

# Hyperspectral Images Classification Based on Inception Network and Kernel PCA

D. Ruiz, B. Bacca, and E. Caicedo

**Abstract**—Recent advances in remote sensing have shown great potential for different kind of applications like vegetation and crop supervision. Using hyperspectral images (HSI), this process can be performed over large areas of land, allowing for a fast and non-invasive analysis of variables such as water stress, diseases, type of crops, among many others. In this context, representative spatial-spectral features are crucial to develop the data classification process of hyperspectral remote sensing images. In this way, the use of deep learning networks has shown a remarkable classification performance in many applications as the processing of hyperspectral images. In this paper, a data classification model that use kernel PCA (K-PCA) and inception network architecture to generate deep spatial-spectral features is proposed. The features generated are used to label the different kind of classes into the HSI. The labeling process uses a logistic regression (LR) algorithm. This model was validated using six different datasets. The experiments performed shown that the proposed strategy allows improving the data classification performance regarding the results obtained by the traditional stacked layer model of convolutional neural networks (CNN). Quantitatively speaking, the overall accuracy over all experiments of the proposed model for all tested datasets is greater than 92%.

**Index Terms**—Convolutional neural network, Deep learning, Dimensionality reduction, Hyperspectral images, Inception network, Principal component analysis, Remote sensing.

## I. INTRODUCCIÓN

LAS imágenes hiperespectrales (HSI) son conjuntos de datos que usualmente están compuestos por cientos de bandas o canales que contienen la información capturada en diferentes regiones del espectro electromagnético. El uso adecuado de esta información posibilita el desarrollo de un gran número de aplicaciones como: levantamiento de mapas en entornos urbanos, gestión ambiental, análisis de cultivos, detección de minerales, entre muchos otros [1]. En este tipo de aplicaciones el problema se centra en la identificación de la clase a la que pertenece cada píxel de la imagen, utilizando un número reducido de muestras etiquetadas de entrenamiento [2].

D. Ruiz, Grupo de investigación en percepción y sistemas inteligentes, Universidad del Valle, Santiago de Cali, Colombia, ruiz.david@correounivalle.edu.co.

B. Bacca, Grupo de investigación en percepción y sistemas inteligentes, Universidad del Valle, Santiago de Cali, Colombia, bladimir.bacca@correounivalle.edu.co.

E. Caicedo, Grupo de investigación en percepción y sistemas inteligentes, Universidad del Valle, Santiago de Cali, Colombia, eduardo.caicedo@correounivalle.edu.co.

Sin embargo, debido a la alta dimensionalidad y a la variabilidad tanto espectral como espacial inherente a las HSI, es necesario utilizar estrategias de clasificación robustas que permitan abordar las características particulares de estos conjuntos de datos [3].

La clasificación de datos en imágenes hiperespectrales es un campo de investigación bastante activo y de fundamental importancia para el desarrollo de sistemas de sensado remoto. En este sentido, las propuestas relacionadas con sistemas de clasificación basados en HSI son diversas y usualmente están compuestos por una etapa de extracción de características y una etapa final de clasificación [1].

Las características generadas a partir de una HSI pueden ser de tipo espectral o espectral-espacial. Las características espectrales son aquellas generadas a partir de la información espectral de cada píxel de la imagen y no tienen en cuenta las relaciones espaciales entre los píxeles vecinos [4]. Por otro lado, las características espectrales-espaciales son generadas a partir del vector espectral de cada píxel en la imagen y la información proporcionada por sus vecinos más próximos. En [5], [6] y [7] se muestra como los sistemas basados en características espectrales-espaciales generan mejores resultados de clasificación en comparación con sistemas que utilizan información puramente espectral.

En los últimos años, debido al surgimiento de los algoritmos de *deep learning* (DL), los métodos de extracción de características espectrales-espaciales basados en técnicas de *machine learning* (ML) están siendo adaptados rápidamente al contexto de los sistemas de sensado remoto basados en HSI [2], [8]–[11]. Su capacidad para aprender características de forma automática permite obtener una mejor interpretación de los datos y simplifica el proceso de clasificación en comparación con métodos tradicionales de procesamiento [12].

En [13], se presenta por primera vez un sistema de extracción de características que utiliza algoritmos de DL para la clasificación de datos en HSI. En [13], el algoritmo de análisis de componentes principales (PCA) es utilizado como etapa inicial de reducción dimensional, seguido por un *stacked autoencoder* (SAE) que permite encontrar una representación profunda de las características espectrales-espaciales de la HSI. Las características generadas son etiquetadas utilizando un clasificador del tipo *logistic regression* (LR), que es entrenado a través del algoritmo *backpropagation*. En [14], se presenta un modelo de extracción de características denominado *contextual deep learning* (CDL). CDL es construido a través de varias capas de *autoencoders* y utiliza información de la vecindad para obtener una representación espectral-espacial de los datos de la HSI. Como capa de salida, el modelo propuesto por [14] utiliza un clasificador LR. En

[11], se presenta un modelo que utiliza *deep belief networks* (DBN) para obtener un conjunto de características espectrales-espaciales.

Una de las técnicas de DL más utilizadas para la extracción de características espectrales-espaciales profundas son las redes neuronales convolucionales (CNN). En [10], se presenta uno de los modelos más populares que utiliza PCA y CNN para el procesamiento de una HSI. PCA es todavía uno de los algoritmos más populares en el desarrollo de procesos de reducción dimensional [10]; sin embargo en [15] se muestra que el uso de una generalización no lineal del algoritmo tradicional de PCA, denominado *kernel PCA* (K-PCA), genera mejores resultados, en comparación con PCA tradicional, facilitando los procesos posteriores de clasificación.

En [2], los autores proponen el uso de *balanced local discriminant embedding* (BLDE) como algoritmo de reducción dimensional y CNN para la extracción profunda de características y posterior clasificación. En [8], se propone una CNN con *kernel 3D* con el objetivo de robustecer la etapa de extracción de características. Sin embargo, todas estas propuestas que hacen uso de CNN utilizan un vecindario de tamaño fijo, lo cual debido a la alta dimensionalidad y a la variabilidad espectral y espacial de la información contenida en una HSI, podría no ser suficientemente flexible para trabajar sobre diferentes conjuntos de datos lo cual implica el análisis de diferentes tipos de variables [16].

Para abordar este problema, es necesario utilizar un sistema que permita trabajar con ventanas de vecindarios variables. En este sentido, el uso de arquitecturas de CNN más robustas y eficientes como una arquitectura red *inception* podría resultar más pertinente para la clasificación de datos en HSI. Este modelo de red profunda ha mostrado un gran desempeño en el procesamiento de diferentes tipos de bases de datos [16].

El objetivo principal de este artículo es presentar modelo de clasificación de datos en HSI que utiliza K-PCA como etapa inicial de reducción dimensional y una arquitectura de red *inception* para generar características espectrales-espaciales profundas. Los datos de salida de la red *inception* son etiquetados por medio de un clasificador LR, de acuerdo con la clase a la que pertenece cada uno de los píxeles de la imagen. El uso de una red *inception* permite analizar los datos de la HSI utilizando ventanas de vecindad de diferentes tamaños, lo cual proporciona una gran flexibilidad para trabajar con diferentes conjuntos de datos y abordar posibles problemas de sobreajuste en los procesos de entrenamiento [16].

Este artículo está estructurado de la siguiente manera. En la sección II, se presentan todos los elementos relacionados con la implementación del sistema de clasificación de HSI propuesto en este trabajo. En la sección III se presentan los resultados de desempeño obtenidos con el algoritmo propuesto en comparación con dos sistemas de clasificación tradicionalmente utilizados en el procesamiento HSI: SAE convolucional y CNN de capas apiladas. Las conclusiones y los trabajos futuros son presentados en la sección IV.

## II. CLASIFICACIÓN DE HSI USANDO K-PCA Y UNA RED INCEPTION

En este artículo, se propone un modelo de clasificación para HSI que utiliza K-PCA como etapa de reducción

dimensional y una arquitectura de red *inception* para generar características espectrales-espaciales profundas. Las características generadas son etiquetadas utilizando un clasificador del tipo *logistic regression* (LR), a partir del cual se obtiene el mapa final de clasificación. En la Fig. 1 se presenta el diagrama de bloques del sistema de clasificación propuesto.

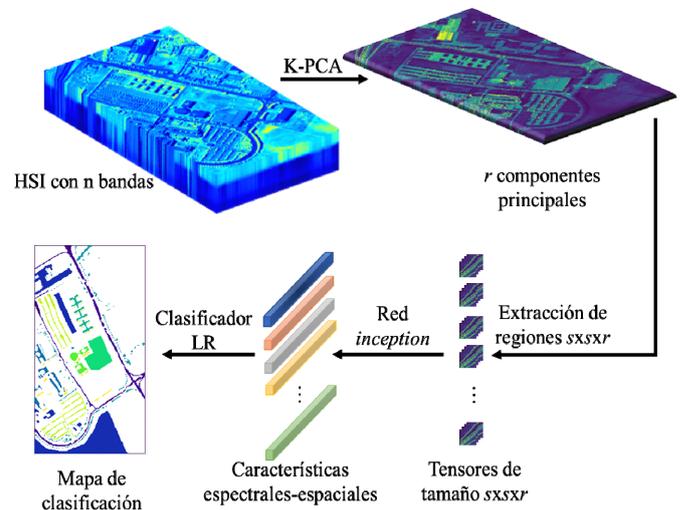


Fig. 1. Esquema de clasificación propuesto basado en kernel PCA y una arquitectura red *inception*.

Las HSI son conjuntos de datos altamente dimensionales que usualmente están compuestos por cientos de bandas espectrales. Una HSI de  $145 \times 145$  píxeles y 220 bandas espectrales tiene aproximadamente 4,6 millones de datos. Este volumen de información genera varios desafíos en el procesamiento y análisis de los datos. Esto, unido a la escasez o dificultad para el levantamiento de muestras en tierra que permitan etiquetar la información y desarrollar los posteriores procesos de entrenamiento, hacen que los desarrollos relacionados con sistemas de clasificación en HSI se vean muchas veces afectados por el fenómeno de *Hughes* [17]. Este fenómeno ocurre cuando el tamaño del conjunto de muestras de entrenamiento no es lo suficientemente grande respecto a la dimensión de los datos de entrada, generando un ajuste deficiente de los parámetros del clasificador y produciendo como resultado una reducción significativa en la precisión del proceso [1], [3]. Para mitigar este fenómeno, generalmente se realiza una etapa inicial de reducción dimensional de los datos hiperespectrales [15]. En este sentido, PCA es uno de los algoritmos de reducción dimensional más utilizados en este tipo de procesos [10]. PCA es un método basado en proyecciones que transforma la información altamente dimensional en información de pocas dimensiones. Los procesos de este tipo modifican los datos originales mediante la generación de proyecciones o combinaciones lineales [1]. Las ventajas de PCA son su baja complejidad y la ausencia de parámetros de configuración, sin embargo PCA solo considera estadísticas de segundo orden, lo cual puede limitar la efectividad del método [15]. En este sentido, estudios como el presentado en [15] han demostrado que la versión no lineal de PCA, denominada *kernel PCA* (K-PCA), es capaz de capturar

estadísticas de orden superior y por lo tanto generar una mejor representación del conjunto de datos original.

Tal como se muestra en la Fig. 1, el sistema de clasificación propuesto utiliza como etapa inicial de preprocesamiento un algoritmo de K-PCA para realizar la reducción dimensional de los datos de entrada. Los componentes principales son organizados de acuerdo con el nivel de varianza de mayor a menor. De esta manera, la mayor parte de la información contenida en la HSI es capturada en unos pocos componentes principales. El esquema de clasificación propuesto utiliza los  $r$  componentes principales que contengan como mínimo el 95% de la varianza total de los datos [18].

Posteriormente al proceso inicial de reducción dimensional desarrollado con K-PCA, es necesario implementar un algoritmo robusto y eficiente que permita extraer características representativas de los elementos de interés en la imagen hiperespectral; teniendo en cuenta las características particulares de las HSI, como son la poca variabilidad entre clases y la alta variabilidad entre los datos de una misma clase.

Para este fin, en aplicaciones de procesamiento de imágenes, las CNN son el método más utilizado para la extracción de características profundas [19]. En general, la arquitectura de las CNN tradicionales consiste en un conjunto de capas apiladas, donde la salida de cada capa es utilizada como entrada de la siguiente capa. De esta manera, los datos de entrada son procesados de manera progresiva, capa por capa, generando características complejas que representan aspectos abstractos del conjunto original de datos. Una capa convolucional típica está conformada por los siguientes elementos [12]: primero, una etapa de convolución en la cual la entrada es operada con un conjunto de filtros parametrizables, con el objetivo de extraer lo que se conoce como mapa de características; Segundo, una transformación no lineal o función de activación como *rectified linear unit* (ReLU) que se utiliza para enfatizar la salida de los filtros y elimina comportamientos atípicos. Finalmente, un operador de agrupamiento que combina características de elementos cercanos y reduce el mapa de características [19]. La implementación en detalle de una CNN bidimensional se presenta en [8].

Añadir varias capas convolucionales apiladas permite a la CNN generar una representación más profunda y abstracta de los datos de entrada. Todas las capas de la CNN son entrenadas utilizando el algoritmo *backpropagation*. El mapa de características obtenido finalmente a la salida de la red es vectorizado y utilizado como elemento de entrada de un algoritmo de clasificación [19]. Sin embargo, los modelos de CNN tradicionales utilizan filtros de tamaño fijo en cada una de las capas de la red, lo cual para conjuntos de datos como las HSI puede no ser lo suficientemente flexible para obtener un desempeño adecuado en el proceso de clasificación [16]. En este sentido, el uso de arquitecturas de redes de aprendizaje como *inception* resultan de gran utilidad.

*Inception* es un tipo popular de arquitectura de redes neuronales convolucionales. Este tipo de arquitectura está conformado por un conjunto de módulos convolucionales, los cuales operan como pequeñas redes independientes, divididas en varias ramas de procesamiento simultáneo. En el contexto de este trabajo, la arquitectura *inception* ayuda a la red a

aprender características espectrales y espaciales que pueden ser utilizadas en un proceso de clasificación. La principal ventaja de una red *inception* es que proporciona la posibilidad de operar la entrada con múltiples tamaños de filtros, permitiendo generar mapas de características más flexibles y que contienen mucha más información que un mapa de características generado por una arquitectura tradicional [16].

La estructura básica de una red *inception* es mostrada en la Fig. 2, la cual está compuesta de cuatro ramas de procesamiento. La primera es una rama que carece de convolución espacial y que opera solo sobre la información espectral de cada uno de los píxeles de la HSI (solo realiza una convolución 1x1). La segunda rama utiliza una convolución 1x1 seguida de una convolución de tamaño 5x5. La tercera rama inicia con una operación de agrupamiento seguido de una convolución de 3x3. Finalmente, la cuarta rama está conformada por una operación de convolución 1x1, seguida de dos capas de convolución 3x3. Las salidas de cada una de las ramas son concatenadas en un solo bloque que apila de manera secuencial las características resultantes. [19].

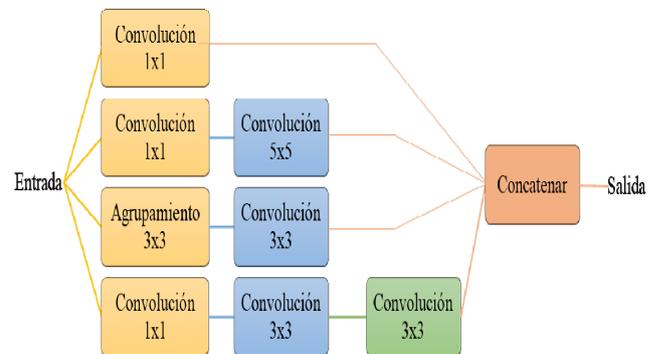


Fig. 2. Arquitectura red inception.

Como se muestra en la Fig. 1, para cada píxel  $(x,y)$  en los  $r$  componentes principales obtenidos con K-PCA, se extrae una subregión de tamaño  $s \times s \times r$ . De esta manera, el tensor resultante contiene la información espacial de los vecinos más próximos a cada píxel  $(x,y)$ . Cada una de las subregiones de tamaño  $s \times s \times r$ , centradas en cada píxel  $(x,y)$ , es utilizada como elemento de entrada a la arquitectura de red *inception* presentada en la Fig. 2. Esto se realiza con el objetivo de generar un conjunto de características espectrales y espaciales que resulte representativo para un proceso posterior de clasificación. Con base a el trabajo presentado en [12], en donde se realiza una comparación del desempeño obtenido en un proceso de clasificación de una HSI, usando una CNN tradicional y subregiones de distintos tamaños; para el esquema de clasificación propuesto se utilizan subregiones de tamaño  $9 \times 9 \times r$ . Los resultados obtenidos en [12] indican que valores más altos de  $s$  no afectan significativamente el desempeño del sistema. De esta forma, cada píxel en la HSI es procesado como una subregión de dimensión  $s \times s \times r$ , por medio de filtros convolucionales de diferentes tamaños, los cuales no deben superar las dimensiones de la ventana  $s \times s$ .

Finalmente, las características espectrales y espaciales obtenidas a la salida de la red *inception* son etiquetadas utilizando un clasificador LR. El clasificador permite

cuantificar la relación existente entre cada una de las variables categóricas de salida y el vector de entrada. Entonces el tamaño de la capa de salida en el esquema de clasificación propuesto es igual al número de clases presente en la HSI. Por tanto, el vector de salida del clasificador LR representa la distribución de probabilidad del vector de características de entrada respecto a cada una de las clases. La salida con el valor más alto es la clase a la cual se asigna el vector de entrada [19].

### III. RESULTADOS Y DISCUSIÓN

El objetivo de las pruebas es evaluar el desempeño del algoritmo propuesto basado en K-PCA y una red *inception* para la clasificación de los distintos tipos de vegetación, cultivos o edificios presentes en diferentes HSI. Para esto, el algoritmo de clasificación propuesto se validó utilizando seis conjuntos de datos de imágenes hiperespectrales ampliamente conocidas y de acceso público [20][21]: *Indian Pines*, *Salinas Valley*, *Pavia University*, *Salinas Valley A*, *Pavia Center* y *Urban*. Estos conjuntos de datos fueron tomados por el *Airborne Visible-Infrared Imaging Spectrometer Sensor* (AVIRIS) y el *Reflective Optics System Imaging Spectrometer* (ROSIS).

#### A. Descripción de los Datos de Prueba

El primer conjunto de datos pertenece al lugar de prueba de *Indian Pines* en el noroeste de Indiana [20]. La Fig. 3 muestra la imagen RGB y su respectivo *ground truth* con diferentes tipos de vegetación y cultivos.



Fig. 3. Conjunto de datos *Indian Pines*. Derecha: Imagen RGB. Izquierda: *Ground truth* con regiones de: alfalfa, maíz 1, maíz 2, maíz 3, césped 1, árboles, césped 2, heno, avena, soya 1, soya 2, soya 3, trigo, madera, edificios, piedra.

Este conjunto de datos tiene imágenes de 145 píxeles x 145 píxeles y 220 bandas espectrales en un rango de longitud de onda entre 400 nm y 2500 nm.

El segundo conjunto de datos pertenece al lugar de prueba *Salinas Valley* en California [20]. La Fig. 4 muestra la imagen RGB y el *ground truth* con los diferentes cultivos en los datos de *Salinas Valley*. Este conjunto de datos está compuesto por imágenes de 512 píxeles x 217 píxeles, 204 bandas de reflectancia espectral, capturadas en un rango de longitud de onda entre 400 nm a 2500 nm y 3.7 m de resolución espacial por píxel.

El tercer conjunto de datos pertenece al lugar de prueba de *Pavia University* [20], en el norte de Italia. La Fig. 5 muestra

la imagen RGB y el *ground truth* con diferentes tipos de elementos, como vegetación y edificios. Este conjunto de datos tiene imágenes de 610 píxeles x 340 píxeles y 103 bandas de reflectancia espectral.



Fig. 4. Conjunto de datos *Salinas Valley*. Derecha: Imagen RGB. Izquierda: *Ground truth* con regiones de: brócoli 1, brócoli 2, barbecho1, barbecho2, barbecho3, rastrojo, apio, uvas, soya, maíz, lechuga 1, lechuga 2, lechuga 3, lechuga 4, viñedo 1, viñedo 2.



Fig. 5. Conjunto de datos *Pavia University*. Derecha: Imagen RGB. Izquierda: *Ground truth* con regiones de: asfalto, pradera, grava, árboles, metal, tierra, pavimento, ladrillo, sombras.

El cuarto conjunto de datos pertenece al lugar de prueba *Salinas Valley Section A* en California [21]. Este es un conjunto de datos tomado de una pequeña sección perteneciente a el mismo lugar de captura de *Salinas Valley*. Está compuesto por imágenes de 86 píxeles x 83 píxeles y 204 bandas espectrales. La Fig. 6 muestra la imagen RGB y su respectivo *ground truth* con diferentes clases presentes en la imagen.



Fig. 6. Conjunto de datos *Salinas Valley A*. Derecha: Imagen RGB. Izquierda: *Ground truth* con regiones de: brócoli, maíz, lechuga 1, lechuga 2, lechuga 3, lechuga 4.

El quinto conjunto de datos pertenece al lugar de prueba de *Pavia Center* en Italia [21]. La Fig. 7 muestra la imagen RGB y el *ground truth* con diferentes tipos elementos comunes en un paisaje urbano. Este conjunto de datos tiene imágenes de 1096 píxeles x 1096 píxeles y 103 bandas de reflectancia espectral.

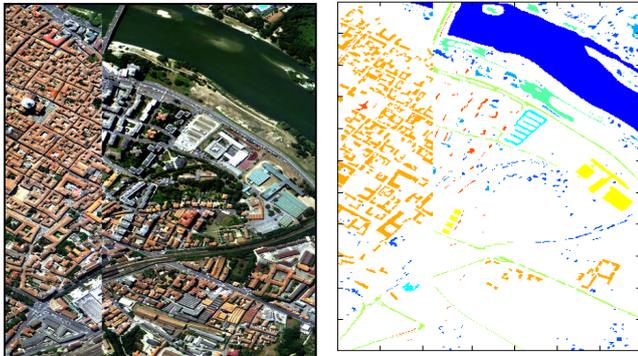


Fig. 7. Conjunto de datos *Pavia Center*. Derecha: Imagen RGB. Izquierda: *Ground truth* con regiones de: agua, arboles, asfalto, ladrillo, pavimento, baldosa, sombras, pradera, tierra.

Finalmente, sexto conjunto de datos pertenece al lugar de prueba llamado *Urban* y fue generado por el *Geospatial Research Laboratory* de Estados Unidos [21]. Está compuesto por imágenes de 307 píxeles x 307 píxeles y 162 bandas espectrales, capturadas en un rango de longitud de onda entre 400 nm a 2500 nm y 2.0 m de resolución espacial por píxel.

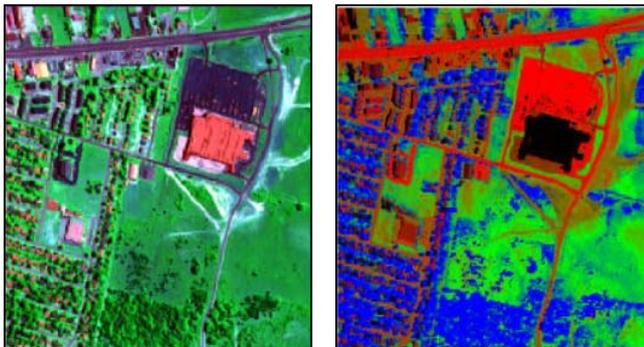


Fig. 8. Conjunto de datos *Urban*. Derecha: Imagen RGB. Izquierda: *Ground truth* con regiones de: asfalto, césped, arboles, tejado, metal, tierra.

**B. Desempeño del Algoritmo de Clasificación**

El desempeño de este sistema de clasificación descrito en la Fig.1 es comparado con dos esquemas convencionales de clasificación, que son ampliamente utilizados en el procesamiento de HSI. El primero hace uso de PCA y un SAE convolucional (SCAE) como el reportado en [9] y el segundo hace uso de PCA y una CNN bidimensional como el modelo referenciado en [8]. Los procesos de entrenamiento, validación y prueba de las redes profundas utilizadas en los experimentos utilizan el 30%, 30% y 40% de los datos respectivamente.

La Tabla I muestra las diferentes clases de elementos presentes en cada una las HSI utilizadas para las pruebas, así como el número total de muestras correspondiente a cada una de las clases.

Teniendo en cuenta las clases de elementos a identificar presentados en la Tabla I, y el proceso de clasificación propuesto en este artículo, las Tablas II, III, IV, V, VI y VII muestran los resultados de precisión para cada uno de los conjuntos de datos, considerando diez ejecuciones de los algoritmos de clasificación. En estas tablas, La columna uno muestra las clases en la escena, la columna dos muestra los resultados obtenidos con un sistema que usa PCA y un SCAE, la columna tres muestra los resultados para PCA y una CNN bidimensional. La columna cuatro presenta la precisión para el sistema propuesto que utiliza K-PCA y la arquitectura red *inception*. Con el objetivo de obtener un proceso de reducción dimensional estándar, los dos esquemas de reducción dimensional (PCA y K-PCA) utilizados en los sistemas de clasificación comparados en este estudio, utilizan los *r* componentes principales que contengan como mínimo el 95% de la varianza total de los datos [18]. En este sentido los conjuntos de datos de *Indian Pines*, *Salinas Valley* y *Pavia University* son representados respectivamente por nueve, tres y seis componentes principales para PCA y diecisiete, cuatro y diez componentes para K-PCA. Los conjuntos de datos de *Salinas Valley A*, *Pavia Center* y *Urban* son representados respectivamente por 4, 5 y 18 componentes principales para PCA y 4, 10 y 15 componentes para K-PCA.

TABLA I  
CLASES Y NO. DE MUESTRAS EN CADA CONJUTO DE DATOS

<i>Indian Pines</i>		<i>Salinas Valley</i>		<i>Pavia University</i>	
Clase	Muestras	Clase	Muestras	Clase	Muestras
Alfalfa	46	Brócoli 1	2009	Asfalto	6631
Maíz 1	1428	Brócoli 2	3726	Pradera	18649
Maíz 2	830	Barbecho1	1976	Grava	2099
Maíz 3	237	Barbecho2	1394	Arboles	3064
Césped 1	483	Barbecho3	2678	Metal	1345
Arboles	730	Rastrojo	3959	Tierra	5029
Césped 2	28	Apio	3579	Pavimento	1330
Heno	478	Uvas	11271	Ladrillo	3682
Avena	20	Soya	6203	Sombras	947
Soya 1	972	Maíz	3278	-	-
Soya 2	2455	Lechuga 1	1068	-	-
Soya 3	593	Lechuga 2	1927	-	-
Trigo	205	Lechuga 3	916	-	-
Madera	1265	Lechuga 4	1070	-	-
Edificios	386	Viñedo 1	7268	-	-
Piedra	93	Viñedo 2	1807	-	-
<i>Pavia Center</i>		<i>Salinas Valley A</i>		<i>Urban</i>	
Clase	Muestras	Clase	Muestras	Clase	Muestras
Agua	824	Brócoli	391	Asfalto	18570
Arboles	820	Maíz	1343	Césped	35198
Asfalto	816	Lechuga 1	616	Arboles	22468
Ladrillo	808	Lechuga 2	1525	Tejado	6821
Pavimento	808	Lechuga 3	674	Metal	2436
Baldosa	1260	Lechuga 4	799	Tierra	8756
Sombras	476	-	-	-	-
Pradera	824	-	-	-	-
Tierra	820	-	-	-	-

En las Tablas II - VII, los índices de comparación utilizados fueron: precisión general (OA), precisión promedio (AA) e índice kappa ( $k$ ), que son medidas estadísticas ampliamente utilizadas para comparar los resultados obtenidos en el procesamiento de imágenes hiperespectrales. Se espera que OA y AA tengan el mayor valor porcentual posible y  $k$  tenga valores cercanos a uno [3], [22], [23].

TABLA II  
INDICES DE DESEMPEÑO: AA, OA y  $k$  PARA EL CONJUNTO DE DATOS INDIAN PINES

Clase	PCA+SCAE %	PCA+CNN %	K-PCA+ Inception %
Alfalfa	85.87+/-5.21	53.48+/-38.7	96.3+/-3.56
Maíz 1	89.96+/-2.20	82.75+/-20.3	86.06+/-6.51
Maíz 2	87.28+/-10.69	84.19+/-11.8	95.57+/-3.02
Maíz 3	91.37+/-2.29	89.70+/-15.5	97.76+/-1.9
Césped 1	79.37+/-18.06	86.3+/-19.9	82.51+/-12.2
Arboles	90.99+/-7.26	94.73+/-9.8	99.30+/-0.4
Césped 2	91.07+/-4.89	33.57+/-34.0	91.79+/-6.08
Heno	94.64+/-0.53	99.92+/-0.2	99.56+/-0.54
Avena	93.00+/-3.50	12.00+/-19.9	78.5+/-22.9
Soya 1	91.35+/-3.79	91.10+/-6.5	93.68+/-3.11
Soya 2	89.66+/-6.17	83.08+/-20.3	95.02+/-2.95
Soya 3	89.74+/-2.06	77.15+/-23.5	83.95+/-7.57
Trigo	92.85+/-3.30	89.41+/-31.4	100+/-0
Madera	87.28+/-12.56	91.00+/-11.8	94.58+/-5.89
Edificios	86.30+/-8.28	87.02+/-15.7	92.80+/-4.59
Piedra	92.96+/-1.93	96.88+/-7.4	95.70+/-2.63
<b>AA</b>	<b>89.59+/-5.79</b>	<b>78.27+/-17.9</b>	<b>92.69+/-5.24</b>
<b>OA</b>	<b>89.18+/-2.52</b>	<b>86.44+/-7.3</b>	<b>92.97+/-0.73</b>
<b>k</b>	<b>0.8838+/-0.028</b>	<b>0.8463+/-8.1</b>	<b>0.9198+/-0.83</b>

TABLA III  
INDICES DE DESEMPEÑO: AA, OA y  $k$  PARA EL CONJUNTO DE DATOS SALINAS VALEY

Clase	PCA+SCAE %	PCA+CNN %	K-PCA+ Inception %
Brócoli 1	73.54+/-43.45	84.13+/-33.4	99.86+/-0.07
Brócoli 2	73.49+/-41.46	86.62+/-27.4	99.06+/-0.58
Barbecho1	92.42+/-5.17	89.07+/-11.9	97.28+/-1.33
Barbecho2	98.39+/-2.09	99.64+/-0.3	99.31+/-0.54
Barbecho3	98.29+/-1.39	98.43+/-3.9	99.22+/-0.6
Rastrojo	99.35+/-0.73	100+/-0	99.11+/-1.07
Apio	87.99+/-31.26	98.42+/-4.8	99.06+/-0.8
Uvas	86.17+/-5.52	89.94+/-10.4	92.28+/-0.9
Soya	98.60+/-1.19	99.95+/-0.05	98.5+/-1.85
Maíz	90.73+/-5.48	98.28+/-2.1	95.83+/-3.19
Lechuga 1	75.51+/-22.65	81.94+/-37.7	98.09+/-0.78
Lechuga 2	99.40+/-1.07	98.12+/-5.3	98.38+/-1.16
Lechuga 3	99.76+/-0.34	99.90+/-0.2	99.16+/-0.59
Lechuga 4	84.19+/-22.17	99.20+/-1.4	98.84+/-0.49
Viñedo 1	81.55+/-8.09	77.21+/-20.7	91.33+/-7.56
Viñedo 2	93.44+/-4.85	98.88+/-1.7	98.06+/-1.48
<b>AA</b>	<b>89.55+/-12.31</b>	<b>93.73+/-10.1</b>	<b>97.71+/-1.94</b>
<b>OA</b>	<b>88.83+/-4.56</b>	<b>92.16+/-3.9</b>	<b>96.25+/-1.62</b>
<b>k</b>	<b>0.8757+/-0.051</b>	<b>0.912+/-0.04</b>	<b>0.958+/-1.79</b>

Los índices AA, OA y  $k$  presentados en las Tablas II - VII, muestran que el algoritmo de clasificación de HSI propuesto basado en K-PCA y una arquitectura de red *inception* generan porcentajes de precisión superiores al 92 por ciento e índices  $k$  cercanos a uno.

Esto permite concluir que el algoritmo propuesto es una alternativa eficiente y viable para un sistema de clasificación de imágenes hiperespectrales de diferentes tipos.

TABLA IV  
INDICES DE DESEMPEÑO: AA, OA y  $k$  PARA EL CONJUNTO DE DATOS PAVIA UNIVERSITY

Clase	PCA+SCAE %	PCA+CNN %	K-PCA+ Inception %
Asfalto	97.63+/-0.72	99.72+/-0.46	99.33+/-0.55
Pradera	96.16+/-3.72	98.89+/-1.1	99.53+/-0.45
Grava	95.18+/-3.54	95.89+/-6.8	97.24+/-2.88
Arboles	98.17+/-1.31	99.63+/-0.2	94.57+/-2.84
Metal	59.97+/-51.61	100+/-0	99.78+/-0.14
Tierra	89.62+/-6.73	97.70+/-1.9	95.27+/-8.54
Pavimento	98.27+/-0.73	99.81+/-0.18	97.79+/-1.46
Ladrillo	97.04+/-0.47	99.42+/-0.9	98.62+/-0.47
Sombras	89.40+/-31.42	99.62+/-0.5	98.82+/-0.65
<b>AA</b>	<b>91.27+/-11.14</b>	<b>98.97+/-1.34</b>	<b>97.88+/-2.0</b>
<b>OA</b>	<b>94.57+/-2.19</b>	<b>98.91+/-0.65</b>	<b>98.39+/-1.35</b>
<b>k</b>	<b>0.9282+/-0.029</b>	<b>0.986+/-0.86</b>	<b>0.978+/-1.8</b>

TABLA V  
INDICES DE DESEMPEÑO: AA, OA y  $k$  PARA EL CONJUNTO DE DATOS SALINAS VALLE A

Clase	PCA+SCAE %	PCA+CNN %	K-PCA+ Inception %
Brócoli	100+/-0	100+/-0	99.77+/-0.08
Maíz	99.48+/-0.91	100+/-0	99.64+/-0.51
Lechuga 1	94.76+/-8.96	95.80+/-13.13	99.38+/-1.10
Lechuga 2	96.43+/-8.12	100+/-0	99.51+/-0.33
Lechuga 3	99.99+/-0.05	100+/-0	100+/-0
Lechuga 4	99.97+/-0.05	90.00+/-31.60	98.22+/-0.95
<b>AA</b>	<b>98.44+/-3.01</b>	<b>97.63+/-7.5</b>	<b>99.42+/-0.50</b>
<b>OA</b>	<b>98.24+/-2.24</b>	<b>98.02+/-6.2</b>	<b>99.42+/-0.22</b>
<b>k</b>	<b>0.9781+/-0.028</b>	<b>0.9753+/-0.08</b>	<b>0.9927+/-0.003</b>

TABLA VI  
INDICES DE DESEMPEÑO: AA, OA y  $k$  PARA EL CONJUNTO DE DATOS PAVIA CENTER

Clase	PCA+SCAE %	PCA+CNN %	K-PCA+ Inception %
Agua	59.35+/-51.10	100+/-0	99.98+/-0.01
Arboles	66.61+/-46.02	91.51+/-6.38	97.13+/-0.90
Asfalto	75.67+/-40.25	91.99+/-7.16	92.12+/-3.73
Ladrillo	84.40+/-16.33	97.90+/-3.87	99.27+/-0.43
Pavimento	85.70+/-30.99	98.79+/-2.59	99.31+/-0.31
Baldosa	94.33+/-1.47	99.64+/-0.36	99.52+/-0.18
Sombras	91.46+/-5.26	98.06+/-1.42	99.80+/-0.17
Pradera	59.84+/-51.50	99.71+/-0.81	99.76+/-0.13
Tierra	49.12+/-51.78	99.87+/-0.19	98.18+/-0.64
<b>AA</b>	<b>74.05+/-32.75</b>	<b>97.50+/-2.53</b>	<b>98.34+/-0.72</b>
<b>OA</b>	<b>65.39+/-28.72</b>	<b>99.10+/-0.44</b>	<b>99.50+/-0.069</b>
<b>k</b>	<b>0.6027+/-0.299</b>	<b>0.9873+/-0.006</b>	<b>0.993+/-0.0009</b>

TABLA VII  
INDICES DE DESEMPEÑO: AA, OA y  $k$  PARA EL CONJUNTO DE DATOS URBAN

Clase	PCA+SCAE %	PCA+CNN %	K-PCA+ Inception %
Asfalto	88.67+/-3.99	89.63+/-4.77	95.02+/-3.91
Césped	87.95+/-3.36	90.64+/-2.94	95.76+/-2.84
Arboles	76.05+/-26.84	81.36+/-7.96	95.17+/-3.39
Tejado	51.96+/-36.02	77.75+/-5.67	91.11+/-5.04
Metal	19.40+/-21.04	54.89+/-4.20	75.43+/-15.02
Tierra	48.22+/-25.97	65.83+/-6.50	85.38+/-13.53
<b>AA</b>	<b>62.04+/-19.53</b>	<b>76.68+/-5.34</b>	<b>89.64+/-7.29</b>
<b>OA</b>	<b>77.19+/-8.68</b>	<b>84.07+/-1.14</b>	<b>93.65+/-1.24</b>
<b>k</b>	<b>0.6881+/-0.130</b>	<b>0.7858+/-0.015</b>	<b>0.9151+/-0.017</b>

Las Fig. 9, Fig. 10, Fig. 11, Fig. 12, Fig. 13 y Fig. 14 muestran el desempeño, durante el proceso de entrenamiento, para cada uno de los algoritmos comparados, utilizando los conjuntos de datos de *Indian Pines*, *Salinas Valley*, *Pavia*

University, Salinas Valley A, Pavia Center y Urban. La imagen superior (función de costo) corresponde a el valor de la función de costo y la imagen inferior (precisión entrenamiento) representa la precisión alcanzada por la red durante cada iteración del proceso de entrenamiento. Al observar estos resultados, se muestra que el algoritmo propuesto tiene un mejor desempeño durante el proceso de entrenamiento, logrando una mejor convergencia y precisión con respecto al algoritmo tradicional.

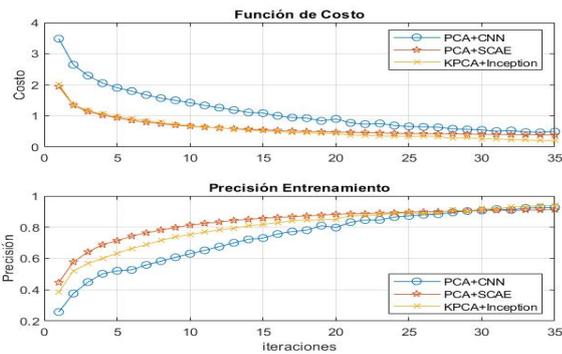


Fig. 9. Desempeño de la función de costo y precisión obtenida en el entrenamiento del conjunto de datos *Indian Pines*.

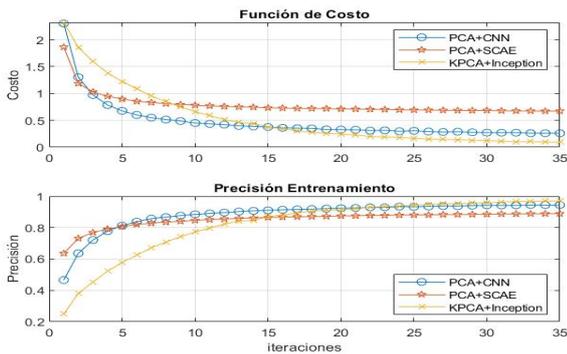


Fig. 10. Desempeño de la función de costo y precisión obtenida en el entrenamiento del conjunto de datos *Salinas Valley*.

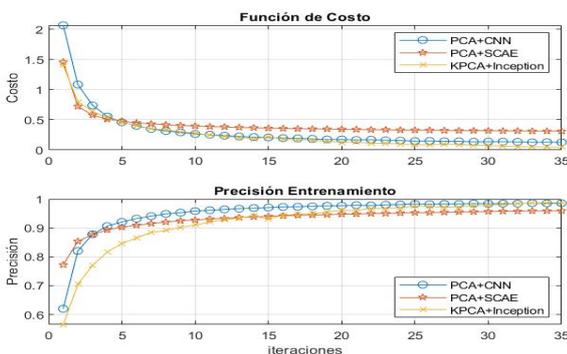


Fig. 11. Desempeño de la función de costo y precisión obtenida en el entrenamiento del conjunto de datos *Pavia University*.

En este momento, los clasificadores recién entrenados, se utilizan para obtener los mapas de clasificación que se muestran en la Fig. 15. La Fig. 15 muestra los mapas de clasificación generados por cada uno de los algoritmos comparados, considerando los seis conjuntos de datos de

imágenes hiperespectrales utilizados en este trabajo. En la Fig. 15, la columna uno muestra *ground truth* de la escena, la columna dos muestra los resultados para PCA y un SCAE, la columna tres muestra los resultados del sistema que usa PCA y una CNN bidimensional tradicional. Finalmente, la columna cuatro muestra los resultados obtenidos con el sistema de clasificación basado en K-PCA y la arquitectura red *inception* propuesta en este trabajo.

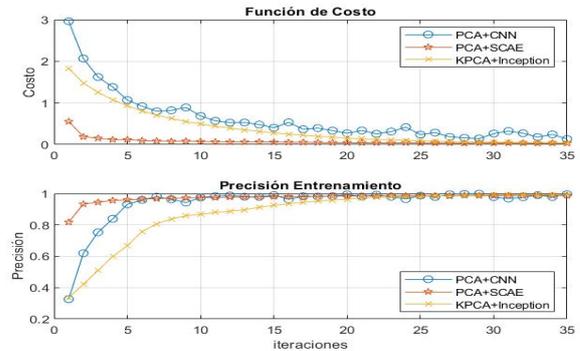


Fig. 12. Desempeño de la función de costo y precisión obtenida en el entrenamiento del conjunto de datos *Salinas Valley A*.

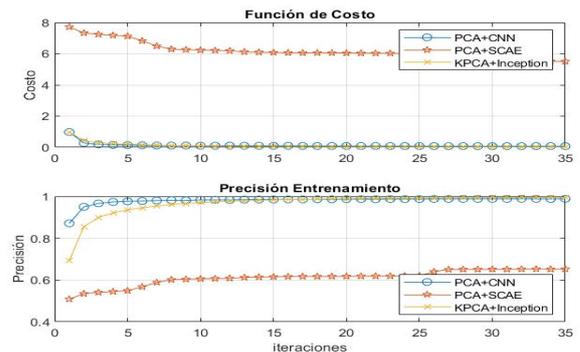


Fig. 13. Desempeño de la función de costo y precisión obtenida en el entrenamiento del conjunto de datos *Pavia Center*.

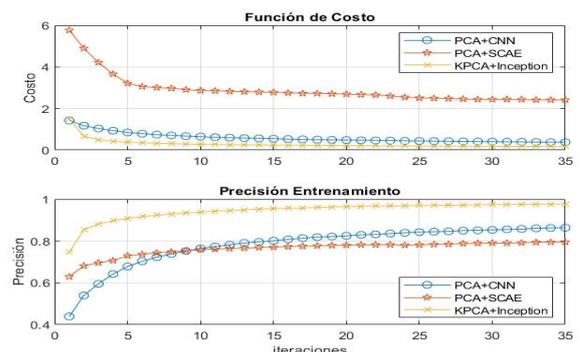


Fig. 14. Desempeño de la función de costo y precisión obtenida en el entrenamiento del conjunto de datos *Urban*.

Con el fin de obtener una mejor apreciación visual del resultado del proceso de clasificación, la Fig. 16 muestra las diferencias entre el *ground truth* y los mapas de clasificación. Las imágenes fueron obtenidas utilizando un proceso de resta común. Al igual que en la Fig. 15, cada una de las columnas representa los resultados de cada algoritmo probado. Las zonas

negras indican puntos que tienen diferencias con respecto al *ground truth*. Los mapas de clasificación de la Fig. 15 y las diferencias en las imágenes de la Fig. 16 permiten concluir que el uso de K-PCA y la arquitectura red *inception* proporciona un mejor mapa de clasificación, con menos errores y que se parece más al *ground truth*, corroborando los resultados presentados en las Tablas II-IV.

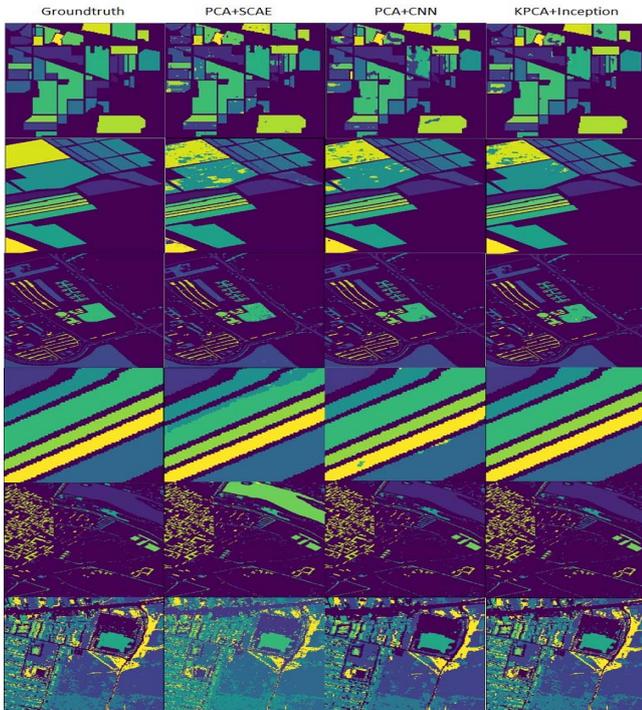


Fig. 15. Mapas de clasificación obtenidos para *Indian Pines*, *Salinas Valley*, *Pavia University*, *Salinas A*, *Pavia Center* y *Urban*.

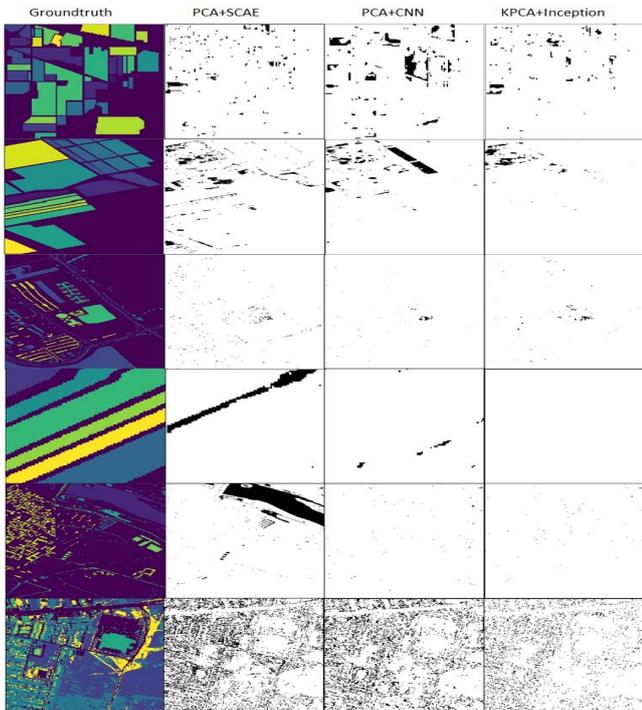


Fig. 16. Diferencias entre el *ground truth* y los mapas de clasificación.

C. Desempeño del Algoritmo de Clasificación Respecto al Número de Componentes Principales

Con el objetivo de determinar el comportamiento de los diferentes sistemas de clasificación comparados en este estudio, frente a variaciones en el número de componentes principales, se realizan experimentos para determinar el índice de precisión general (OA) respecto al número de componentes utilizados.

En las Fig. 17, Fig. 18, Fig. 19, Fig. 20, Fig. 21 y Fig. 22 se presentan los resultados obtenidos para cada uno de los seis conjuntos de datos utilizados. Cada una de las gráficas presenta el desempeño general de los tres esquemas de clasificación comparados, respecto al número de componentes principales utilizados en la ejecución del experimento.

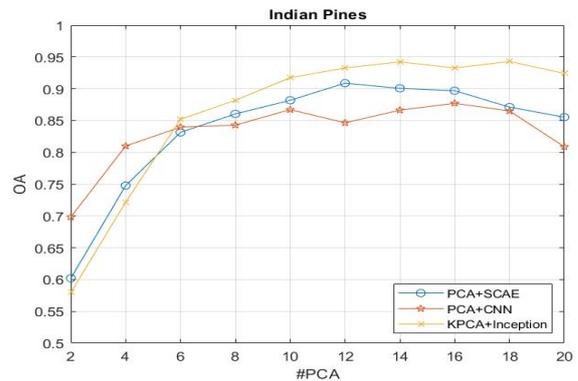


Fig. 17. Desempeño de los clasificadores respecto al número de componentes principales para el conjunto de datos *Indian Pines*.

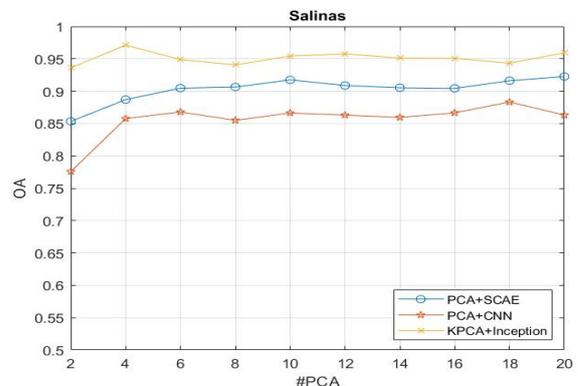


Fig. 18. Desempeño de los clasificadores respecto al número de componentes principales para el conjunto de datos *Salinas Valley*.

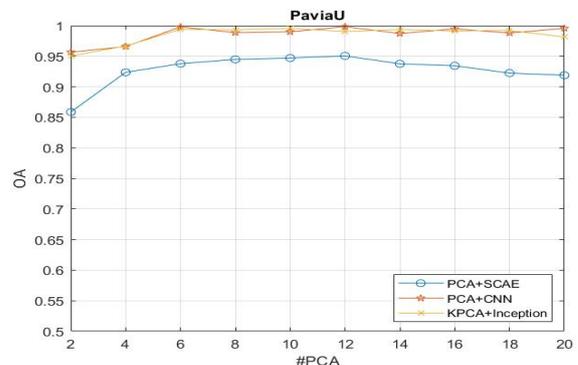


Fig. 19. Desempeño de los clasificadores respecto al número de componentes principales para el conjunto de datos *Pavia University*.

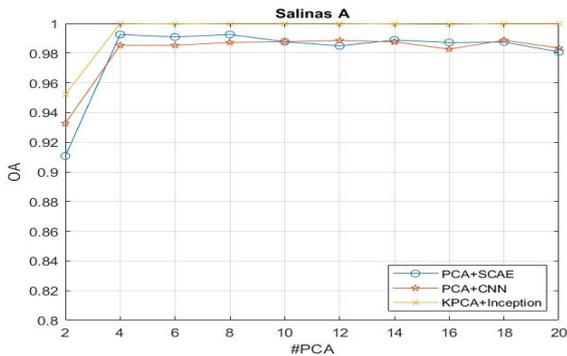


Fig. 20. Desempeño de los clasificadores respecto al número de componentes principales para el conjunto de datos *Salinas Valley A*.

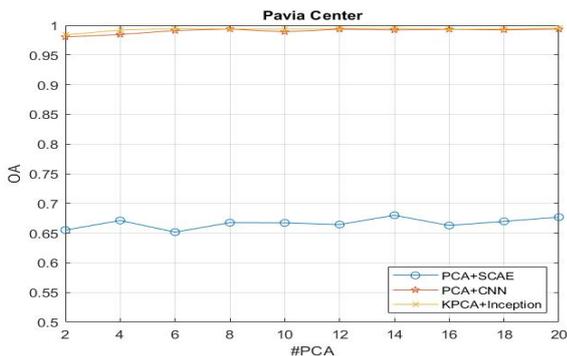


Fig. 21. Desempeño de los clasificadores respecto al número de componentes principales para el conjunto de datos *Pavia Center*.

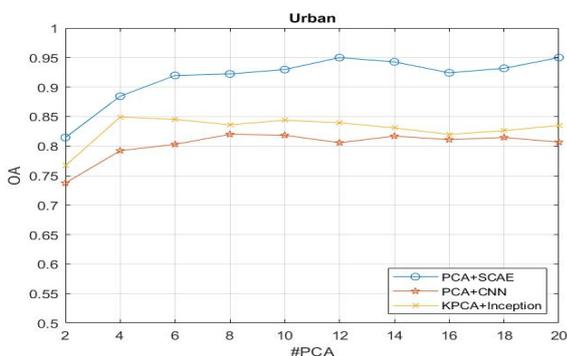


Fig. 22. Desempeño de los clasificadores respecto al número de componentes principales para el conjunto de datos *Urban*.

Las gráficas permiten observar que el incremento de número de componentes principales mejora el índice de precisión general de los sistemas de clasificación. Sin embargo, después de un determinado número de componentes la precisión tiende a permanecer constante independientemente del número de dimensiones utilizadas.

Este comportamiento permite concluir que el uso de la varianza total de los datos [18] es un referente adecuado para la selección automática del número de componentes principales.

#### IV. CONCLUSIONES

Para el proceso de reconocimiento y clasificación de imágenes hiperespectrales cuya riqueza en datos radica en su alta dimensionalidad, es fundamental la obtención de características espectrales y espaciales representativas, que

pueden ser utilizadas en aplicaciones de sensado remoto de vegetación o cultivos, mapeo de entornos urbanos, detección de cambios en el paisaje, entre otros. De igual manera, El uso de redes de aprendizaje profundo ha demostrado desempeños de clasificación notables en muchas aplicaciones como el procesamiento de imágenes hiperespectrales. En este sentido, este artículo presentó un modelo de clasificación de imágenes hiperespectrales que utiliza K-PCA como elemento de reducción dimensional y una arquitectura de red *inception* para generar características espectrales espaciales profundas. Estas características son etiquetadas utilizando un clasificador LR.

Con el fin de probar el sistema propuesto, se utilizaron seis imágenes hiperespectrales bien conocidas y de acceso público [20], [21]: *Indian Pines*, *Salinas Valley*, *Pavia University*, *Salinas Section A*, *Pavia Center* y *Urban*. Los índices de comparación utilizados son los siguientes: precisión general (OA), precisión promedio (AA) e índice kappa (k), que son medidas estadísticas ampliamente utilizadas para evaluar los resultados obtenidos en el procesamiento de imágenes hiperespectrales.

Los resultados obtenidos muestran que el sistema de clasificación de HSI propuesto en este trabajo es una herramienta poderosa para la extracción eficiente características espaciales y espectrales de una HSI, generando índices de precisión superiores al 92% en todas las imágenes de prueba. El algoritmo de clasificación basado en K-PCA y una red *inception* logra una precisión general del 92.9%, 96.2 y 98.3% para los conjuntos de datos de *Indian Pines*, *Salinas Valley* y *Pavia University*, respectivamente y una precisión de 99.4%, 99.5%, y 93.6% para los conjuntos de datos de *Salinas Section A*, *Pavia Center* y *Urban*.

Los resultados consignados en las Tablas II – VII, muestran que la principal fortaleza del sistema de clasificación basado en K-PCA y una red *inception*, propuesto en este trabajo, es el incremento obtenido en los índices de desempeño. Los resultados muestran que para los conjuntos de datos de *Indian Pines*, *Salinas Valley*, *Pavia University*, *Salinas Section A*, *Pavia Center* y *Urban*, el esquema de clasificación propuesto en este trabajo proporciona una mejora del 6.5%, 4.1%, -0.5%, 1.4%, 34.1% y 9.6% con respecto a los resultados obtenidos por el sistema que utiliza PCA y un modelo CNN tradicional y una mejora de 3.8%, 7.4%, 3.8%, 1.2%, 0.4% y 16.5% respecto al sistema de utiliza PCA y SFAE. Estos resultados son importantes ya que los conjuntos de datos incluyen diferentes clases de vegetación, cultivos y elementos de entornos urbanos, que tienen una gran similitud entre clases, lo que genera un gran desafío para el proceso de clasificación. El análisis de los datos muestra que para el conjunto de datos de *Pavia University*, los índices de comparación obtenidos con el esquema de clasificación propuesto resultan ser muy similares a los obtenidos con el esquema tradicional de clasificación basado en PCA y una CNN. Esto puede deberse a que el conjunto de datos está compuesto por clases con una mayor variabilidad entre ellas, lo cual resulta más adecuado para el funcionamiento de distintos esquemas supervisados de clasificación.

En síntesis, los resultados obtenidos muestran que el algoritmo de clasificación basado en K-PCA y una arquitectura de red *inception* genera una mejor precisión y desempeño con respecto a arquitecturas de clasificación basadas en SFAE y

CNN tradicionales. Del mismo modo, las pruebas muestran que K-PCA es una estrategia eficiente de representación inicial de características, que unida a una arquitectura red *inception* es una alternativa confiable y flexible para ser utilizada en un sistema de clasificación de imágenes hiperespectrales. Sin embargo, la principal debilidad del esquema de clasificación propuesto radica en el costo computacional elevado asociado al uso de K-PCA como elemento inicial de reducción dimensional.

En base a estos elementos y a los resultados obtenidos en el desarrollo de este trabajo, consideramos que las próximas investigaciones relacionadas con sistemas de procesamiento de imágenes hiperespectrales, deben orientarse a robustecer los esquemas de extracción de características, enfocándose principalmente en los del tipo no supervisado, para así generar algoritmos que no dependan completamente de un conjunto de datos etiquetados de entrenamiento, lo cual es en muchas ocasiones una de las principales limitantes al momento de desarrollar este tipo de sistemas.

#### REFERENCIAS

- [1] P. S. Thenkabail, J. G. Lyon, and A. Huete, *Hyperspectral remote sensing of vegetation*. New York: CRC Press Taylor & Francis Group, 2012.
- [2] W. Zhao and S. Du, "Spectral-Spatial Feature Extraction for Hyperspectral Image Classification: A Dimension Reduction and Deep Learning Approach," *IEEE Trans. Geosci. Remote Sens.*, vol. 54, no. 8, pp. 4544–4554, 2016.
- [3] P. Ghamisi *et al.*, "Advances in Hyperspectral Image and Signal Processing: A comprehensive overview of the state of the art," *IEEE Geosci. Remote Sens. Mag.*, no. december, pp. 37–78, 2017.
- [4] L. He, J. Li, C. Liu, and S. Li, "Recent Advances on Spectral Spatial Hyperspectral Image Classification: An Overview and New Guidelines," pp. 1–19, 2017.
- [5] G. Mercier and M. Lennon, "Support Vector Machines for Hyperspectral Image Classification with Spectral-based kernels," in *IEEE Geoscience & Remote Sensing Symposium*, 2003, vol. 1, pp. 288–290.
- [6] G. Moser and S. B. Serpico, "Combining support vector machines and Markov random fields in an integrated framework for contextual image classification," *IEEE Trans. Geosci. Remote Sens.*, vol. 51, no. 5, pp. 2734–2752, 2013.
- [7] P. Ghamisi, J. A. Benediktsson, and M. O. M. O. Ulfarsson, "Spectral-Spatial Classification of Hyperspectral Images Based on Hidden Markov Random Fields," *IEEE Trans. Geosci. Remote Sens.*, vol. 52, no. 5, pp. 2565–2574, 2014.
- [8] Y. Chen, H. Jiang, C. Li, X. Jia, and P. Ghamisi, "Deep Feature Extraction and Classification of Hyperspectral Images Based on Convolutional Neural Networks," *IEEE Trans. Geosci. Remote Sens.*, vol. 54, no. 10, pp. 6232–6251, 2016.
- [9] R. Kemker and C. Kanan, "Self-Taught Feature Learning for Hyperspectral Image Classification," *IEEE Trans. Geosci. Remote Sens.*, vol. 55, no. 5, pp. 2693–2705, 2017.
- [10] A. Romero, C. Gatta, G. Camps-valls, and S. Member, "Unsupervised Deep Feature Extraction for Remote Sensing Image Classification," *IEEE Trans. Geosci. Remote Sens. 1 Unsupervised*, vol. 54, no. 3, pp. 1–14, 2015.
- [11] X. Jia, Y. Chen, and X. Zhao, "Spectral-Spatial Classification of Hyperspectral Data Based on Deep Belief Network," vol. 8, no. 6, pp. 2381–2392, 2015.
- [12] E. Aptoula, M. C. Ozdemir, and B. Yanikoglu, "Deep Learning with Attribute Profiles for Hyperspectral Image Classification," *IEEE Geosci. Remote Sens. Lett.*, vol. 13, no. 12, pp. 1970–1974, 2016.
- [13] Y. Gu, Y. Chen, Z. Lin, X. Zhao, G. Wang, and Y. Gu, "Deep Learning-Based Classification of Hyperspectral Data," *Ieee J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 7, no. 6, pp. 2094–2107, 2014.
- [14] X. Ma, J. Geng, and H. Wang, "Hyperspectral image classification via contextual deep learning," *EURASIP J. Image Video Process.*, vol. 2015, no. 1, p. 20, 2015.

- [15] M. Fauvel, J. Chanussot, and J. A. Benediktsson, "Kernel principal component analysis for the classification of hyperspectral remote sensing data over urban areas," *EURASIP J. Adv. Signal Process.*, vol. 2009, no. 2, 2009.
- [16] Z. Xiong, Y. Yuan, and W. Qi, "Ai-Net: Attention Inception Neural Networks for Hyperspectral Image Classification," *IGARSS 2018 - 2018 IEEE Int. Geosci. Remote Sens. Symp.*, pp. 2647–2650, 2018.
- [17] S. Theodoridis and K. Koutroumbas, *Pattern Recognition*, Second ed. Elsevier academic press, 2003.
- [18] L. Ángel Ruiz, "Análisis de componentes principales, aplicaciones en teledetección," 2003.
- [19] F. Chollet, *Deep Learning with Python*, MEAP Editi. Manning Publications, 2017.
- [20] M. Graña, "Hyperspectral Remote Sensing Scenes," *Grupo de Inteligencia Computacional de la Universidad del País Vasco*. [Online]. Available: [http://www.ehu.es/ccwintco/index.php?title=Hyperspectral\\_Remote\\_Sensing\\_Scenes](http://www.ehu.es/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes). [Accessed: 27-Nov-2019].
- [21] R. S. Laboratory, "Data of Remote Sensing Laboratory," *Engineering, school of surveying and geospatial. University of Tehran*. [Online]. Available: <https://rslab.ut.ac.ir/data>. [Accessed: 27-Nov-2019].
- [22] M. Fauvel, Y. Tarabalka, J. A. Benediktsson, J. Chanussot, and J. C. Tilton, "Advances in spectral spatial classification of hyperspectral images," *Proc. IEEE*, vol. 101, no. 3, pp. 652–675, 2013.
- [23] A. Plaza *et al.*, "Recent advances in techniques for hyperspectral image processing," *Remote Sens. Environ.*, vol. 113, no. SUPPL. 1, pp. S110–S122, 2009.



**David Ruiz Hidalgo** received the Engineering degree in Electronic Engineering in 2011 and his M.Sc in 2015 from Universidad del Valle, Cali, Colombia. He is developing his Ph.D studies in electrical and electronic engineering in the same institution. He is researcher at the Perception and Intelligent Systems Group, Universidad del Valle.

His current research interests are in the field of image processing, computer vision and machine learning.



**Bladimir Bacca Cotés** graduated in Electronic Engineering in 1999, he received his M.Sc. in 2004 both at the Universidad del Valle, Cali, Colombia. Received a Ph.D. at the University of Girona in 2012. He is a Professor of the Electrical and Electronic Engineering School at the Perception and Intelligent Systems Group, Universidad del Valle.

His current research interests are in the field of localization and mapping for mobile robots, computer vision, focusing on SLAM and appearance-based environmental models.



**Eduardo Caicedo Bravo** received the Engineering degree in Electrical Engineering from Universidad del Valle in 1984. He received his M.Sc. in 1993 and his PhD in industrial computer in 1996 at the Universidad Politécnica de Madrid. He is a Professor of the Electrical and Electronic Engineering School at the Perception and Intelligent Systems Group,

Universidad del Valle. His current research interests are in the field of computer intelligence and smart grids.