

# Segmentación semántica para imágenes de paisajes tropicales

Corzo Ussa, German Darío.  
corzog@javeriana.edu.co  
Pontificia Universidad Javeriana

*Abstract* - In the present work a method is established for semantic segmentation of cartographic images of Colombian tropical landscapes through the supervised analysis of groups of pixels in three classes: vegetation, water sources and other objects (strange elements in the nature of the landscape). The proposed technique allows integrating the characteristics of color, texture and edges present in the context of groups of pixels and transform the space of multiple channels directly into a Euclidean vector space. This is achieved by improving the machine processing time by having a statistical representation of the data instead of a large amount of raw data pixel by pixel and allows classifying the data using machine learning techniques. Finally, an error analysis is made in both machine training and classification.

*Resumen*—En el presente trabajo se establece un método para segmentación semántica de imágenes cartográficas de paisajes tropicales colombianos a través del análisis supervisado de grupos de píxeles en tres clases: vegetación, fuentes de agua y otros objetos (elementos extraños en la naturaleza del paisaje). La técnica planteada permite integrar las características de color, textura y bordes presentes en el contexto de grupos de píxeles y transformar el espacio de múltiples canales directamente en un espacio vectorial Euclidiano. Con ello se logra mejorar el tiempo de procesamiento de máquina al tener una representación estadística de los datos en lugar de una gran cantidad de datos crudos pixel por pixel y permite clasificar los datos utilizando técnicas de máquinas de aprendizaje. Finalmente se hace un análisis de error tanto en el entrenamiento de la máquina como en la clasificación.

---

*Índice de Términos*— semántica, matriz de covarianza, puntos sigma, máquinas de vectores soporte (SVM).

## I. INTRODUCCIÓN

En el análisis de imágenes cartográficas, es necesario conocer diferentes objetos que son de interés para determinar múltiples factores con respecto a la demografía, hidrografía, medio ambiente, zonas de producción, vías transitables, entre otras. Sin embargo, para un analista de imágenes es difícil clasificar y dar conceptos de valor sobre lo que puede determinarse a simple vista de una fotografía o un mosaico de imágenes a color, por esta razón, identificar, conocer, delimitar, detectar y comparar los objetos de una imagen obtenida con sensores CCD o Infrarrojo son determinantes para dar mayor valor a este tipo de imágenes. La técnica más usada para diferenciar los objetos es la segmentación, existen varios métodos y algoritmos que usan la probabilidad de pertenecer a cierto punto en el espacio de color o el clustering basado en la ubicación de centros de color a cierta distancia [6]. El agrupamiento de datos (clustering) es una técnica común para la clasificación de datos que permite tener un mejor manejo de ellos; esta técnica se utiliza en diversos campos como la identificación de estructuras en modelos

difusos [11], compresión de datos y la segmentación de imágenes, donde la distribución de la información puede ser de cualquier tamaño y forma. Las técnicas de segmentación que analizan píxeles individuales son poco confiables para muchos tipos de imágenes pues los valores de los píxeles pueden ser los mismos en clases diferentes.




Figura 1. Imágenes segmentadas por conocimiento experto con 3 clases: vegetación (verde), fuentes de agua (azul), y otros (amarillo).

Actualmente se usan técnicas que analizan el contexto de los píxeles a clasificar, por esta razón se suelen observar grupos cercanos de píxeles y utilizar técnicas que permiten conocer el valor y la relación estadística con sus vecinos, así se puede conocer si hace parte de un borde, un espacio con textura o si efectivamente hay una superficie plana en cuyo caso lo más probable es que los píxeles cercanos tendrán valores muy parecidos en el espacio de color.

En este artículo se analizará una técnica de clasificación a través de máquinas de vectores soporte multiclase, el primer problema planteado consiste en presentar los datos de tal forma que puedan ser una entrada para la máquina de entrenamiento y la clasificación de los datos. Para ello se aplicará una transformación de la matriz de covarianza a partir de una representación en puntos sigma [9] que representa una integración de apariencia, respuesta a filtros y otras características contenidas en el contexto de grupos de píxeles.

Los resultados son recogidos en tablas que muestren la probabilidad de error y la matriz de confusión para algunas técnicas de clasificación a través de máquinas de aprendizaje, luego entrenar y clasificar los datos con una metodología supervisada y realizar el análisis de error en la clasificación, comparándola con las plantillas hechas por el experto y los resultados de un algoritmo de segmentación por píxel.

## II. DESCRIPCIÓN DE LA TÉCNICA

### A. Procesamiento de Datos

Para el procesamiento de los grupos de píxeles en el entrenador se realizaron pruebas sobre 5 imágenes de paisajes tropicales seleccionadas de un conjunto de 219 fotografías tomadas desde una plataforma aérea con sensor CCD e IR. La selección se hizo teniendo en cuenta la presencia de las tres clases requeridas en cada una de ellas y verificando que fuesen homogéneas entre sí, es decir, tomadas en lo posible de forma vertical, a la misma hora del día y en condiciones de sol/nubosidad similares.

Tabla I  
Ejemplo de clasificación de imágenes manual, se escogieron 5 de ellas para implementar el clasificador.

Nombre	Formato	Sensor	Vegetación	Agua	Construcciones	Otros	Reconocimiento visual
000M0	BMP	CCD	1	1	1	1	BUENA
001M	TIFF	CCD	1	1	1	1	BUENA
002M	TIFF	CCD	1	1	0	1	BUENA
003M	TIFF	CCD	1	1	0	1	MALA
004M	TIFF	CCD	1	1	0	1	REGULAR
005M	TIFF	CCD	1	1	0	1	MALA
006M	TIFF	CCD	1	1	1	1	MALA
007M	TIFF	CCD	1	1	1	1	MALA
008M	TIFF	CCD	1	1	1	1	BUENA
009M	TIFF	CCD	1	1	1	1	REGULAR
010M	TIFF	CCD	1	1	1	1	REGULAR
011M	TIFF	CCD	1	1	0	1	MUY BUENA
012M	TIFF	CCD	1	1	1	1	MUY BUENA
013M	TIFF	CCD	1	1	1	1	MALA
014M	TIFF	CCD	1	1	1	1	BUENA
015M	TIFF	CCD	1	1	1	1	REGULAR

Se realizaron pruebas del comportamiento sobre los píxeles de

color a través de algoritmos de clasificación no supervisada como k-means y mezcla de Gaussianas, respuesta a filtro promedio y Gaussiano y detección de esquinas a través del algoritmo de Harris.

Con el anterior procedimiento se determina como las diferentes clases responden a los algoritmos que procesan los pixeles, observándose por ejemplo que los grupos de color no reconocen las fuentes de agua pues esta puede tener colores diferentes, sin embargo el filtro promedio, con el cual se puede analizar la varianza entre grupos de pixeles muestra que esta misma clase tiene un comportamiento en el cual los pixeles adjuntos tienen gran probabilidad de ser iguales, reconociendo el agua sin importar el color que tenga. De forma similar el comportamiento de los algoritmos en diferentes características muestra la importancia del contexto para determinar las clases.




Figura 2. Características de las clases. (a) Paisaje tropical, (b) Clasificación de pixeles por color (RGB) con mezcla de Gaussianas, (c) Textura con filtro promedio (d) Detección de esquinas con algoritmo de Harris.

Los descriptores de covarianza [13] proveen una representación de características de baja dimensión que puede integrar de forma simple múltiples

canales, como color, respuesta a filtros, bordes, entre otros y utiliza la correlación entre ellos. Las matrices de covarianza pueden ser eficientemente calculadas y proveen una integración de varios canales de características, sin embargo, el espacio de las matrices de covarianza no tiene la forma de espacio vectorial Euclidiano, esta representación no puede ser directamente usada para muchas técnicas de aprendizaje de máquina.

Para resolver este inconveniente y aprovechar el potencial de los descriptores de covarianza, se propone una técnica que realiza la transformación del espacio vectorial.

### B. Obtención de puntos Sigma

Para representar matrices de covarianza individuales directamente en un espacio vectorial Euclidiano, es posible realizar una transformación que consiste en encontrar un pequeño conjunto de  $2d + 1$  vectores específicos  $s_i \in \mathbb{R}^d$  llamados puntos sigma [8], los cuales se construyen de la siguiente forma:

$$s_0 = \mu \quad s_i = \mu + \alpha(\sqrt{\Sigma})_i \quad s_{i+d} = \mu - \alpha(\sqrt{\Sigma})_i \quad (1)$$

### C. Algoritmo para presentación de datos

Para la representación de características se propone un algoritmo basado en Puntos Sigma [9] el cual requiere el vector de medias  $\mu^k$  y la matriz de covarianza  $\Sigma^k$ , así:

1. Realizar una regularización simple

$$\Sigma^k = \Sigma^k + \epsilon I \quad (2)$$

2. Calcular la raíz cuadrada de la matriz tal que

$$\Sigma^k = LL^T \quad (3)$$

3. Calcular  $s_i^k$  de acuerdo a (1)
4. Construir el conjunto de Puntos Sigma

$$S^k = (s_0^k, s_1^k, \dots, s_{2d}^k) \quad (4)$$

### III. SOLUCIÓN PROPUESTA

Se propone implementar la técnica de clasificación aplicando SVM con kernel lineal, cuadrático, gaussiano y cúbico, los cuales están incluidos en el toolbox de Matlab y compararlo con otras técnicas desde los resultados de entrenamiento y seleccionar la de menor error. Para implementar el clasificador se presentan los datos aplicando el algoritmo basado en Puntos Sigma para una transformación de la matriz de covarianza en el espacio de color (RGB) de una selección aleatoria de un conjunto de pixeles  $m \times n$ . De esta forma siendo  $s_i \in R^3$ , donde  $i = 2(3) + 1 = 7$ , se obtiene:

$$S^1 = (s_0^1, s_1^1, s_2^1, s_3^1, s_4^1, s_5^1, s_6^1) \quad (5)$$

Se procesan conjuntos de 10, 25 y 50 muestras por cada clase para un total de 150 cuadros aleatorios de 10 x 10 pixeles. Para ingresar los datos al entrenador se tiene cada muestra individual etiquetada con un total de 21 características producto del cálculo de los puntos sigma.

El resultado del entrenamiento de maquina muestra que son cuasi-perfectamente diferenciables en todos los casos mostrando los mejores resultados con kernel cúbico y gaussiano fino, se selecciona este último para realizar las pruebas con datos provenientes de la

misma imagen y de otra similar.

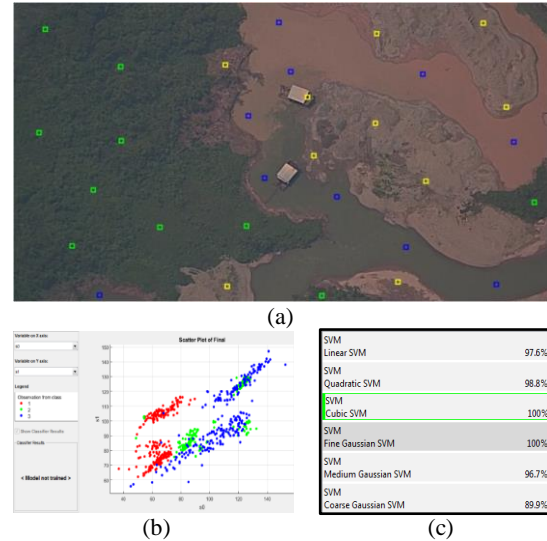


Figura 3. Entrenamiento con SVM. (a) 10 Muestras por clase de 10 x 10 pixeles, (b) Representación de cada punto en el espacio vectorial, (c) Resultados del entrenamiento para SVM con varios kernel.




Figura 4. Muestras para prueba del clasificador. (a) Muestras provenientes de la imagen para entrenamiento, (b) Muestras provenientes de una imagen similar.

Los datos tanto de entrenamiento como los de los resultados de clasificación pueden ser guardados en una tabla para su uso posterior, las muestras se toman aleatoriamente en forma supervisada y encuentran los errores por comparación de los resultados de la imagen completa de los datos de prueba, también se revisó la matriz de confusión con el fin de analizar los resultados frente al error por cada clase.

#### A. Análisis de error por cuadro

De la imagen 011M.tif se toman 50

muestras por cada clase para un total de 150 que son entrenadas con SVM kernel “fine gaussian” el modelo se aplica a 30 cuadros aleatorios (10 por cada clase) de la misma imagen (011M.tif) y de otra imagen (012M.tif) de esta forma puede probarse la base del método calculando el error cuadro por cuadro comparándolos según su posición en las imágenes ground truth.

emplea esta técnica para reducir el tiempo de procesamiento sin aumentar demasiado el error de clasificación.

Tabla II  
Error de clasificación para cuadros de 10 x 10 pixeles

Muestra	012M	011M	ECM	012M	011M	ECM	012M	011M	ECM
1	Veg	Veg	0	Agu	Agu	0	Otro	Otro	0
2	Veg	Agu	1	Agu	Agu	0	Otro	Otro	0
3	Veg	Veg	0	Agu	Agu	0	Otro	Otro	0
4	Veg	Veg	0	Agu	Agu	0	Otro	Otro	0
5	Veg	Veg	0	Agu	Agu	0	Otro	Otro	0
6	Veg	Veg	0	Agu	Agu	0	Otro	Otro	0
7	Veg	Veg	0	Agu	Agu	0	Otro	Otro	0
8	Veg	Agu	1	Agu	Agu	0	Otro	Otro	0
9	Veg	Veg	0	Agu	Agu	0	Otro	Otro	0
10	Veg	Veg	0	Agu	Agu	0	Otro	Otro	0

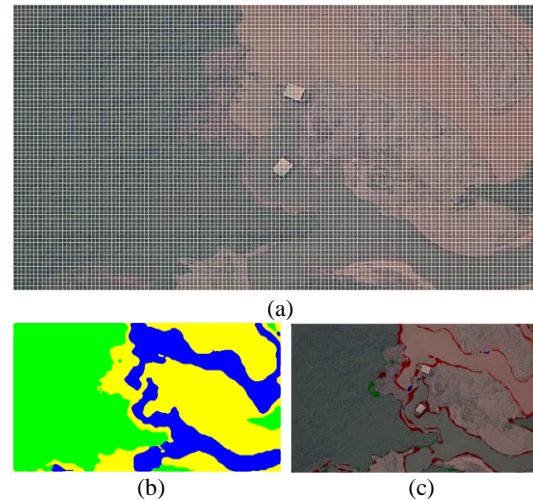


Figura 5. Proceso de segmentación en imágenes (a) Red de grupo de pixeles para clasificar, (b) Resultado con entrenamiento de 50 muestras (c) Imagen de error.

El error para muestras de la misma imagen de donde proviene el entrenamiento es 0% y el de otra imagen se calcula en el 6,66%

### B. Análisis de error para imagen entrenada

El desarrollo y puesta a punto del algoritmo de segmentación se hizo con la imagen 012M.tif, el método escogido para hacer el análisis de error consistió en obtener resultados de la imagen con 10, 25 y 50 muestras supervisadas con la certeza del experto de pertenecer a cada clase. Luego se segmenta la imagen completa recorriéndola en cuadros de 10 x 10 como se observa en la figura 5, se

Tabla III  
Resultados de la clasificación para 50 muestras de imagen entrenada

TRUE CLASS	CLASE PREDECIDA			Total x Clase	Píxeles Correctos	Píxeles erróneos
	1	2	4			
1	97,1%	0,0%	2,9%	42%	97%	3%
2	0,6%	85,1%	14,3%	25%	85%	15%
4	1,8%	0,5%	97,7%	33%	98%	2%
Total				100%		

En esta imagen la principal confusión se presenta entre agua y otros, esto sucede porque hay zonas modificadas por el hombre producto de la minería ilegal donde se desvían cauces de ríos y se mueven volúmenes de tierra que al final terminan siendo barro, el cual puede ser confundido con agua del mismo río. Esta imagen también muestra la combinación de agua contaminada de procesos químicos para extracción de metales con agua de un río, esto claramente no es normal y las zonas donde ocurre deben ser identificadas para hacer seguimiento del impacto económico, ambiental y social.

Para hacer una comparación del algoritmo con otros de segmentación no supervisada, se realiza la misma prueba de error con la imagen 012M.tif, pero esta vez clasificando píxeles individuales a través mezcla de gaussianas, figura 12. En este caso se cada píxel se asigna en un grupo N de distribuciones gaussianas (N = 3) que representan cada clase con una media específica, los pixeles se estiman con la mayor probabilidad de pertenecer a alguna clase cercana a su media.




Figura 6. Resultado imagen 012M.tif segmentada con algoritmo no supervisado GMM, (a) Resultado de la segmentación (c) comparación del error.

La matriz de confusión muestra alta probabilidad de error entre clase agua y otros ya que el algoritmo reúne solamente colores y no relación entre colores cercanos, en este caso una solución podría ser agregar una distribución más (N=4) para separar el color del barro con otro color de agua.

Tabla IV

Resultados de la clasificación para 60 muestras de 2 imágenes

TRUE CLASS	CLASE PREDECIDA			Total x Clase	Píxeles Correctos	Píxeles erróneos
	1	2	4			
1	<b>94,1%</b>	5,6%	0,3%	42%	94%	6%
2	0,6%	<b>46,7%</b>	52,7%	25%	47%	53%
4	2,5%	21,7%	<b>75,8%</b>	33%	76%	24%
Total				100%		

### C. Análisis de error para nuevas imágenes

Uno de los requerimiento de usuario final es poder enriquecer la base de datos para segmentar nuevas imágenes con

datos existentes, para comprobar la utilidad, se prueba con 50 muestras obtenidas de otra imagen similar, en este caso la 011M.tif con las cuales se entrena la máquina y aplica el clasificador en la imagen 012M.tif, de la misma forma se realiza para GMM escogiendo N=3, al final las muestras de ambas imágenes enriquecerán la población total para evaluación de nuevas entradas.




Figura 7. Resultado imagen 012M.tif segmentada con información de otra imagen (a) Para 50 muestras con transformación con sigma points (c) GMM con N=3 distribuciones gaussianas de otra imagen.

El análisis de error muestra un resultado muy diferente en cuanto a los píxeles clasificados pues un alto porcentaje de píxeles que pertenecen a las clases agua y otros fueron confundidas con vegetación

## IV. RESULTADOS

### A. Error de entrenamiento

La tabla IV muestra la recopilación de resultados para las pruebas realizadas con 5 imágenes seleccionadas y comparadas con la plantilla ground truth clasificada por un experto. La relación de píxeles clasificados correctamente con cada método se muestra con sombra gris y el peor caso con sombra roja, también se relaciona el porcentaje de píxeles pertenecientes a cada clase que hay en la

imagen evaluada.

Tabla V  
Píxeles correctamente clasificados en 5 imágenes evaluadas con información de sí mismas

INFORMACION DE LAS IMÁGENES		ANÁLISIS DE ERROR DE ENTRENAMIENTO				
CLASE	IMAGEN	Píxeles				
		Clase	10	25	50	GMM
VEGETACION	000MO.bmp	70%	55,53%	76,00%	88,25%	95,70%
	011M.tif	61%	91,73%	93,45%	95,07%	91,70%
	012M.tif	42%	95,11%	97,58%	97,10%	94,10%
	030M.tif	88%	62,01%	95,88%	98,60%	75,50%
	031M.tif	54%	88,57%	92,67%	93,99%	82,30%
AGUA	000MO.bmp	11%	87,96%	73,86%	73,99%	95,50%
	011M.tif	22%	65,76%	79,61%	84,10%	95,60%
	012M.tif	25%	86,44%	81,28%	85,10%	46,70%
	030M.tif	9%	84,34%	84,99%	85,55%	98,50%
	031M.tif	26%	70,06%	91,28%	92,20%	99,80%
OTROS	000MO.bmp	19%	95,50%	96,93%	97,24%	55,60%
	011M.tif	17%	97,84%	97,03%	95,77%	61,50%
	012M.tif	33%	97,34%	97,32%	97,73%	75,80%
	030M.tif	4%	96,19%	92,63%	86,35%	3,30%
	031M.tif	20%	97,92%	97,72%	97,02%	0,40%

Se comprueba que con un porcentaje muy pequeño de muestras para entrenamiento en cada imagen para segmentación semántica se pueden obtener resultados correctos, por encima del 55%, mediante una técnica simple de entender para un usuario final, quien solo tendrá que hacer clic en donde tenga la certeza que es muestra de la clase que desea clasificar. El algoritmo permite además tomar mayor cantidad de muestras para obtener precisión en la clasificación por encima del 85%, segmentando eficientemente las imágenes por completo y guardando las muestras para análisis futuros.

### B. Error con nuevas imágenes

La técnica requiere poner a prueba imágenes nuevas con información previa de tal forma que sobre las zonas de duda se haga un análisis más profundo. Se comparan los resultados para el caso de la segmentación semántica versus la

segmentación por píxeles GMM, en este caso hay que destacar que el análisis en ambos casos es supervisado pues se toman decisiones a partir de la información previa.

Tabla VI  
Píxeles correctamente clasificados en 5 imágenes con información de otra imagen similar

INFORMACION DE LAS IMÁGENES		ANÁLISIS DE ERROR DE CLASIFICACIÓN CON NUEVAS IMÁGENES		SEGMENTACIÓN CON TODOS LOS DATOS	
CLASE	IMAGEN	Píxeles x Clase	50 MUESTRAS DE OTRA	GMM DE OTRA	750 MUESTRAS
VEGETACION	000MO.bmp	70%	21,31%	97,72%	95,45%
	011M.tif	61%	95,90%	99,79%	97,10%
	012M.tif	42%	93,60%	96,53%	96,80%
	030M.tif	88%	18,70%	98,14%	98,99%
	031M.tif	54%	43,50%	22,79%	98,19%
AGUA	000MO.bmp	11%	24,95%	7,91%	84,13%
	011M.tif	22%	82,40%	0,00%	92,56%
	012M.tif	25%	32,30%	43,45%	86,37%
	030M.tif	9%	38,70%	34,52%	88,52%
	031M.tif	26%	0,40%	99,94%	93,67%
OTROS	000MO.bmp	19%	94,77%	0,00%	89,94%
	011M.tif	17%	95,10%	17,80%	91,73%
	012M.tif	33%	99,20%	11,87%	97,76%
	030M.tif	4%	99,90%	90,92%	84,76%
	031M.tif	20%	96,90%	1,36%	94,32%

Se observan mejores resultados en segmentación semántica principalmente en la clase otros, para el usuario final es más valioso tener precisión en ella, ya que el objetivo de búsqueda es encontrar anomalías en los paisajes tropicales que normalmente solo deben estar compuestos de las clases vegetación y agua. La última columna muestra además que teniendo mayor cantidad de muestras el algoritmo mejora sus resultados, siendo la base de la inteligencia artificial una ventaja adicional para el método propuesto. Por estas razones el algoritmo semántico se adapta mejor a las condiciones de cambio en cuanto a la toma de las fotografías ya que estas difieren en muchos factores, es más simple de usar y tiene mayor efectividad clasificando los grupos de píxeles

desconocidos.

## V. CONCLUSIONES

Los resultados demuestran que el clasificador funciona con baja probabilidad de error sacando pocos datos de entrenamiento. Por otro lado el algoritmo consume pocos recursos computacionales, máxime teniendo en cuenta que se transformaron 928.800 datos de color con características en sus componentes RGB, en 150 muestras con 21 características obtenidas de su respuesta a los descriptores de covarianza en el entrenamiento y luego aplicándolos en la clasificación. Los resultados son superiores al 80% en segmentación correcta de las clases haciendo que al algoritmo aplicado la metodología de segmentación sea relevante y funcional para el usuario final.

La técnica es aplicable y eficiente para la segmentación de imágenes de paisajes tropicales, además permite integrar otras características que ayudan a diferenciar más clases y con mayor precisión.

Una ventaja es que siempre se pueden mejorar los resultados en la medida que se tenga mayor número de muestras de entrenamiento dando la posibilidad de obtener resultados más exactos de los objetos contenidos en la imagen. Esta posibilidad no es aprovechable en los algoritmos de segmentación por píxel.

Una desventaja en el desarrollo del algoritmo es que resulta muy dependiente de la disponibilidad del experto para recopilar datos para el análisis de error, razón por la cual no fue posible usar la totalidad de las imágenes

disponibles en la base de datos para las pruebas y por otro lado algunas imágenes no cumplían los requisitos suficientes para las pruebas. De la misma forma se evidenció la dificultad para obtener imágenes para hacer otro tipo de análisis con sensores como el IR, ya que existe un grado de confidencialidad que no pudo superarse para obtenerlas, limitando el cumplimiento de los objetivos propuestos.

## VI. RECOMENDACIONES Y TRABAJOS FUTUROS

La base fundamental del algoritmo aplicado, consistió en la presentación de los datos en forma de sigma points y entrenados con SVM, es posible profundizar en el método si se emplea con otros métodos de entrenamiento de máquina y evaluando su desempeño.

Se debe evaluar el modo de presentación de los datos, para un ambiente supervisado. Este conocimiento es útil para mejorar el análisis y evaluación de imágenes cartográficas que en un futuro permitan mejorar la identificación de objetos extraños en imágenes de otros paisajes colombianos como el desierto, montaña, zonas costeras y marítimas donde son importantes estos estudios.

Para mejorar el análisis, velocidad de procesamiento y facilidad de uso por parte del usuario, es posible mejorar el algoritmo adicionando funciones semiautomáticas aprovechando las ventajas de presentar los datos a través de sigma points. Estos generan un grupo de números (en este caso 21) que relacionan el comportamiento de los



componentes RGB de un grupo de píxeles, en el caso de las clases agua y vegetación parte de los sigma points se encuentran en intervalos muy pequeños ya sea por ejemplo porque la vegetación siempre es verde en distintas tonalidades o el agua siempre es plana sin importar su color lo que permite generar clústeres a través de mecanismos no supervisados como la mezcla de gaussianas para encontrar a priori la clase de un cuadro de píxeles seleccionado.

## VII. REFERENCIAS

- [1] Arbeláez, P.; Hariharan, B.; Gu, C.; Gupta, S.; Bourdev, L.; Malik, J.; University of California, Berkeley, *Semantic Segmentation using Regions and Parts*, Junio 2012, [https://people.eecs.berkeley.edu/~sgupta/pdf/ahggbm\\_cvpr2012.pdf](https://people.eecs.berkeley.edu/~sgupta/pdf/ahggbm_cvpr2012.pdf).
- [2] Avendaño, J.; Parra, J.; Bayona, J.; *Segmentación y clasificación de imágenes SAR en zonas de inundación en Colombia, una herramienta computacional para prevención de desastres*, Universidad Antonio Nariño – Revista de Facultades de Ingeniería, vol. 4, No. 8, pp 24-38; enero – Junio de 2014.
- [3] Carmona E.: Tutorial sobre maquinas vectores soporte (SVM), Universidad Nacional de Educación a Distancia UNED, 11 de Julio de 2014, p.1. <http://www.ia.uned.es/~ejcarmona/publicaciones/I2013-Carmona%20SVM.pdf>
- [4] Castilla G.; *Tesis Doctoral: Object-oriented analysis of remote sensing images for land cover mapping: conceptual foundations and a segmentation method to derive a baseline partition for classification*. Universidad Politécnica de Madrid Escuela Técnica Superior de Ingenieros de Montes, 2003.
- [5] Cordts, M.; Omran, M.; Ramos, S.; Rehfeld, T.; Enzweiler, M.; Benenson, R.; Franke, U.; Roth, S.; Schiele, B.; *The Cityscapes Dataset for Semantic Urban Scene Understanding*, Abril 2016, <https://arxiv.org/pdf/1604.01685.pdf>.
- [6] E. Guevara y O. A. Sánchez, “Segmentación de imágenes a color mediante técnicas de agrupamiento de datos empleando los algoritmos k-means y c-means”, Unidad Profesional Interdisciplinaria en Ingeniería y Tecnologías Avanzadas-IPN. México, D. F., Boletín No. 51, Nov de 2015
- [7] E. Guevara y O. A. Sánchez, “Segmentación de imágenes a color mediante técnicas de agrupamiento de datos empleando los algoritmos k-means y c-means”, Unidad Profesional Interdisciplinaria en Ingeniería y Tecnologías Avanzadas-IPN. México, D. F., Boletín No. 51, Nov de 2015.
- [8] Julier, S., Uhlmann, J.K.: A general method for approximating nonlinear transformations of probability distributions. Technical report, Robotics Research Group, Department of Engineering Science, University of Oxford (1996)
- [9] Kluckner S., Mauthner T., Roth P., Bischof H., Semantic classification in aerial imagery by integrating appearance and height information, Institute for Computer Graphics and Vision, Graz University of Technology, Austria, 2009. <http://www.icg.tugraz.at>.
- [10] P. Ponce, “Inteligencia Artificial con Aplicaciones a la Ingeniería” (1ª Edición) Alfaomega, México: ISBN: 978-607-7854-83-8. 2010.
- [11] P. Ponce, “Inteligencia Artificial con Aplicaciones a la Ingeniería” (1ª Edición) Alfaomega, México: ISBN: 978-607-7854-83-8. 2010
- [12] Pacheco, C.; Del Valle, H.; Delrieux, C.; *Revisión de algoritmos de segmentación desde una perspectiva orientada al sentido remoto de imágenes ópticas y de radar*, Conference Paper, Agosto 2014. <http://www.researchgate.net/publication/269631987>.
- [13] Tuzel, O., Porikli, F., Meer, P.: Learning on lie groups for invariant detection and tracking, Mitsubishi Electric Research Laboratories, TR2008-031 July 2008, CVPR (2008). <https://pdfs.semanticscholar.org>
- [14] Ventura, C.; La segmentación semántica y sus benchmarks, [en línea], Universidad abierta de Cataluña, May 26, 2016, <http://informatica.blogs.uoc.edu/2016/05/26/la-segmentacion-semantica-y-sus-benchmarks/>.