

Segmentación y clasificación de imágenes SAR en zonas de inundación en Colombia, una herramienta computacional para prevención de desastres

Segmentation and classification of SAR imagery on flood zones in Colombia, a computing tool for disaster prevention

Jonathan Avendaño Pérez*, Jaime Alberto Parra Plazas**, Jhon Fredy Bayona***



RESUMEN

La detección de zonas de inundación es fundamental para la prevención de desastres, por este motivo en este trabajo se presenta una herramienta computacional desarrollada en MATLAB que ofrece una alternativa a las existentes en el mercado para la clasificación supervisada de imágenes SAR (*Synthetic Aperture Radar*) de zonas de inundación. En particular se usaron diferentes métodos de clasificación para seleccionar de acuerdo al desempeño el mejor para el estudio de zonas de inundación en Colombia. Los datos de entrenamiento fueron generados con los resultados de las segmentaciones *Fuzzy- Clustering*, *K-means* y *Region-Growing* sobre imágenes SAR de zonas de inundación. Los métodos de clasificación implementados fueron un clasificador basado en el método Bayesiano y un clasificador basado en máquinas de soporte vectorial (SVM). Para evaluar el desempeño de los clasificadores se utilizaron índices como la exactitud total, la exactitud dependiendo del usuario, el índice Kappa y R'. De acuerdo a los resultados el clasificador basado en máquinas de soporte vectorial presenta mayor exactitud; sin embargo, el clasificador bayesiano se desempeña mejor clasificando píxeles que corresponden a poblaciones, aun con pocos datos de entrenamiento.

Fecha Recibido: Noviembre 13 de 2013

Fecha Aceptado: Marzo 25 de 2014

* Ingeniero Electrónico, Escuela Colombiana de Carreras Industriales-ECCI. Técnico profesional en Electrónica Industrial. Fue el mejor Saber-Pro a nivel nacional en el programa Técnico Profesional en Electrónica y Afines en el año 2009. Docente en la Escuela Colombiana de Carreras Industriales. jonathan.avendano.p@gmail.com

** Ingeniero Mecánico de la Universidad INNCA. Magister en ingeniería Mecánica de la Universidad de los Andes. Candidato a Doctor en Ingeniería en la Universidad de los Andes. Docente investigador, Escuela Colombiana de Carreras Industriales. jaiparra@gmail.com

*** Ingeniero electrónico, Universidad Antonio Nariño. Magister en Ingeniería Electrónica, Pontificia Universidad Javeriana. Docente investigador en la Escuela Colombiana de Carreras Industriales. ingebayona@gmail.com

Palabras clave: SAR, Clasificación, Segmentación, imágenes de zonas de inundación.

ABSTRACT

In order to prevent natural flood disasters it is important to identify the flood areas. In Colombia, there is space to develop automatic tools able to detect and study flood areas. For this reason, in this work we propose a computational tool in MATLAB, able to detect and classify Colombia's flood zones in SAR imagery. In particular, we used different classifiers, and according to the performance we selected the best. The training database was generated with the results of Fuzzy Clustering, K -means and Region -Growing segmentations on flood zones in SAR imagery. We used two different classifiers: the first one is a Bayes classifier, while the second one is a Support Vector Machine (SVM). In order to evaluate the performance, we used indices such as the overall accuracy, user accuracy and Kappa index. According to the results, the SVM classifier presents better accuracy. However, the Bayes classifier had better results classifying pixels corresponding to populations even with little training data.

Keywords. SAR, Classification, Segmentation, flood areas imagery.

1. INTRODUCCIÓN

En Colombia es muy común tener tiempos de sequía extrema y de abundante lluvia. Las lluvias en épocas del llamado fenómeno de la niña ejercen cambios en la hidrografía colombiana que provocan inundaciones y afectan física, económica y sensiblemente a las poblaciones cercanas a los ríos. Es entonces cuando las organizaciones del estado buscan tener un buen manejo de emergencias haciendo campañas de prevención, asistencia y recuperación en las zonas afectadas. El Instituto de Hidrología, Meteorología y Estudios Ambientales (IDEAM) es el organismo encargado de estudiar y monitorear el comportamiento del clima y la hidrología de Colombia. El IDEAM tiene en diferentes puntos de los ríos más importantes de Colombia estaciones hidrológicas que entregan medidas de caudal y nivel, esto con el fin de tener una idea del comportamiento de los cambios climáticos y de alguna manera prevenir pérdidas de vidas humanas y recursos económicos: como la ganadería, la agricultura y la infraestructura de los pueblos cercanos a estos ríos. Con esta información el IDEAM elabora unas gráficas en las que se ilustra el nivel del caudal de cada río para después tomar acciones preventivas basadas en alarmas que son informadas a los organismos del estado de prevención y rescate. Para lo ante-

rior se necesita de expertos que conozcan el área de inundación y que de una u otra manera con esta información de las estaciones de hidrología generen las diferentes alertas (amarilla, naranja o roja). Estos datos por lo general son mostrados a los representantes de las gobernaciones y municipios para que se tomen decisiones de acuerdo a la situación. La información es muy compleja de interpretar por personas ajenas al medio; pues no se cuenta con una interfaz amigable a todo usuario que sea capaz de ilustrar de la mejor manera la situación. Aquí es donde las imágenes satelitales pueden jugar un papel importante a la hora de evaluar los daños causados por una inundación. Con un buen procesamiento digital de imágenes es posible tener una herramienta con la cual no solo se pueda evaluar los daños en una inundación sino que también se pueda realizar seguimientos del comportamiento del río a través del tiempo que permitan determinar en una situación el posible actuar del río si sigue creciendo, además de permitir a las organizaciones territoriales escoger terrenos que a lo largo del tiempo no se han inundado aun en épocas de bastante lluvia para realizar sus construcciones y desarrollos de infraestructura. Las imágenes satelitales de apertura sintética SAR pueden ofrecer información exacta y precisa sin importar la nubosidad o la hora del día en que se tomaron.

Esta información puede ser clasificada en tierra, agua, poblaciones y otras clases de un sector geográfico. Estas imágenes originalmente poseen un ruido conocido como *Speckle*, el cual no permite una buena interpretación visual o digital de la imagen. Muchos algoritmos de segmentación utilizan la información presente en cada pixel, por esta razón las imágenes SAR deben ser mejoradas a través de filtros y muchas veces es necesario realizar procesos de fusión con otras imágenes de la misma zona provenientes de diferentes sensores con el fin de mejorar la calidad de la imagen. Para solucionar este inconveniente se han realizado estudios como el de Gambini [1] quien en 2006 creó un modelo estadístico del ruido *Speckle* y posteriormente elaboró un método para filtrarlo.

Los programas informáticos que existen hoy en día para el procesamiento de imágenes satelitales, como por ejemplo ARGIS y ENVI-SAR, poseen herramientas de segmentación y clasificación de imágenes, pero no se puede hacer una comparación entre varias opciones para establecer cuál es el mejor método de clasificación, estos programas están hechos para varios usos y no sólo para el uso de imágenes SAR y menos de una sola área territorial. Otro problema que existe es que no hay un patrón universal para evaluar los clasificadores y decidir cuál es mejor para este tipo de imágenes, como tampoco existen muchos datos de entrenamiento para realizar las clasificaciones supervisadas. El IDEAM puede acceder a imágenes satelitales de las zonas de interés, pero no cuenta con un software desarrollado para el estudio espacial y temporal de dichas zonas y de esta manera observar por separado los ríos, tierra o población. Un software que sea capaz de proporcionar información precisa acerca de la cantidad de áreas que el río inunda en condiciones de invierno o la cantidad de agua que desaparece en caso de sequía; una herramienta con la cual se pueda hacer simulaciones del comportamiento histórico (temporal) de un río para evaluar las zonas más aptas que permitan elaborar Planes de Desarrollo Territorial (POT) acordes a mapas de riesgo.

2. TRABAJOS RELACIONADOS

En la segmentación de imágenes existen diferentes técnicas que buscan extraer características de

las imágenes como por ejemplo: puntos de interés, bordes, contornos, regiones, etc. Para el caso de las imágenes SAR las técnicas más usadas son las que están enfocadas en caracterizar regiones. *Fuzzy Clustering* y *K-means* son técnicas de identificación no supervisada de patrones que buscan agrupar clases por su similitud, *Region-Growing* es una técnica de segmentación que toma en cuenta la información de los píxeles vecinos para después agruparlos. Si estos algoritmos son implementados sobre imágenes SAR el resultado será una agrupación de píxeles dentro de la imagen que representa zonas homogéneas dentro de la misma. En 2007 Yu and Clausi [2], realizaron un sistema para el análisis de hielo marino sobre imágenes SAR de zonas canadienses, los datos fueron obtenidos del Servicio Canadiense de Hielo *Canadian Ice Service* (CIS). El algoritmo de segmentación se basó en la técnica de crecimiento de región (*Region Growing*), debido a que esta guarda una buena segmentación y produce etiquetas semánticas de manera interactiva. El enfoque de este trabajo se llamó *Iterative Region Growing using Semantics* (IRGS) y fue evaluado por la interpretación visual de varios expertos del CIS quienes concluyeron que esta técnica es muy útil en el análisis del hielo marino, después de haber aplicado este algoritmo sobre varios conjunto de datos. Por otro lado en 2010 Huan-Min Luo et al. [3], implementaron los algoritmos de *Fuzzy Clustering* y *K-means* para la segmentación y posterior clasificación de zonas de bosques en datos POLInSAR (*Polarimetric Interferometric SAR*), aprovechando la información Física y las propiedades estáticas de los datos polarimétricos e interferométricos. En 2012, Samanta and Sanjal [4], realizaron segmentación de imágenes SAR, teniendo en cuenta las funciones de objetivo de dos diferentes técnicas de *Fuzzy-Clustering* su resultado fue que la técnica propuesta es efectiva a la hora de segmentar imágenes SAR. Este mismo año Yu and Clausi implementaron una extensión al algoritmo *Iterative Region Growing with Semantics* (IRGS) propuesto en [2] para la segmentación y clasificación no supervisada de datos SAR [5]. Un trabajo que muestra la importancia de las imágenes SAR en el estudio de fenómenos físicos es el presentado por Sae-puloh et al. [6] quienes en 2012 realizaron una aplicación con base a la decisión bayesiana para

la clasificación de datos polarimétricos Pi-SAR en la cual se extrajeron características geomorfológicas y estructurales de un volcán activo, ellos exponen que la comprensión geomorfológica y la distribución de los materiales de la superficie de un volcán activo son cruciales para la caracterización de las erupciones y mitigación de riesgos volcánicos, citan que en el estudio de los volcanes los sensores remotos SAR son la única observación y tecnología útil para el monitoreo en cualquier condición meteorológica. Pal et al. [7] en 2005, experimentaron sobre “Landsat 7 ETM+” con datos hiperespectrales, los resultados indicaron la superioridad de una SVM frente los métodos de Máxima probabilidad (*maximun likelihood*) y *Backpropagation Artificial Neural Networks* a la hora de que la dimensión de datos de entrada aumenta y los conjuntos de datos de entrenamiento decrecen. En el 2007, Tan et al. [8] formularon una nueva técnica que combinó la descomposición de entropía y la clasificación por SVM's. Su enfoque fue probado en imágenes multi-temporales SAR para el monitoreo de arroz y fue especialmente útil cuando recogió información polarimétrica por cada clase resultando una buena separación entre clases. En 2009 Lardeux et al. [9], usaron SVM's para clasificar densidad tropical de vegetación en imágenes SAR, sus resultados mostraron precisiones 20 % más altas que en los métodos de clasificación de “*Wishart*”. Ellos señalaron que una SVM puede realizar mejor aproximación que la típica aproximación de “*Wishart*” cuando el radar no sigue una “Distribución de *Wishart*”. En 2010 Mladic et al. [10], evaluaron tres paquetes comerciales de software para la detección de objetos basada en la clasificación binaria de áreas perturbadas y no perturbadas sobre imágenes en alta resolución. El software ENVI fue uno de los tres evaluados y este incorporaba un algoritmo ajustado desde la librería de “*Support Vector Machine*” (LIBSVM). Los resultados en las tres herramientas fueron comparados con “*Definiens Classification*” mostrando que las SVM's tienen alta consistencia comparadas con otros algoritmos de clasificación. Para la evaluación de la clasificación muchas veces es necesario hacer uso de la interpretación visual, pero la correcta evaluación de los métodos de clasificación es importante para el desarrollo de buenos algorit-

mos ya que esto permite evaluar por medio de comparaciones el comportamiento de los clasificadores. Con el objeto de establecer criterios de calidad en 2004 Dou et al. [11], implementaron un nuevo enfoque para la evaluación de la precisión en la clasificación de imágenes llamado R'. Los resultados obtenidos arrojaron un método nuevo y eficaz para la evaluación de la eficiencia en la clasificación de imágenes. En comparación con el índice de kappa el cual sólo puede reflejar la precisión total de la clasificación el método R' permite evaluar la clasificación por cada clase. En 2007 Liu et al. [12] realizaron una revisión y evaluación comparativa sobre las medidas de precisión de los clasificadores con el fin de ofrecer varias alternativas para evaluar la clasificación haciendo uso de la matriz de confusión.

3. SEGMENTACIÓN DE IMÁGENES SAR

La segmentación busca extraer características de las imágenes como por ejemplo: puntos de interés, bordes, contornos, regiones, etc. Este proceso divide la imagen en grupos de píxeles u objetos dando como resultado un conjunto de segmentos que cubren la imagen, o un conjunto de curvas de nivel extraídas de la imagen. Dass et al. [13]. La segmentación se aplica a diversos campos como por ejemplo: en procesos médicos, imágenes diagnósticas, planeación de tratamientos y estudios de anatomía, localización de carreteras, bosques, pueblos, agua, en imágenes satelitales, entre otras aplicaciones que necesiten identificar alguna característica. Durante muchos años se ha investigado sobre algoritmos para segmentar imágenes pero no se tienen métodos universales y esto hace que sea un problema no resuelto, siendo un desafío vigente para estudio del procesamiento digital de imágenes.

3.1 Región Growing

Este método fue desarrollado por Adamas and Bischof en 1994 [14] y busca por medio de un criterio de similitud agrupar píxeles. El proceso empieza con unos valores de intensidad de pixel dentro de la imagen que son definidos inicialmente, a estos valores se les conoce como semillas. La técnica busca agrupar píxeles vecinos

a las semillas que cumplan con el criterio de similitud determinado, este proceso de agrupación se realiza hasta que no se encuentre más valores de intensidad de pixel que cumplan con el criterio de similitud.

Algoritmo 1. Region Growing

1. Seleccionar las semillas dentro de la imagen.
2. Establecer el criterio de similitud.
3. Comprobar los pixeles cercanos a la semilla y determinar si cumplen con el criterio de similitud.
4. Si cumplen con el criterio estos pixeles se agregan a la semilla formando así una nueva semilla y se repite el paso 3. Si no cumple con el criterio no se agrupan estos pixeles y se termina el proceso.
5. Realizar los pasos 3 y 4 con todas las semillas definidas.

3.2 Clustering

En el procesamiento digital de imágenes la segmentación por *Clustering* tiene como objetivo agrupar pixeles en *Clusters* o racimos. Estos métodos son algoritmos interactivos en los cuales inicialmente se selecciona el número de *Clusters* (K), y seguidamente el algoritmo de manera autónoma agrupa los datos dentro de las imágenes entregando como resultado una imagen segmentada en colores, textura, intensidad o una mezcla de los anteriores

1) *k-means*: Este método fue desarrollado por MacQueen en 1967 [15]. Es uno de los métodos no supervisados para agrupar *Clusters*. Su funcionamiento consiste en escoger en primera instancia k -centroides de cada elemento a agrupar, la colocación de estos centroides juegan un papel importante a la hora de tener una buena agrupación. Después de que se han colocado los centroides se procede a calcular la distancia de cada elemento a cada centroide, etiquetando el elemento con el centroide con el cual tiene menor distancia de separación. Una vez se han asignado las etiquetas a todos los elementos se encuentra nuevamente la ubicación de cada centroide calculando la media de los valores asignados al grupo del centroide. Los pasos anteriores se repiten hasta que la ubicación de los

centroides converge. El algoritmo para *k-means* se resume de la siguiente manera:

En conclusión el algoritmo de k -means, pretende minimizar la función de costo:

Algoritmo 2 *K-means*

1. Seleccionar la ubicación inicial de los k -centroides. Este paso es muy importante para la correcta agrupación de los elementos, se procura que cada centroide quede lo más alejado uno del otro.
2. Determinar la distancia de cada elemento con respecto a cada k -centroide, asignadole la etiqueta del k -centroide de menos distancia. la fórmula para calcular las distancias es:

$$C^{(i)} := \min_k \|x^{(i)} - u_k\|^2 \quad (1)$$

Donde $C^{(i)}$ es la etiqueta asignada a cada elemento $x^{(i)}$ correspondiente al k -centroide con menor distancia, u_k es la ubicación de cada k -centroide, $\|x^{(i)} - u_k\|^2$ es la distancia del elemento $x^{(i)}$ al clúster u_k .

3. Cuando se tiene la asignación total de etiquetas de los elementos a agrupar, se procede a calcular la nueva posición de los k -centroides esto se realiza calculando el valor medio de los elementos agrupados a cada centroide por medio de la siguiente fórmula:

$$u_k = \frac{1}{L} \sum_{i=1}^L x_k^{(i)} \quad (2)$$

Donde L es el número de elementos asignados a cada centroide k .

4. Los pasos 2 y 3 se realizan hasta que el valor de los k -centroides converge.

$$j = \sum_{k=1}^K \sum_{i=1}^m \|x_i^{(k)} - u_k\|^2 \quad (3)$$

Donde K = Número de *Clusters* y m = Número de elementos (píxeles).

2) *Fuzzy-Clustering*: Conocido también como *Fuzzy-Clustering C-means* (FCM), fue desarrollado por Dunn en 1974 [16], y mejorado por Bezdek en 1981 [17], busca agrupar los elementos por medio del grado de pertenencia de los elementos a cada clúster. Este algoritmo busca minimizar la siguiente función de costo:

$$j_m = \sum_{i=1}^m \sum_{k=1}^K (u_{ki})^q \|x_i - c_k\|^2 \quad (4)$$

Dónde u_{ki} es el grado de pertenencia de x_i al cluster c_k , q es un exponente de ponderación para cada pertenencia difusa donde $1 \leq q < \infty$, m el número de elementos a segmentar, K es el número de clusters que debe ser $2 \leq K < m$. Yang and Huang, 2007 [18].

El grado de pertenencia u_{ki} es calculado de la siguiente manera:

$$u_{ki} = \frac{1}{\sum_{k=1}^K \frac{\|x_i - c_j\|^{\frac{2}{q-1}}}{\|x_i - c_k\|}} \quad (5)$$

Donde c_j es el valor del centro del clúster, calculado de la siguiente manera:

$$u_{ki} = \frac{1}{\sum_{k=1}^K \frac{\|x_i - c_j\|^{\frac{2}{q-1}}}{\|x_i - c_k\|}} \quad (6)$$

En resumen el algoritmo de *Fuzzy-Clustering* es:

Algoritmo 3. *Fuzzy-Clustering*

1. Escoger los valores de K , q y el Criterio de terminación E que varía entre 0 y 1.
2. Inicializar la matriz de partición difusa con:
 $U^{(0)}$, $U = [u_{ki}]$.
3. Por cada cluster se calcula el valor del centro, $C(k) = [c_j]$ con $U(k)$, usando la ecuación 6.
4. Actualizar $U(k)$, $U(k+1)$, ecuación 5.
5. Verificar si $\|U(k+1) - U(k)\| < E$ Si esto es cierto el algoritmo termina de lo contrario vuelve al paso 3.

4. CLASIFICACIÓN SUPERVISADA DE IMÁGENES SAR

La clasificación de imágenes se puede definir como el proceso que busca identificar la clase a la que pertenece cada pixel, objeto o región dentro una imagen. La clasificación puede ser supervisada y consiste en que se utilizan datos (firmas espectrales) ya identificados como muestras para encontrar datos no identificados. La no supervisada busca datos en una imagen sin datos de muestra es decir sin la ayuda de un experto o un estudio previo de la imagen.

4.1 Clasificador Bayesiano

Este método se basa en el teorema de decisión de Bayes el cual fue elaborado por Thomas Bayes en 1763 y está definido como:

$$P(A_i|B) = \frac{P(B|A_i)P(A_i)}{P(B)} \quad (7)$$

Dónde: $P(A_i|B)$ son las probabilidades a posteriori, $P(B|A_i)$ es la probabilidad de B en la hipótesis A_i y $P(A_i)$ son las probabilidades a priori. Una descripción completa de cómo funciona el clasificador bayesiano puede ser encontrada en el libro de Pajares y de la Cruz, [19].

El algoritmo para la clasificación bayesiana queda definido de la siguiente manera:

Algoritmo 4 Clasificador Bayesiano

1. Definir el número de clases C de acuerdo a los vectores de entrenamiento que se tengan.
2. Calcular la media de cada vector de entrenamiento.
3. Calcular la distancia de Mahalanobis de cada elemento con respecto a la media de cada vector de entrenamiento, y clasificar el elemento con respecto a la siguiente ecuación:

$$X \in C_i, \text{ si } d_E^2(X, m_i) < d_E^2(X, m_j) \quad \forall i \neq j, i, j = 1, 2, \dots, c \quad (8)$$

dónde

$$d_E^2 = \|x - y\|^2 = (x - y)^T (x - y) \quad (9)$$

4.2 Clasificador basado en SVM

Las SVM's fueron desarrolladas por Cortes y Vapnik en 1995 [20]. Fueron pensadas en un principio para la clasificación binaria. Están dentro de los clasificadores supervisados debido a que requieren muestras de entrenamiento, pero la literatura muestra que las SVM's no son relativamente sensibles al tamaño de la muestra Mountrakis et al. 2011 [21]. Esta técnica de clasificación busca separar las clases lo mejor posible aun si es necesario proyectar los datos en un espacio diferente al original. Cuando los datos no son separables linealmente se realiza un cambio de espacio por medio de transformaciones no




Figura 1. Varios Hiperplanos de separación con sus respectivos márgenes

lineales. En el caso de que exista una separación lineal entre clases, las SVM's crean un hiperplano que separa las clases entre si.

Existen muchos hiperplanos que pueden separar las clases, pero algunos con mayor margen que otros como se ilustra en la Figura 1. Lo que se busca con las SVM's es maximizar el margen de separación y minimizar el error a la hora de separar las clases encontrando un hiperplano separador óptimo.

La figura 2 ilustra la arquitectura de una SVM, donde la función de *kernel* $K(x_i, x_j)$ es escogida a priori, los parámetros de pesos y el umbral b son encontrados durante la fase del entrenamiento. La primera capa de pesos en la figura 2 son un sub-set de datos de entrenamiento ("Vectores de soporte"), y la segunda capa de pesos $\lambda_i = y_i \alpha_i$ son calculados por medio de los multiplicadores de Lagrange. Finalmente la clasificación se realiza de acuerdo al signo de la función de decisión de la ecuación (10).




Figura 2. Arquitectura de una SVM [22]

$$f(x) = \text{sgn} \left(\sum_i \lambda_i K(x_i, x_j) + b \right) \quad (10)$$

El algoritmo para la clasificación por SVM es:

Algoritmo 5 Clasificador por SVM

1. **Fase de entrenamiento:** Consiste en entrenar el modelo con conjunto de datos de entrenamiento $(x_i, y_i), i = 1, 2, 3, \dots, m$ donde $y \in \{1, -1\}$, esto con el fin de encontrar los hiperplanos que entreguen la mejor separación *kernel* y los parámetros del *kernel*.
2. **Fase de predicción:** Con el modelo ya entrenado se busca establecer a que clase pertenece cada elemento dependiendo de su posición frente al hiperplano.

Las SVM's son esencialmente clasificadores binarios (sólo dos clases), sin embargo, pueden adoptar tareas de clasificación múltiple (multi-clase) comúnmente usadas en teledetección. En los clasificadores SVM es muy común ver dos tipos de funcionamiento el '1 vs 1' y el '1 vs todos' Gidudu et al. 2007 [23]. El método '1 vs todos'. Consiste en entrenar K SVM's para distinguir $y_i = i$ del resto, para $i = 1, 2, 3, \dots, K$.

5. ÍNDICES DE EVALUACIÓN

Los índices de evaluación en la clasificación supervisada de imágenes remotas cumplen una importante labor a la hora de escoger el mejor método de clasificación para un caso en específico.

Clasificación: $f(x) = \text{sgn} \left(\sum_i \lambda_i K(x_i, x_j) + b \right)$

Pesos

Comparación:

$K(x_i, x_j) =$ Linea, o Polinomial, o RBF, o Sigmoide.

Vectores de soporte: x_1, \dots, x_n

Vector de entrada x

Cuadro I. Matriz de confusión

Datos Clasificados	Datos de Referencia				
	1	2	...	m	Total
1	P_{11}	P_{12}	...	P_{1m}	P_{1+}
2	P_{21}	P_{22}	...	P_{2m}	P_{2+}
...
m	P_{m1}	P_{m2}	...	P_{mm}	P_{m+}
Total	P_{+1}	P_{+2}	...	P_{+m}	N

Estos índices permiten hacer una comparación numérica de la eficiencia de los clasificadores para tener un argumento para decidir que método aplicar.

En la actualidad existen muchos índices que miden la eficiencia de los clasificadores, algunos de estos correlacionados entre sí, pero es difícil labor decir cuál de estos índices es la mejor manera de evaluar la clasificación de imágenes remotas. El trabajo de Liu and Kumar, 2007 [12] hace un resumen de diferentes mediadas para la evaluación de los clasificadores, ellos exponen en su trabajo que los índices de *User's Accuracy*, *Producer's Accuracy* y *Overall Accuracy* no deben faltar a la hora de evaluar el desempeño de un clasificador.

La mayoría de los índices de evaluación en la clasificación supervisada de imágenes hacen uso de la conocida matriz de confusión. Cuadro I.

Los siguientes índices hacen uso de la matriz de confusión y fueron tomados del trabajo de Liu and Kumar, 2007 [12].

5.1 User's Accuracy:

$$ua_i = \frac{P_{ii}}{P_{i+}} \quad (11)$$

Es una razón entre el número de elementos correctamente clasificados por clase y los elementos que fueron clasificados en esa clase, este índice comprende valores entre 0 y 1, siendo 1 el mejor valor posible. Si el resultado es 1 esto indica que el método aplicado no se equivocó clasificando dicha clase.

5.2 Producer's Accuracy:

$$pa_i = \frac{p_{ii}}{p_{+i}} \quad (12)$$

Es una razón entre el número de elementos correctamente clasificados por clase y los elementos que pertenecen a esa categoría, este índice comprende valores entre 0 y 1, siendo 1 el mejor valor posible. Si el resultado es 1 esto indica que el método aplicado clasifica bien los datos de referencia de esa categoría.

5.3 Overall Accuracy (OA):

$$OA = \frac{1}{N} \sum_i^m P_{ii} \quad (13)$$

Este índice es una razón entre el total de datos correctamente clasificados y el número total de observaciones incluidas en la matriz. Varía entre 0 y 1, siendo 1 el mejor resultado. Si el resultado es 1 esto indica que el método aplicado clasificó correctamente cada una de las clases.

5.4 Overall Error (OE):

$$OE = 1 - OA \quad (14)$$

Este índice está directamente correlacionado con el índice número 3 (OA), mide la tasa de error que tuvo el método aplicado a la hora de clasificar. Varía entre 1 y 0 siendo 0 el mejor valor, Si el valor es 0 esto indica que el clasificador no tuvo errores.

Los anteriores índices fueron desarrollados por Story y Congalton, 1986 [24].

5.5 Kappa

$$Kappa = \frac{\sum_i^m P_{ii} - \sum_i^m P_{+i}P_{i+}}{1 - \sum_i^m P_{+i}P_{i+}} \quad (15)$$

Es una medida de concordancia que muestra el grado de acuerdo entre dos observadores a la hora de clasificar, en este caso los dos observadores son: los datos que clasifica el método y los datos de referencia. Este índice fue realizado por Cohen, 1960 [25], e introducido en la evaluación de imágenes remotas por Congalton y Mead, 1983 [26]. Este valor varía entre 0 y 1 siendo 1 el mejor valor posible. Una escala de valorización para el índice kappa es el cuadro II que fue propuesto por Landis and Koch, 1977 [27].

Cuadro 2. Escala de valorización para el índice *Kappa*

<i>Kappa</i>	Grado de acuerdo
$K = 0,00$	Sin acuerdo
$K > 0,2$	Insignificante
$0,21 < K < 0,4$	Discreto
$0,41 < K < 0,6$	Moderado
$0,61 < K < 0,8$	Sustancial
$0,81 < K < 1$	Casi Perfecto
$K = 1$	Perfecto

5.6 V-F. R' y R'_i

Este método de evaluación fue introducido por Dou et al. 2004 [11] para la clasificación de imágenes remotas. Consiste en lo siguiente:

Una imagen remota llamada S donde A son los datos de referencia, N_A el número de datos de referencia, B los datos obtenidos de la clasificación, N_B el número de datos obtenidos de la clasificación, AB los datos correctamente clasificados, N_{AB} el número de datos correctamente clasificados y N el número total de píxeles (datos) de la imagen. Entonces:

$$R'(A|B) = R(A|B) + P(A) \quad (16)$$

Dónde:

$$R(A|B) = \frac{N_{AB}}{N_A} + \frac{N_B}{N} \quad (17)$$




Figura 3. Relación entre los datos clasificados y los de referencia [11]

$$P(A) = \frac{N_A}{N} \quad (18)$$

La ecuación (16) es el índice R' de la clasificación total. Para el índice R'_i por clase la formulación es la siguiente:

$$R'_i = \frac{N_{ABi}}{N_{Ai}} - \frac{N_{Bi} + N_{Ai}}{N} \quad (19)$$

Los resultados obtenidos al evaluar la clasificación con R' , muestran un método nuevo y eficaz para la evaluación de la eficiencia en la clasificación de imágenes. En comparación con el índice de *kappa* el cual sólo puede reflejar la precisión total de la clasificación, el método R' permite evaluar la clasificación por cada clase. Dou et al. 2004, [11].

6. MÉTODO

La figura (4) ilustra las fases del método propuesto en este trabajo. Se inicia con la generación de los datos de entrenamiento con los cuales se entrenaran los dos enfoques de clasificación supervisada propuestos (Bayesiano y SVM). Los datos de entrenamiento son generados con los resultados de las segmentaciones (*Fuzzy-Clustering*, *K-means* y *Region- Growing*) aplicadas al conjunto de datos de imágenes SAR utilizado en este trabajo. Con los datos de entrenamiento generados en la primera fase los cuales contienen tres grupos de firmas espectrales (agua, tierra y poblaciones) se procede con la fase de clasifica-




Figura 4. Método propuesto

ción, en esta fase se clasifican los píxeles de las imágenes en agua, tierra y poblaciones. La última fase del método propuesto consiste en evaluar el desempeño de cada clasificador por medio de índices de calidad.

6.1 Generación de los datos de entrenamiento

Para la implementación de los algoritmos de clasificación supervisada es necesario tener un conjunto de datos para entrenar cada modelo, pero debido a que en Colombia no existe una base de datos en la que se encuentren los valores de intensidad de píxeles que dentro de una imagen SAR correspondan a zonas de agua, tierra y poblaciones, fue necesario elaborar un conjunto de datos de entrenamiento para tal fin. Lo primero que se hizo fue segmentar las imágenes para caracterizar cada clase (agua, tierra y poblaciones) usando los algoritmos de *Fuzzy-Clustering*, *K-means* y *Región-Growing*. El resultado de cada segmentación por cada clase fue una imagen binarizada en la cual se tenía '1' cuando el valor de intensidad del píxel correspondía a la clase, y '0' si era lo contrario. En la Figura 5 se ilustra el resultado de una segmentación de Agua usando *Fuzzy-Clustering* sobre una imagen SAR. Con los resultados de las tres segmentaciones se realizó una verificación píxel a píxel dentro cada imagen segmentada y la imagen original. Si el valor en la posición del píxel de la imagen segmentada era "1", dicho valor de la misma posición dentro de la imagen original se almacenaba como dato de entrenamiento dentro de una base de datos. En la Figura 6 se ilustra el proceso para la creación de la datos de entrenamiento de una clase.

El proceso que se ilustra en la Figura 6, se realizó por cada clase y luego se unificaron sus resul-




Figura 5. Resultado de la segmentación usando *Fuzzy-Clustering*

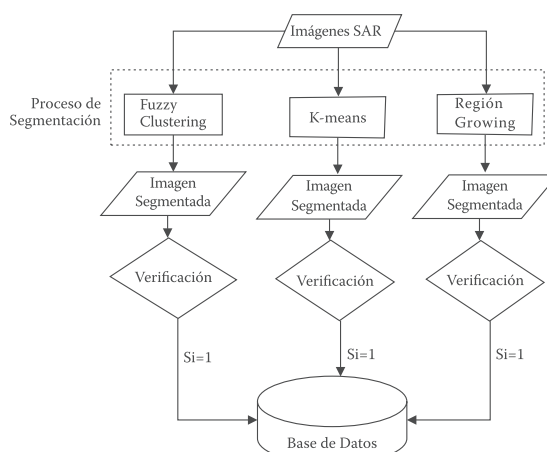


Figura 6. Algoritmo para la creación de la base de datos de una clase

tados obteniendo al final una base de datos de entrenamiento con 328.391 elementos donde 173.326 pertenecen a valores de intensidad de agua, 149.589 de tierra y 5476 de poblaciones.

6.2 Implementación de los algoritmos de clasificación y evaluación

Para facilitar la implementación de los algoritmos de clasificación se creó una interfaz gráfica de usuario (GUI) usando MATLAB. En el caso de la SVM se implementó la versión 3.6 de la librería (LIBSVM) para MATLAB realizada en 2011 por

Chang et al. [28], esta librería tiene dentro de sus funciones la validación cruzada herramienta que se usó para elegir los mejores parámetros ($g = \text{gamma}$) y ($c = \text{costo}$), los cuales para este caso fueron de ' $c = 4$ ' y ' $g = 1024$ '. Con estos parámetros la clasificación con SVM logró una eficiencia del 98.8 %; se utilizó el *Kernel RBF (Radial Basis Function)*. En cuanto al clasificador bayesiano se usó el programa que Pajares et al. [19] ofrece en su libro "Ejercicios resueltos de Visión por Computador". Después de que se garantizó que se contaba con una buena base de datos para el entrenamiento y que ambos algoritmos de clasificación estaban funcionando correctamente se desarrolló una GUI en MATLAB que permitió evaluar los algoritmos de clasificación implementados mediante los índices de comparación: *Producer's Accuracy*, *Users's Accuracy*, R_i por clase, *Overall Accuracy (OA)*, *Overall Error (OE)*, *Kappa*, *Mean Square Error (MSE)* y R' .

6.3 Creación de la imagen de referencia

Para la evaluación de los clasificadores fue necesario crear una imagen de referencia de la cual se pudiera conocer la clasificación exacta de las clases dentro de la misma. Para su creación se escogieron aleatoriamente píxeles dentro de zonas homogéneas de las imágenes reales correspondientes a cada clase (agua, tierra y poblaciones). Cabe aclarar que en la clase tierra se encuentran las firmas espectrales de los píxeles de suelos expuestos, áreas de pastizales, vegetación rastrojera y todo tipo de terreno que no corresponda a las poblaciones (asfalto, edificios, carreteras, etc.) El resultado fue una imagen de 128×128 píxeles con tres zonas diferentes como se puede observar en la Figura 7 donde: la parte superior corresponde a agua, la intermedia a tierra y la inferior a poblaciones.




Figura 7.
Imagen sintética

6.4 Configuración del experimento

Este proyecto usó imágenes SAR de Colombia de diciembre de 2010, época de grandes inundaciones, estas imágenes corresponden a la zona del río Magdalena bajo y fueron obtenidas del banco de imágenes del IDEAM y están previamente procesadas en cuanto al ruido *Speckle*. Todas las imágenes usadas en este proyecto son de polarización HH, con resolución radiométrica de 16 bits, resolución espacial de 10 metros y son provenientes del sensor remoto RADARSAT-2.

7. EXPERIMENTACIÓN Y RESULTADOS

Se implementaron los algoritmos de clasificación propuestos en este trabajo sobre la imagen sintética, cambiando para cada algoritmo el número de datos de entrenamiento (10, 100, 500 y 1000). Para mostrar los resultados de la clasificación se usaron tres colores: verde para la clase tierra, azul para la clase agua y rojo para la clase población. Figura 8.

En los cuadros 3 y 4 están las matrices de confusión de cada clasificador para 1000 muestras, los cuadros 5, 6 y 7 muestran los índices de evaluación de cada clasificador con diferente número de datos de entrenamiento. Los cuadros 5, 6 y 7 comparan los resultados de la clasificación por clase (agua, tierra y poblaciones) entre los dos

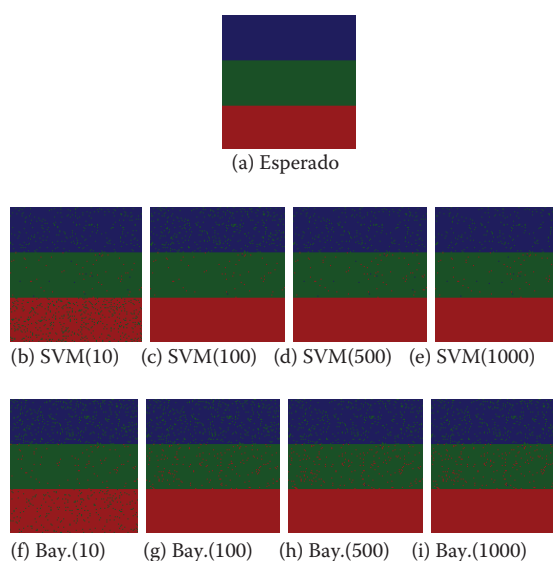


Figura 8. Resultados clasificación imagen sintética

algoritmos, mientras que el cuadro 8 compara el resultado total de la evaluación de los dos algoritmos de clasificación. Los siguientes resultados se obtuvieron al implementar los algoritmos de clasificación propuestos en este trabajo usando MATLAB 2011b sobre un computador con sistema operativo Windows 8, con un procesador AMD Athlon (tm) II Dual-core M320 a 2.10Ghz y 3 Gb de RAM.

Como se puede observar en el cuadro 8, el algoritmo de SVM tiene una eficiencia menor que el bayesiano cuando se usan pocos datos de entrenamiento, pero cuando se usa mayor número de datos de entrenamiento la eficiencia de algoritmo con SVM aumenta mientras que la del bayesiano empieza a disminuir. El índice Kappa el cual es una medida de concordancia entre dos matrices, aumenta en el SVM a medida de que se usan más datos para el entrenamiento y en el Bayesiano a partir de 1000 datos de entrenamiento empieza a disminuir. El índice R' con 10 datos para el entrenamiento es igual para los dos algoritmos pero a medida de que se aumentan los datos de entrenamiento este índice empieza a subir para el SVM y a disminuir para el algoritmo Bayesiano. En el cuadro 6 se puede observar que las SVM clasifican mejor la clase agua que el bayesiano, que ambos algoritmos después de 100 muestras no se equivocan clasificando poblaciones y que ambos tienen casi una misma precisión de clasificación de la clase tierra. En el cuadro 5 se ilustran los resultados del 'PRODUCER'S ACCURACY' y se puede evidenciar que: a medida de que se aumenta el número de muestras la eficiencia del clasificar los pixeles de referencia de la clase agua se mantiene en las SVM y disminuye en el Bayesiano, en la clase tierra se evidencia un crecimiento de este índice por parte de los dos algoritmos

y con la clase población se puede observar una tendencia a disminuir.

En el cuadro 7 donde se ilustran los resultados de R' por clase se puede observar que: con la clase agua el índice para el SVM es mayor que el del bayesiano pero se mantienen a medida de que se aumentan los datos de entrenamiento, para el caso de la clase tierra este índice aumenta en el SVM pero se mantiene en el bayesiano y con la clase población ambos índices aumentan a mayor número de muestras pero las SVM tienen mejores resultados.

Los resultados del cuadro 6 muestran que en el caso de que se no se cuente con muchos datos para el entrenamiento y que se buscara una buena clasificación de las poblaciones sería pertinente usar el algoritmo bayesiano en vez del basado en vectores de soporte, cabe aclarar que lo anterior serviría para aplicarlos a este caso de estudio, con esta base de datos y las imágenes con las cuales se trabajo en este proyecto.

Cuadro 3. Matriz de confusión svm (1000 muestras)

	Agua	Tierra	Pobla.	Total
Agua	5266	238	0	5504
Tierra	13	5418	73	5504
Pobla.	0	0	5376	5376
Total	5279	5656	5449	16384

Cuadro 4. Matriz de confusión bayesiano (1000 muestras)

	Agua	Tierra	Pobla.	Total
Agua	5064	440	0	5504
Tierra	2	5277	225	5504
Pobla.	0	0	5376	5376
Total	5066	5717	5601	16384

Cuadro 5. Producer's accuracy en (%)

No. Muestras	SVM			Bayesiano		
	Agua	Tierra	Pobla.	Agua	Tierra	Pobla.
10	99.79	86.888	98.794	100	87.465	98.148
100	99.96	92.947	98.914	100	91.591	96.43
500	99.79	95.12	98.642	99.96	92.741	95.982
1000	99.753	95.792	98.66	99.96	92.303	95.982

Cuadro 6. Users's accuracy en (%)

No. Muestras	SVM			Bayesiano		
	Agua	Tierra	Pobla.	Agua	Tierra	Pobla.
10	94.949	98.728	89.918	91.151	98.255	94.642
100	92.496	98.891	100	91.151	96.384	100
500	94.949	98.455	100	92.496	95.875	100
1000	95.67	98.437	100	92.005	95.875	100

Cuadro 7. R² por clase

No. Muestras	SVM			Bayesiano		
	Agua	Tierra	Pobla.	Agua	Tierra	Pobla.
10	0.965	0.941	0.928	0.941	0.941	0.958
100	0.95	0.967	0.996	0.941	0.946	0.987
500	0.965	0.972	0.995	0.95	0.947	0.986
1000	0.97	0.975	0.995	0.946	0.945	0.986

Cuadro 8. Indices globales

SVM				
No. Muestras	10	100	500	1000
OA (%)	94.567	97.106	97.784	98.022
OE (%)	5.432	2.893	2.215	1.977
Kappa	0.918	0.956	0.966	0.97
MSE	0.054	0.028	0.022	0.019
R ²	0.945	0.971	0.977	0.98
Bayesiano				
No. Muestras	10	100	500	1000
OA (%)	94.683	95.813	96.093	95.929
OE (%)	5.316	4.187	3.906	4.07
Kappa	0.92	0.937	0.941	0.938
MSE	0.053	0.041	0.039	0.04
R ²	0.946	0.958	0.96	0.959

Los resultados del cuadro 8 donde se muestran los índices de la eficiencia total de un clasificador muestran la superioridad del algoritmo basado en vectores de soporte para la clasificación de imágenes SAR. Con base a este resultado se procedió a ejecutar este algoritmo sobre una imagen real de una zona de inundación en Colombia usando 1000 datos para el entrenamiento. La imagen usada corresponde al área comprendida en las siguientes coordenadas: Longitud Oeste =

133° 33' 23.3099", Latitud Norte = 4° 18' 5.8401", Longitud Este = 133° 31' 5.9745" y Latitud Sur = 4° 05' 20.1729". En la parte superior de esta imagen se encuentra ubicado el municipio del Plato Magdalena cuya altura promedio sobre el nivel del mar es de 20 metros. La temperatura aproximada en esta zona de Colombia es de 32 °C. Este municipio se encuentra localizado a las orillas del río Magdalena por esta razón es susceptible a las inundaciones. La imagen usada fue tomada el 13 de diciembre de 2010 por el satélite RADARSAT-2 y es propiedad del IDEAM.



(a) Imagen Original

(b) Imagen clasificada




Figura 9. Resultado de la clasificación usando SVM

7. CONCLUSIÓN

En este trabajo el lector puede observar dos propuestas. La primera es una técnica para la generación de una base de datos de entrenamiento de imágenes SAR en zonas de inundación.

La base de datos es utilizada para realizar el entrenamiento de los clasificadores supervisados. La generación de esta base de datos se hizo mediante el uso de distintas técnicas de segmentación como *Fuzzy-Clustering*, *K-means* y *Region Growing*. Esta técnica representa una alternativa a estudios donde no se cuenta con una base de datos para realizar el entrenamiento de clasificadores supervisados. La segunda propuesta es una herramienta computacional para clasificar las imágenes, y evaluar el desempeño del clasificador.

La implementación de índices de calidad mostró una alternativa para la selección de un clasificador en un caso de estudio específico, como por ejemplo el de este trabajo (zonas de inundación en Colombia), esto permitió una comparación numérica de los resultados de la clasificación. Estos índices mostraron que para este caso de estudio la clasificación por SVM tiene mayor eficiencia que el clasificador bayesiano a la hora de evaluar la precisión total de la clasificación, pero el clasificador bayesiano es mejor detectando la clase poblaciones aun con pocos datos de entrenamiento. Lo anterior se puede verificar en los cuadros 8 y 6 respectivamente. Como trabajo futuro se propone la implementación de algoritmos de detección de cambios y fusión temporal que evalúen los cambios en alguna zona particular de Colombia antes, durante y después de una inundación. Para esto se pueden implementar métodos de detección de cambios *post-classification* o *pre-classification*.

AGRADECIMIENTOS

Agradecemos al IDEAM por las imágenes SAR que facilitaron para el desarrollo de este trabajo.

REFERENCIAS

[1] M. J. Gambini, "Modelos de segmentación basados en regiones y contornos activos aplicados a imágenes de radar de apertura sintética," Ph.D. dissertation,

Universidad de Buenos Aires Facultad de Ciencias Exactas y Naturales Departamento de Computación, 2006.

[2] Q. Yu and D. Clausi, "Sar sea-ice image analysis based on iterative region growing using semantics," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 45, no. 12, pp. 3919–3931, Dec 2007.

[3] H.-M. Luo, E. Chen, X. Li, J. Cheng, and M. Li, "Unsupervised classification of forest from polarimetric interferometric sar data using fuzzy clustering," in *Wavelet Analysis and Pattern Recognition (ICWAPR), 2010 International Conference on*, 2010, pp. 201–206.

[4] D. Samanta and G. Sanyal, "Segmentation technique of sar imagery based on fuzzy c-means clustering," in *Advances in Engineering, Science and Management (ICAESM), 2012 International Conference on*, 2012, pp. 610–612.

[5] P. Yu, A. K. Qin, and D. Clausi, "Unsupervised polarimetric sar image segmentation and classification using region growing with edge penalty," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 50, no. 4, pp. 1302–1317, 2012.

[6] A. Saepuloh, K. Koike, and M. Omura, "Applying bayesian decision classification to pi-sar polarimetric data for detailed extraction of the geomorphologic and structural features of an active volcano," *Geoscience and Remote Sensing Letters, IEEE*, vol. 9, no. 4, pp. 554–558, 2012.

[7] M. Pal and P. Mather, "Support vector machines for classification in remote sensing," *International Journal of Remote Sensing*, pp. 1007–1011, 2005.

[8] C. Tan, J. Koay, K. Lim, H. Ewe, and H. Chuah, "Classification of multi-temporal sar images for rice crops using combined entropy decomposition and support vector machine technique," *Progress in Electromagnetics Research*, pp. 19–39, 2007.

[9] C. Lardeux, P. Frison, C. Tison, J. Souyris, B. Stoll, and B. Fruneau, "Support vector machine for multi-frequency sar polarimetric data classification," *IEEE Transactions on Geoscience and Remote Sensing*, pp. 4143–4152, 2009.

[10] C. Mladinich, "An evaluation of object-oriented image analysis techniques to identify motorized vehicle effects in semi-arid to arid ecosystems of the american west," *GIScience & Remote Sensing*, pp. 53–77, 2010.

[11] A. X. Dou, X. Q. Wang, and M. W. Dou, "A new approach to evaluate the accuracy of image classification result - r." *Geoscience and Remote Sensing Symposium, 2004. IGARSS '04. Proceedings. 2004 IEEE International*, 2004.

- [12] C. Liu, P. Frazier, and L. Kumar, "Comparative assessment of the measures of thematic classification accuracy," *Remote Sensing of Environment*, pp. 606–616, 2007.
- [13] R. Dass, Priyanka, and S. Devi, "Image segmentation techniques," *International Journal of Electronics & Communication Technology IJEC*, vol. 3, no. 14, pp. 66–70, March 2012.
- [14] R. Adams and L. Bischof, "Seeded region growing," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 16, no. 6, pp. 641–647, 1994.
- [15] J. B. MacQueen, "Some methods for classification and analysis of multivariate observations," in *Proc. of the fifth Berkeley Symposium on Mathematical Statistics and Probability*, L. M. L. Cam and J. Neyman, Eds., vol. 1, Proc. of the fifth Berkeley Symposium on Mathematical Statistics and Probability. University of California Press, 1967, pp. 281–297.
- [16] J. C. Dunn, "A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters," 1974.
- [17] J. C. Bezdek, "Pattern recognition with fuzzy objective function algorithms," 1981.
- [18] Y. Yang and S. Huang, "Image segmentation by fuzzy c-means clustering algorithm with a novel penalty term," *COMPUTING AND INFORMATICS*, vol. 26, no. 1, 2007. [Online]. Available: <http://www.cai.sk/ojs/index.php/cai/article/view/296>
- [19] G. Pajares and J. M. de la Cruz Garcia, *Ejercicios resueltos de Vision por Computador*. Mexico D.F., 221 Mexico: Alfaomega, 2008.
- [20] C. Cortes and V. Vapnik, "Support-vector networks," *Mach. Learn.*, vol. 20, no. 3, pp. 273–297, Sep. 1995. [Online]. Available: <http://dx.doi.org/10.1023/A:1022627411411>
- [21] 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. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0924271610001140>
- [22] B. Scholkopf and A. J. Smola, *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*. The MIT Press, 2001.
- [23] A. Gidudu, G. Hulley, and T. Marwala, "Image classification using svms: One-against-one vs one-against-all," *CoRR*, vol. abs/0711.2914, 2007.
- [24] M. Story and R. G. Congalton, "Accuracy assessment - A user's perspective," *Photogrammetric Engineering and Remote Sensing*, vol. 52, no. 3, pp. 397–399, Mar. 1986. [Online]. Available: <http://www.asprs.org/publications/pers/scans/1986journal/mar/1986mar397-399.pdf>
- [25] J. Cohen, "A Coefficient of Agreement for Nominal Scales," *Educational and Psychological Measurement*, vol. 20, no. 1, p. 37, 1960.
- [26] R. Congalton and R. A. Mead, "A Quantitative Method to Test for Consistency and Correctness in Photointerpretation," *PHOTOGRAMMETRIC ENGINEERING & REMOTE SENSING*, vol. 49, no. 1, pp. 69–74, 1983. [Online]. Available: <http://www.citeulike.org/group/7074/article/6012274>
- [27] J. R. Landis and G. G. Koch, "The Measurement of Observer Agreement for Categorical Data," *Biometrics*, vol. 33, no. 1, pp. 159–174, Mar. 1977.
- [28] C.-C. Chang and C.-J. Lin, "LIBSVM: A library for support vector machines," *ACM Transactions on Intelligent Systems and Technology*, vol. 2, pp. 27:1–27:27, 2011, software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.