

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-27

EVALUACIÓN DE ALGORITMOS DE REDUCCIÓN DE DIMENSIONES BASADOS EN DESCRIPTORES DE FORMA FRENTE AL RUIDO PARA EL ANÁLISIS DE IMÁGENES HIPERESPECTRALES

Deiver Giovan Molina García

Ingeniería de Sistemas

María Constanza Torres Madroño

INSTITUTO TECNOLÓGICO METROPOLITANO

Abril de 2018

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

RESUMEN

En este trabajo de laboratorio se realiza una comparación del desempeño del descriptor de forma basado en Fourier y el análisis de componentes principales, para la clasificación de imágenes hiperespectrales. Para realizar esta comparación se implementó la función ***ClassIndianPinesSVM***.

En la comparación se realizaron 20 ejecuciones para cada experimento. Los experimentos se realizaron para la imagen Indian Pines sin ruidos y con niveles de ruido de 5, 10, 20 y 30 db. El desempeño se analiza desde los resultados de clasificación, promediando los valores de precisión y matrices de confusión.

Con los resultados obtenidos se logró demostrar que el descriptor de forma basado en Fourier no pierde precisión significativa frente a su rival cuando la imagen tiene un nivel de ruido determinado.

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

RECONOCIMIENTOS

La realización de este trabajo de laboratorio fue posible, en primer lugar, a la cooperación brindada por la profesora María Constanza Torres Madroñero, quien fue la responsable de brindar todo el apoyo en el desarrollo del mismo.

Se agradece además a los profesores que estuvieron en este camino durante todo este ciclo complementario para convertirme en un ingeniero de sistemas que llevara orgulloso la fortuna de ser egresado del ITM.

A mis padres y amigos, gracias porque todos aportaron para que hoy esté cumpliendo esta práctica de laboratorio y así alcanzar el logro por el que tanto se ha trabajado, por no dejarme desistir y siempre tener las palabras que me impulsaron a conseguir el fin.

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

ACRÓNIMOS

MIRP- Maquinas Inteligentes y Reconocimiento de Patrones

PCA - Técnica análisis de componentes principales.

SVM - Maquinas de super vectores.

DR - Reductor de Dimensiones.

CP - Class Indian Pines.

FD - Fourier Descriptors.

PC - Principal Components.

CM - Confusion Matrix o Maps.

db - decibeles.

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

TABLA DE CONTENIDO

1.	INTRODUCCIÓN
2.	MARCO TEÓRICO.....
3.	METODOLOGÍA
4.	RESULTADOS Y DISCUSIÓN
5.	CONCLUSIONES, RECOMENDACIONES Y TRABAJO FUTURO
	REFERENCIAS

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

1. INTRODUCCIÓN

La percepción remota tiene diversas aplicaciones que van desde la agricultura de precisión, estudios relacionados al cambio climático, monitoreo del crecimiento urbano, aplicaciones militares, así como estudios de desarrollo sostenible. En Colombia este campo está en desarrollo y es un nuevo foco de investigación.

Entre los sistemas remotos se destacan los sensores hiperespectrales, que capturan información en cientos de bandas a lo largo del espectro electromagnético, proporcionando información tanto espacial como espectral, que permite la identificación de materiales de forma remota. Dada la alta resolución espectral de este tipo de imágenes, los algoritmos tradicionales de aprendizaje de máquinas y reconocimiento de patrones se ven enfrentados a los retos que acompañan la alta dimensionalidad de los datos.

Una forma para mejorar el desempeño de los algoritmos de aprendizaje de máquinas sobre datos hiperespectrales es el uso de técnicas de reducción de dimensiones. En el Laboratorio de Maquinas Inteligentes y Reconocimiento de Patrones se ha desarrollado una nueva metodología para la reducción de la dimensión de imágenes hiperespectrales a partir del uso de descriptores de forma.

Los descriptores de forma son ampliamente usados en visión artificial para el reconocimiento de objetos de una escena. En el trabajo adelantado en el laboratorio, el uso de los descriptores de forma se extiende al procesamiento de imágenes hiperespectrales.

Los resultados preliminares de esta metodología representan un significativo avance en el estado del arte. Sin embargo, es necesario el estudio del desempeño de la metodología

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

frente a diferentes escenarios, de tal forma que se pueda evaluar su robustez y desempeño.

El objetivo de este producto de laboratorio es evaluar la metodología de reducción de dimensiones basada en descriptores de forma frente a diferentes escenarios (imágenes reales capturadas sobre agricultura, minería y agua) y con diferentes niveles de ruido. La evaluación del desempeño de la metodología se realizará a través del uso un clasificador de máquinas de soporte vectorial y con tres imágenes reales, de las cuales se tiene sus respectivos mapas de clasificación.

Los objetivos de esta práctica de laboratorio son:

1. Evaluar el desempeño de una metodología de reducción de dimensiones para el procesamiento de imágenes hiperespectrales basada en descriptores de forma frente a diferentes escenarios y niveles de ruido
2. Generar mapas de confusión a partir de los resultados de clasificación de las imágenes obtenido a partir de un clasificador de máquina de soporte vectorial

Para el desarrollo de esta práctica de laboratorio se realizará actividades relacionadas con:

1. Revisión de literatura científica para la comprensión de los métodos de reducción de dimensiones y procesamiento de imágenes.
2. Implementación de rutinas para agregar diferentes niveles de ruido a las imágenes y adaptación de la metodología desarrollada en MIRP.
3. Escritura de un informe tecnico-cientifico que incluya los mapas de clasificación resultantes y las matrices de confusión.

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

2. MARCO TEÓRICO

Los sistemas de detección remota permiten la caracterización de la atmósfera, la superficie terrestre y los océanos para observación de la tierra.

Ejemplos de sensores remotos son: multiespectrales y sistemas hiperespectrales que recogen datos espaciales, espectrales y datos temporales de la superficie de la Tierra. Sensores multiespectrales, tales como MODIS y Landsat, tienen un número relativamente pequeño de bandas no contiguas (es decir, menos de 25 bandas). En cambio, en el hiperespectral los sistemas muestran continuamente el espectro electromagnético a muy alta resolución espectral. Por ejemplo, el Airborne Espectrómetro de Imágenes Visibles / Infrarrojas -AVIRIS de la NASA recoge datos de 224 bandas espectrales entre 400 nm y 2500 nm con una resolución espectral de 10 nm. La información capturada por estos sensores la podemos ver como un cubo, donde cada píxel es una firma espectral que caracteriza los materiales en el campo de visión del sensor [1], [2].

Los enfoques de procesamiento para imágenes multiespectrales e hiperespectrales se clasifican en: detección de objetivos, clasificación temática y desmezcla [1]. La clasificación es ampliamente utilizada para el procesamiento de imágenes hiperespectrales y se basa en reglas aprendidas de muestras de capacitación (aprendizaje supervisado) o procesos iterativos (aprendizaje no supervisado) [2]. El avance de las técnicas de clasificación para datos multivariados ha promovido el uso de estas técnicas en teledetección. Por ejemplo, los clasificadores de máquinas Súper vector -SVM han mostrado un gran potencial para la clasificación de imágenes hiperespectrales [3] - [4]. Sin embargo, el alto número de bandas espectrales y su alta correlación dificultan la clasificación de los datos hiperespectrales debido a los fenómenos de Hughes [5], [6]. Una forma de lidiar con la alta dimensionalidad de los datos hiperespectrales es usar técnicas de reducción dimensional DR.

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

Existen enfoques de DR que usan información a priori para encontrar espacios de representación que proporcionen una mejor discriminación de clase. Algunos ejemplos de estos enfoques son la proyección subespacial ortogonal [7], el análisis discriminante local de Fisher [8] y las técnicas basadas en el aprendizaje múltiple [9]. En cambio, los enfoques no supervisados no usan información sobre las clases. Algunos ejemplos son el análisis de componentes principales - PCA [1], la fracción mínima de ruido [10], el análisis de componentes independientes [11] y las técnicas basadas en la transformación wavelet [12]. A pesar de la alta diversidad de técnicas DR, PCA se usa comúnmente para aplicaciones de teledetección (ej. [13] - [14]). PCA transforma un conjunto de datos en un nuevo espacio de representación de tal manera que los componentes no están correlacionados y generalmente ordenados por variaciones decrecientes. La ventaja de PCA es que preserva las variaciones de imagen en pocas dimensiones.

Hasta donde se sabe, no hay enfoques DR que usen información de forma de firmas espectrales. La forma de una firma espectral permite la identificación remota de materiales [1], [2], luego se espera que mejore la clasificación de imágenes hiperespectrales utilizando técnicas de DR que tengan en cuenta las formas de la firma. En este producto de laboratorio se exploran los descriptores de forma basados en Fourier propuestos en la tesis de la maestría *“Shape Descriptors for Hyperspectral Image Classification”*. Los descriptores de forma son ampliamente utilizados para el reconocimiento de objetos [15], [16]. Los descriptores de formas de Fourier se obtienen a partir de firmas espectrales y un subconjunto de estos se usa para construir un nuevo espacio de representación. La clasificación se realiza utilizando el nuevo espacio de características y un clasificador SVM. En este trabajo se evalúa el desempeño de estos descriptores frente a diferentes niveles de ruido.

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

3. METODOLOGÍA

Para la ejecución de esta práctica de laboratorio la metodología que se utilizó fue la siguiente:

1. Utilizando la función original ***ClassIndianPinesSVM*** se realizaron 20 ejecuciones de esta.
2. La función se recorrió en un ciclo y en cada vuelta se almacenaron los valores de:
 - ✓ Accuracy_CP
 - ✓ Accuracy_FD
 - ✓ Accuracy_PC
 - ✓ CM_CP
 - ✓ CM_FD
 - ✓ CM_PC
 - ✓ Cpredict_CP
 - ✓ Cpredict_FD
 - ✓ Cpredict_PC
3. Una vez terminado el ciclo se realizó la suma de las variables:
 - ✓ Accuracy_CP
 - ✓ Accuracy_FD
 - ✓ Accuracy_PC
 - ✓ CM_CP
 - ✓ CM_FD
 - ✓ CM_PC
4. Con las sumatorias de las variables, estas se dividieron entre el número de ejecuciones (20), para así obtener el promedio de cada variable:
 - ✓ Accuracy_CP

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

- ✓ Accuracy_FD
- ✓ Accuracy_PC
- ✓ CM_CP
- ✓ CM_FD
- ✓ CM_PC

Para continuar con el experimento se realiza modificación a la función original ***ClassIndianPinesSVM*** añadiendo al código fuente las líneas necesarias para agregar los diferentes tipos de ruidos.

1. Utilizando la función modificada ***ClassIndianPinesSVM*** se realizaron 20 ejecuciones de esta añadiendo a la imagen un ruido de 5db.
2. La función se recorrió en un ciclo y en cada vuelta se almacenaron los valores de:
 - ✓ Accuracy_CP
 - ✓ Accuracy_FD
 - ✓ Accuracy_PC
 - ✓ CM_CP
 - ✓ CM_FD
 - ✓ CM_PC
 - ✓ Cpredict_CP
 - ✓ Cpredict_FD
 - ✓ Cpredict_PC
3. Una vez terminado el ciclo se realizó la suma de las variables:
 - ✓ Accuracy_CP
 - ✓ Accuracy_FD
 - ✓ Accuracy_PC
 - ✓ CM_CP
 - ✓ CM_FD

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

✓ CM_PC

4. Con las sumatorias de las variables, estas se dividieron entre el número de ejecuciones (20), para así obtener el promedio de cada variable:

✓ Accuracy_CP

✓ Accuracy_FD

✓ Accuracy_PC

✓ CM_CP

✓ CM_FD

✓ CM_PC

5. Se repite la operación, pero ahora con ruidos de 10, 20 y 30 db.

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

4. RESULTADOS Y DISCUSIÓN

A continuación, se exponen los resultados obtenidos una vez se calcularon todos los promedios de las variables:

- ✓ Accuracy_CP
- ✓ Accuracy_FD
- ✓ Accuracy_PC
- ✓ CM_CP
- ✓ CM_FD
- ✓ CM_PC

El resultado promedio de la precisión de las imágenes con y sin ruido con cada una de las técnicas se describe en la siguiente tabla.

Variable	Nivel de Ruido				
	0	5	10	20	30
Indian Pines (CP)	0,760645379	0,760577851	0,760664673	0,759333398	0,759449161
Fourier Descriptor (FD)	0,611682423	0,612381825	0,613442987	0,609651746	0,60965657
Principal Components (PC)	0,349551418	0,349710592	0,351234806	0,351784681	0,351693035

Realizando el análisis de la tabla anterior evidenciamos que la técnica FD no pierde una precisión significativa al aplicar el ruido y sigue siendo aproximadamente un 43% más preciso que la técnica PC contra la que la comparábamos.

El resultado de las matrices de confusión (CM) resultantes con las técnicas FD y PC son similares al análisis anterior ya que la matriz promedio resultante no tiene un cambio significativo con o sin ruido.

A continuación se anexa una de las matrices de confusión resultantes de la técnica FD con nivel de ruido 10 db en la ejecución 20.

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO										Código	FDE 089
											Versión	03
											Fecha	2015-01-22

13	0	0	0	0	2	0	1	33	0	0	4	1	0	0	0
0	115	10	4	6	18	0	85	0	0	0	8	0	0	13	121
0	1	70	25	57	0	0	2	0	1	14	37	27	0	0	0
0	1	9	225	167	0	0	1	0	0	24	383	24	0	0	0
0	3	15	61	675	0	0	1	0	0	99	518	62	0	0	0
0	18	1	1	4	332	1	7	0	0	2	17	8	0	0	106
0	1	0	0	0	0	3	0	4	0	0	14	4	0	0	0
0	79	0	0	2	29	0	614	0	0	3	8	3	0	0	9
6	2	0	0	0	7	3	1	445	0	4	6	15	0	0	0
0	5	0	0	0	0	0	12	0	2	0	0	0	0	1	0
0	0	10	41	149	0	0	3	0	0	191	175	45	0	0	0
0	0	5	49	351	1	0	7	0	0	62	1832	161	0	0	0
0	1	0	20	97	2	0	2	0	0	25	502	319	0	0	0
0	0	2	3	0	1	0	0	0	0	6	1	11	71	0	0
0	9	0	0	0	0	0	16	0	0	0	4	0	0	183	0
0	31	0	0	0	42	0	7	0	0	0	1	0	0	1	1212

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

5. CONCLUSIONES, RECOMENDACIONES Y TRABAJO FUTURO

Evaluar el desempeño de una metodología de reducción de dimensiones para el procesamiento de imágenes hiperespectrales basada en descriptores de forma frente a diferentes escenarios y niveles de ruido

Generar mapas de confusión a partir de los resultados de clasificación de las imágenes obtenido a partir de un clasificador de máquina de soporte vectorial

Se concluye que el desempeño de la reducción de dimensiones con la técnica FD es mejor que la técnica PC, además los mapas o matrices de confusión no tienen cambios significativos.

Para obtener mejores resultado y tener mejor precisión se pudo realizar más ejecuciones de las imágenes con ruidos y seguir aumentando gradualmente los niveles de ruido es decir no pasar de 10 a 20 si no a 15 hacerlo de 5 en 5 hasta un nivel de ruido de 50 bd así se soportaría con mayor veracidad la conclusión obtenida.

Con los resultados obtenidos se puede seguir aplicando a otro tipo de imágenes para poder empezar su implementación en el campo de meteorología, agricultura entre otros y demostrar que la técnica basada en FD es funcional en el campo de la visión artificial.

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

REFERENCIAS

- [1] G. Shaw and D. Manolakis, "Signal processing for hyperspectral image exploitation," IEEE Signal Processing Magazine, vol. 19, no. 1, pp. 12–16, Jan 2002.
- [2] A. Plaza, J. A. Benediktsson, J. W. Boardman, J. Brazile, L. Bruzzone, G. Camps-Valls, J. Chanussot, M. Fauvel, P. Gamba, A. Gualtieri et al., "Recent advances in techniques for hyperspectral image processing," Remote sensing of environment, vol. 113, pp. S110–S122, 2009.
- [3] F. Melgani and L. Bruzzone, "Classification of hyperspectral remote sensing images with support vector machines," IEEE Transactions on geoscience and remote sensing, vol. 42, no. 8, pp. 1778–1790, 2004.
- [4] G. Mountrakis, J. Im, and C. Ogole, "Support vector machines in remote sensing: A review," ISPRS Journal of Photogrammetry and Remote Sensing, vol. 66, no. 3, pp. 247–259, 2011.
- [5] G. Hughes, "On the mean accuracy of statistical pattern recognizers," IEEE transactions on information theory, vol. 14, no. 1, pp. 55–63, 1968.
- [6] 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, 2007.

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

[7] J. C. Harsanyi and C.-I. Chang, “Hyperspectral image classification and dimensionality reduction: An orthogonal subspace projection approach,” IEEE Transactions on geoscience and remote sensing, vol. 32, no. 4, pp.779–785, 1994.

[8] W. Li, S. Prasad, J. E. Fowler, and L. M. Bruce, “Locality-preserving dimensionality reduction and classification for hyperspectral image analysis,” IEEE Transactions on Geoscience and Remote Sensing, vol. 50, no. 4, pp. 1185–1198, 2012.

[9] 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.

[10] 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, no. 5, pp. 620–628, 1989.

[11] J. Wang and C.-I. Chang, “Independent component analysis-based dimensionality reduction with applications in hyperspectral image analysis,” IEEE transactions on geoscience and remote sensing, vol. 44, no. 6, pp. 1586–1600, 2006.

[12] 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.

[13] S. Mahesh, D. Jayas, J. Paliwal, and N. White, “Hyperspectral imaging to classify and monitor quality of agricultural materials,” Journal of Stored Products Research, vol. 61, pp. 17–26, 2015.

[14] X. Tong, H. Xie, and Q. Weng, “Urban land cover classification with airborne hyperspectral data: What features to use?” IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 7, no. 10, pp. 3998–4009, 2014.

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

[15] D. Zhang and G. Lu, “Review of shape representation and description techniques,” Pattern recognition, vol. 37, no. 1, pp. 1–19, 2004.

[16] R. B. Yadav, N. K. Nishchal, A. K. Gupta, and V. K. Rastogi, “Retrieval and classification of shape-based objects using fourier, generic fourier, and wavelet-fourier descriptors technique: A comparative study,” Optics and Lasers in engineering, vol. 45, no. 6, pp. 695–708, 2007.

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

FIRMA ESTUDIANTES Deiver Molina

FIRMA ASESOR *[Signature]*

FECHA ENTREGA: 18 Abril 2018

FIRMA COMITÉ TRABAJO DE GRADO DE LA FACULTAD _____

RECHAZADO ___ ACEPTADO ___ ACEPTADO CON MODIFICACIONES ___

ACTA NO. _____

FECHA ENTREGA: _____

FIRMA CONSEJO DE FACULTAD _____

ACTA NO. _____

FECHA ENTREGA: _____