. Fowler and L. Mann. "Locality-preserving dimensionality reduction and classification for hyperspectral image analysis," *IEEE Trans. Geoscience and Remote Sensing*, vol. 50, no. 4, pp. 1185-1198, 2012.
- [42] J. B. Tenenbaum, V. Silva, and J. C. Langford. "A global geometric framework for nonlinear dimensionality reduction," *Science*, vol. 290, no. 2319, 2000.
- [43] S. T. Roweis and L. K. Saul, "Nonlinear dimensionality reduction by locally linear embedding," *Science*, vol. 290, no. 2323, 2000.
- [44] M. Belkin and P. Niyogi, "Laplacian eigenmaps and spectral techniques for embedding and clustering," *In Advances in neural information processing systems*, vol. 1, pp. 585-592, 2002.

- [45] M. Velez-Reyes and L. O. Jimenez. "Subset selection analysis for the reduction of hyperspectral imagery," In *Geoscience and Remote Sensing Symposium Proceedings, 1998. IGARSS'98. 1998 IEEE International*, vol. 3, pp. 1577-1581, 1998.
- [46] V. Vapnik, *Statistical learning theory*, Wiley, New York, 1998.
- [47] T. Blaschke, "Object based image analysis for remote sensing," *Journal of Photogrammetry and Remote Sensing*, vol. 65, pp. 2-16, 2010.
- [48] T. Blaschke, and J. Strobl, "What's wrong with pixels? Some recent developments interfacing remote sensing and GIS," *Zeitschrift fur Geoinformationssysteme*, vol. 14, no. 6, pp. 12-17, 2001.
- [49] M. Fauvel, Y. Tarabalka, J. Benediktsson, J. Chanussot, J. Tilton. "Advances in spectral-spatial classification of Hyperspectral Images," *Proceedings of the IEEE*, 2013, vol. 101, no. 3, pp.652-675, 2013.
- [50] J. A. Benediktsson, J. A. Palmason, and J. R. Sveinsson. "Classification of hyperspectral data from urban areas based on extended morphological profiles," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, no. 3, pp. 480-491, 2005.
- [51] M. Fauvel, J. Benediktsson, J. Chanussot, J. R. Sveinsson. "Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 46, no. 11, pp.3804-3814, 2008.
- [52] P. Soille, "Recent developments in morphological image processing for remote sensing," *Proc. SPIE*, vol. 7477, pp. 747702-1–747702-11, 2009.
- [53] L.O. Jimenez-Rodriguez and J. Rivera-Medina. "Integration of spatial and spectral information in unsupervised classification for multispectral and hyperspectral data," *Remote Sensing*, pp. 24-33, 1999.

- [54] G. Camps-Valls, L. Gomez-Chova, J. Muñoz-Marí, J. Vila-Francés, and J. Calpe-Maravilla. "Composite kernels for hyperspectral image classification," *IEEE Geoscience and Remote Sensing Letters*, vol. 3, no. 1, pp. 93-97, 2006.
- [55] M. Fauvel, J. Chanussot, and J. A. Benediktsson. "A spatial-spectral kernel-based approach for the classification of remote-sensing images," *Pattern Recognition*, vol. 45, no. 1, pp. 381-392, 2012.
- [56] J. C. Tilton, "Image segmentation by region growing and spectral clustering with a natural convergence criterion," in *Proc. of IEEE Geoscience and Remote Sensing Symposium*, pp. 1766-1768, vol. 4, 1998.
- [57] Y. Tarabalka, J. A. Benediktsson, J. Chanussot. "Spectral-spatial classification of hyperspectral imagery based on partitional clustering techniques," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 47, no. 8, pp. 2973-2987, 2009.
- [58] S. Valero, "Hyperspectral Image Representation and Processing with Binary Partition Trees", *IEEE Trans. Image Processing*, vol. 22, no. 4, 2013.
- [59] R. Ji, Y. Gao, R. Hong, Q. Liu, D. Tao, and X. Li. "Spectral-spatial constraint hyperspectral image classification," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 52, no. 3, pp. 1811-1824, 2014.
- [60] J. M. Duarte-Carvajalino, G. Sapiro, M. Vélez-Reyes, P. E. Castillo. "Multiscale representation and segmentation of hyperspectral imagery using geometric partial differential equations and algebraic multigrid methods,". *IEEE Transactions on Geoscience and Remote Sensing*, vol. 46, no. 8, pp. 2418-2434, 2008.
- [61] M. C. Torres-Madroño. "A comparative study of multiscale representations for spatial-spectral classification of hyperspectral imagery,". *DYNA*, 2017.

[62] Y. Rui, T. S. Huang, S. Chang. "Image retrieval: Current techniques, promising directions, and open issues," *Journal of visual communication and image representation*, vol. 10, no. 1, pp. 39-62, 1999.

[63] B. M. Mehtre, M. S. Kankanhalli, W. Lee. "Shape measures for content based image retrieval: a comparison," *Information Processing & Management*, vol. 33, no 3, pp. 319-337, 1997.

[64] D. Zhang, G.Lu. "Pattern Recognition 37", pp. 1-19, 2004.