

## MÓDULO DE SENSORES REMOTOS PARA HIDROSIG JAVA

***Olver O. Hernández y John W. Branch***

*Escuela de Geociencias y Medio Ambiente y Escuela de Sistemas, Facultad de Minas  
Universidad Nacional de Colombia, Sede Medellín  
oohernan@unalmed.edu.co*

Recibido para evaluación: 12 de Agosto de 2003 / Aceptación: 25 de Septiembre de 2003 / Recibida versión final: 30 de Septiembre de 2003

### RESUMEN

El principal objetivo de este trabajo es la construcción de un módulo de sensores remotos para HidroSIG Java, el cual tenga la posibilidad de visualizar imágenes y hacer clasificación supervisada sobre éstas.

Para la clasificación se revisó la bibliografía y se decidió que los algoritmos de clasificación a implementar eran: el paralelepípedo y el de mínima distancia por su rapidez y sencillez, el de máxima probabilidad por que es el más usado y dos algoritmos novedosos, uno basado en redes neuronales y otro en lógica difusa, porque estas herramientas son muy potentes.

El módulo se probó y comparó con otras herramientas comerciales. La herramienta construida fue más rápida en los algoritmos comunes, además con los algoritmos novedosos se obtuvo mejor precisión.

**PALABRAS CLAVES:** Sensores Remotos, Clasificación Supervisada, HidroSIG Java, SIG.

### ABSTRACT

The the main objective of this work is the development of a remote sensing module for HidroSIG Java, presenting the possibility of visualizing images and of making supervised classification on these.

For the classification, bibliography was reviewed and it was decided that the sort al-gorithms to implement were: the paralelepiped and the minimum distance by its speed and simplicity, the one of máximo likelihood because it is the mostly used, and two new algorithms, one based on neural networks and the another one in fuzzy logic, because these tools are very powerful.

The module was proved and compared with other commercial tools. The constructed tool was faster in the common algorithms, in addition with the new algorithms obtained better precisión.

**KEY WORDS:** Remote sensing, supervised classification, HidroSIG Java, GIS.

## 1. INTRODUCCIÓN

Los sensores remotos involucran los procesos de percepción y análisis de la radiación electromagnética reflejada y transmitida de la superficie terrestre. En los últimos años se han desarrollado gran variedad de instrumentos para el muestreo de esta energía. Con la información obtenida por medio de los sensores, se puede analizar cualquier objeto o zona particular de la superficie terrestre, ayudando en diferentes tareas, tales como la localización de recursos naturales, de cuerpos de agua, la planeación de proyectos de construcción, diferenciación entre coberturas vegetales, entre otras muchas aplicaciones.

El procesamiento digital de imágenes puede ser agrupado principalmente en tres categorías: restauración, realce y extracción de información (Sabins, 1986). El proceso de restauración, consiste en reducir ruido, errores y distorsiones geométricas de las imágenes. El realce consiste principalmente en alterar la información visual, para resaltar las características principales de la imagen. Por último la extracción de información, que utiliza técnicas para el reconocimiento y clasificación.

En la parte de la clasificación, existen gran variedad de técnicas para la extracción de información de las imágenes digitales de sensores remotos, y éstas se dividen en dos grandes grupos, las técnicas no supervisadas, y las supervisadas. En la clasificación no supervisada, el computador separa los píxeles en clases, las cuales no son suministradas por nadie, generalmente, únicamente se especifica el número de clases que existen en una imagen y el algoritmo especifica para cada píxel, a que clase pertenece. En la clasificación supervisada el usuario define unas áreas pequeñas, las cuales representan cada una, una categoría del terreno, llamadas regiones de entrenamiento, luego el computador se encarga de asignarle a cada píxel de la imagen una de las categorías que se definieron. Existen varios algoritmos para realizar este tipo de clasificación, entre los más conocidos están el paralelepípedo, el de mínima distancia y el de máxima probabilidad. En los últimos años, investigadores en todo el mundo han desarrollado nuevas técnicas para la clasificación usando redes neuronales y lógica difusa, las cuales no han sido incorporadas a los diferentes software comerciales que se usan para realizar la clasificación supervisada de imágenes de sensores remotos.

En el posgrado en Aprovechamiento de Recursos Hidráulicos de la Facultad de Minas, se ha venido desarrollando un sistema de información geográfico llamado HidroSIG Java. Como su nombre lo indica, este software, está siendo desarrollado en el lenguaje de programación Java, (Correa, 2002; Mantilla, 1999; Ramirez, 2002; Vélez et al., 2000). Esta herramienta fue construida para la visualización de información hidroclimática, manejando para ello información de tipo raster y vectorial.

HidroSIG Java también cuenta con módulos para la visualización y el procesamiento de modelos digitales de terreno, métodos de interpolación para la estimación de variables hidrológicas y climáticas mediante técnicas de redes neuronales, tiene una calculadora para el manejo de datos matriciales y módulos para la visualización e interpretación de series temporales.

El principal objetivo de este trabajo es realizar una herramienta de software para la visualización y clasificación supervisada de imágenes de sensores remotos, que esté acoplada a HidroSIG Java, el cual posea los algoritmos tradicionales e incorpore las nuevas técnicas que se han desarrollado en los últimos años.

Este trabajo es el resultado del desarrollo del trabajo dirigido de grado de Olver Hernández, dirigido por John William Branch, dentro del marco del proyecto HidroSIG Java, el cual es desarrollado por el Posgrado en Aprovechamiento de Recursos Hidráulicos de la Escuela de Geociencias y Medio Ambiente adscrito a la Facultad de Minas de la Universidad Nacional de Colombia sede Medellín. Sinceros agradecimientos al grupo de trabajo del proyecto, principalmente al investigador principal Jaime Ignacio Vélez, por el apoyo y los recursos brindados para el desarrollo de este trabajo.

## 2. SENSORES REMOTOS

El observar la tierra por medio de los sensores remotos ha provisto una nueva vista de la tierra, mostrando nuevos campos de investigación y una amplia variedad de aplicaciones. Los sensores remotos son definidos como la colección e interpretación de información sobre un terreno sin estar en contacto físico con él. Aviones y satélites son las principales plataformas para adquirir información, siendo en este momento los satélites los más

usados, pero en los últimos meses se están desarrollando nuevas técnicas, que permiten obtener más información.

Comúnmente los sensores remotos se refieren a la obtención de información con el empleo de la energía electromagnética, la cual es reflejada o transmitida por los objetos que se encuentran en la superficie terrestre. Existen básicamente dos tipos de sensores: activos y pasivos. Los sensores activos poseen su propia fuente de radiación de energía; el sensor emite un flujo de radiación y la parte que se refleja es captada por el sensor. Los sensores pasivos son aquellos que miden la radiación que emiten o reflejan los objetos que proviene de una fuente externa (Cortijo, 1995).

Todos los objetos situados en la superficie terrestre emiten y reflejan energía. En el caso de la energía que se refleja, debe haber una energía incidente, la cual dependiendo de su longitud de onda, permitirá obtener el valor de la reflectancia del objeto. La radiación responde a diferentes longitudes de onda, por tanto, los sensores multispectrales se valen de ello para obtener varias medidas de un mismo terreno, estas diferentes medidas se convierten en lo que se conoce como bandas espectrales (Hsieh y Landgrebe, 1998).

Los sensores remotos se iniciaron con la aparición de las primeras fotografías. El dispositivo más conocido es la cámara fotográfica, la cual captura un retrato del objeto, concentrando la radiación electromagnética en una película o rollo. Las primeras fotografías de la tierra se tomaron desde globos en 1840 y en la primera Guerra Mundial, se tomaron fotos desde aviones, lo cual sirvió para el reconocimiento militar. La toma de imágenes desde cohetes empezó cuando se inició la era espacial, se tomaban fotos en el momento del ascenso. En los años sesenta, cuando el hombre había conquistado el espacio, los astronautas tomaban fotografías. Ya en los setenta, se incorporaron cámaras a los satélites de órbita.

En los setentas se lanzó el primer satélite de la serie Landsat. Los dos primeros satélites Landsat tenían dos tipos de sensores: el RBV (Return Beam Vidicom) y el MSS (Multi Spectral Scanner), el último fue lanzado en abril de 1999, el cual fue dotado de un sensor muy sofisticado llamado ETM+ (Enhanced Thematic Mapper Plus), que fue una mejora al sensor ETM de Landsat 6. Este sensor captura datos en ocho bandas, seis de ellas con una resolución espacial de 30 metros, una con una

resolución de 60 metros y otra banda pancromática con una resolución de 15 metros.

Otro tipo de imágenes muy comunes son las de tipo SPOT. El satélite SPOT (Système d'Observation de la Terre) fue lanzado en 1986 por la Agencia Espacial Francesa. SPOT emplea el sistema de imágenes HRV (high-resolution visible) (Sabins, 1986). Este sensor toma datos en tres bandas con una resolución espacial de 20 metros y una banda con resolución espacial de 10 metros. Nuevas tecnologías han surgido, con mejor resolución y mayor número de bandas. Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) es un sensor desarrollado en los últimos años por la NASA, el cual toma datos en 224 bandas espectrales con resoluciones espaciales de 20 metros (Hsieh y Landgrebe, 1998).

Una imagen es formada por un proceso de escaneo. Para cada porción de tierra (píxel), un conjunto de  $n$  valores es medido, donde cada uno de los  $n$  valores corresponde a una banda espectral, por lo tanto, cuando se trabaja con imágenes de tipo Landsat, se tendrá por cada píxel siete valores que lo caracterizan. Debido al carácter cuantitativo de estos datos (imágenes), para analizarlos se usan herramientas computacionales.

El análisis de datos de sensores remotos es usualmente hecho a través de técnicas de reconocimiento de patrones. Sobre la extracción de características en el reconocimiento de patrones se han hecho muchas investigaciones, ya que con dichas características se podrá etiquetar cada píxel de una imagen. Muchos métodos se han implementado para llevar a cabo estas tareas y estos han dado buenos resultados (Lee y Landgrebe, 1998).

### 3. CLASIFICACIÓN

La clasificación de imágenes de sensores remotos ha ganado mucha importancia en el análisis de procesos naturales y muchos proyectos de investigación se han basado en el análisis de los resultados de la clasificación. La clasificación puede definirse como: dado un conjunto de medidas sobre un conjunto finito de objetos, casos u observaciones se quiere construir una forma sistemática de predecir de qué clase es un nuevo objeto caso u observación (Cortijo, 1995; Dai, 2002).

El proceso de clasificación tiene dos etapas. La primera es reconocer las categorías que existen en el mundo real.

Tales categorías en el ambiente de sensores remotos pueden ser tipos de cobertura vegetal, roca, cuerpos de agua, construcciones urbanas, entre otros, dependiendo de la escala de la imagen y de la naturaleza del estudio que se va a realizar. La segunda etapa consiste en etiquetar los píxeles de la imagen a clasificar. Este etiquetado se hace con números, en donde por ejemplo la clase agua está etiquetada con el número "1" y así sucesivamente con las demás clases, al final, a cada píxel se le asigna un número, que representa la clase a la que pertenece según las propiedades de cada píxel, el cual puede ser caracterizado por un vector, cuyos elementos son el nivel de gris de cada banda espectral (Mather, 1999; Zhang y Landgrebe, 2001).

El vector cuyos elementos son niveles de gris, que caracteriza un píxel, es conocido como patrón. Luego el proceso de clasificación puede ser considerado como una forma de reconocimiento de patrones, que es la identificación de los patrones asociados a cada uno de los píxeles de la imagen en términos de los objetos que están representados en cada uno de los puntos de la superficie terrestre (Mather, 1999). Los pasos para realizar este reconocimiento son:

1. Selección de los rasgos particulares que mejor describan el patrón.
2. Elección de un método adecuado para la comparación de los patrones.
3. Como paso opcional, la comprobación de los resultados; medición del grado de exactitud conseguido con esa clasificación.

El objetivo final de los sensores remotos, es etiquetar cada uno de los píxeles que componen una imagen de satélite, para con esto obtener un mapa temático, donde ya no se tenga información poco diciente, sino información que puede ser fácil de entender y de analizar. Las etiquetas deben representar cada uno de los tipos de cubierta terrestre que se hallan en la imagen.

Existen dos tipos de clasificación: supervisada y no supervisada.

- **Clasificación supervisada:** El usuario ingresa una información que consiste en unas categorías o clases de información, llamadas conjuntos de entrenamiento, la cual proviene de un conocimiento previo que posee la persona que va a clasificar. En la clasificación se procura localizar los sitios donde los píxeles comparten características similares a las clases

previamente ingresadas por el usuario.

- **Clasificación no supervisada:** En esta no se ingresa información de ejemplo, sino que se agrupan los píxeles de acuerdo con la información espectral, en la que los píxeles que los miembros de una clase tienen características espectrales similares.

En algunos casos se usan métodos mixtos, ya que el método supervisado puede resultar a veces muy subjetivo y el método no supervisado puede carecer de significado real.

Independientemente del método utilizado, se hace necesario efectuar un análisis de las estadísticas, para comprobar que efectivamente se podrá efectuar una discriminación. Hay varios métodos de estudio de los datos, unos analíticos y otros gráficos. Más adelante se utilizará el método gráfico para ilustrar las distintas problemáticas que se plantean en un proceso de clasificación y las soluciones que se proponen.

Luego, el objetivo de la clasificación, es tratar de interpretar y diferenciar las clases o agrupamientos que existan, algo que el ojo humano en conjunto con el cerebro, lo hace muy bien. Pero que por la gran cantidad de datos que hay que etiquetar, se hace necesario el uso de herramientas computacionales.

#### 4. CLASIFICACIÓN SUPERVISADA

La clasificación supervisada es un tipo de método para extraer información de las imágenes de satélite, el cual está basado en un conocimiento externo del área. Entonces, a diferencia de los métodos no supervisados, los métodos supervisados requieren unas entradas del usuario antes de seleccionar el algoritmo a utilizar. Estas entradas pueden ser derivadas de trabajo de campo, análisis de fotos aéreas, reportes, etc (Jimenez y Landgrebe, 1998).

En general, los métodos supervisados son implementados usando algoritmos estadísticos o neuronales. Los algoritmos estadísticos utilizan parámetros derivados de los datos ingresados por el usuario, tales como mínimo, máximo, media, desviación estándar y matrices de varianza y covarianza (Ho.beck y Landgrebe, 1995). Por otro lado los métodos basados en redes neuronales usan la directamente información suministrada por el usuario.



#### 4.1. Conjuntos de entrenamiento

Un conjunto de entrenamiento está compuesto por parejas de información, las cuales están compuestas por un punto y la clase a la que pertenece el punto en cuestión, esta información es extraída de la experiencia o el conocimiento que tenga el usuario. La selección de estos puntos y la clase a la que pertenece cada uno de estos es fundamental a la hora de clasificar, ya que si se ingresa información incorrecta los resultados podrán ser erróneos (Shine y Wakefield, 1999).

La validez de los resultados que se obtengan de la clasificación, estará dado por la representatividad de las muestras tomadas, es decir, que los píxeles tomados contienen las diferentes «variedades» que se presenten en el rango de valores de la clase. Para lograr una buena representatividad de las clases es mejor tomar pocos datos de diferentes zonas, que tomar muchos datos de una sola zona.

#### 4.2. Algoritmos

Los clasificadores, también llamados algoritmos de clasificación son una regla que permite establecer la clase a la que pertenece un punto dado, al aplicar lo anterior a cada uno de los puntos de la imagen, obtendremos el resultado del proceso de clasificación, también llamado mapa temático.

Existen diferentes tipos de algoritmos para llevar a cabo la tarea de clasificación. El más conocido es el algoritmo de máxima probabilidad (Caccetta, 1997). En el ámbito de la investigación, los algoritmos más usados son los de redes neuronales, lógica difusa e híbridos entre estas dos técnicas (Promcharoen y Rangsanteri, 1999).

A continuación se muestra una descripción y principios de los algoritmos implementados para la clasificación supervisada de imágenes: paralelepípedo, mínima distancia, máxima probabilidad, lógica difusa y redes neuronales.

- **Paralelepípedo** Este algoritmo es el que menos cantidad de información requiere, se fija un área de dominio para cada clase, según los valores máximo y mínimo en cada una de las  $n$  bandas. Esta área tendrá la forma geométrica de un paralelepípedo, que definirá tantas regiones  $n$ -dimensionales como clases se hayan definido. Un píxel pertenecerá a la clase si se encuentra dentro del

paralelepípedo que representa a esta clase. Si un píxel no está dentro de ningún paralelepípedo, el píxel queda sin clasificar (ver Figura 1).

En la literatura los valores que definen el paralelepípedo han sido diferentes, el máximo y el mínimo ( $\min < x < \max$ ) han sido descritos en (Mather, 1999), también se puede usar la media y la desviación estándar ( $\mu - \sigma < x < \mu + \sigma$ ) (Jensen, 1996).

Este es un algoritmo muy rápido y muy simple, pero trae consigo algunas desventajas, tales como la superposición de paralelepípedos y la no clasificación de píxeles. Las posibles soluciones para estos problemas puede ser la asignación a la primera clase que se encuentre, si el píxel pertenece a varios paralelepípedos, y asignar a la clase más cercana, si el píxel no se encuentra en ninguna de las regiones de los paralelepípedos.





FIGURA 1.  
Método de clasificación de Paralelepípedo

#### 4.3. Mínima distancia

Este algoritmo es computacionalmente simple y muy usado y requiere la media de los datos de entrenamiento de cada clase en cada banda. Se incluye un píxel en la clase en la que se minimice la distancia entre el píxel y el centro de la clase (ver Figura 2). Para calcular esta distancia comúnmente se usa la distancia euclidiana (ecuación 1).

$$d_{ai} = \sqrt{\sum_{k=0}^n (x_{ak} - \mu_{ki})^2} \quad (1)$$

donde:  $d_{ai}$  es la distancia del píxel  $a$  a la clase  $i$ ,  $x_{ak}$  es la componente  $k$  del píxel  $a$  y  $\mu_{ki}$  es la componente  $k$  de la media de los píxeles de la clase  $i$  (Jensen, 1996).




**FIGURA 2.**  
Método de clasificación de Mínima Distancia.

Se puede indicar un umbral para cada clase, indicando la máxima distancia permitida para asignar la pertenencia a esa clase. Así se pueden parametrizar distintas distancias máximas para distintas clases, en función del grado de concentración que presentan los píxeles. También es un método rápido. Pero presenta la desventaja de que no tiene en cuenta la variabilidad entre clases (la nube de puntos con forma elipsoidal).

#### 4.4. Máxima Probabilidad (Likelihood)

Este algoritmo asume previamente que los datos de las clases tienen distribuciones normales y está basado en calcular las probabilidades de que un píxel pertenezca a cada clase. Se asignará a la clase de mayor probabilidad. Es el más complejo y que más cálculos realiza pero también el que da los mejores resultados en el ámbito de los clasificadores estadísticos. Tiene en cuenta la variabilidad de las clases (ver Figura 3).



**FIGURA 3.**  
Método de Máxima Probabilidad

El clasificador de máxima probabilidad hace uso de variables estadísticas tales como el vector de medias para cada clase, y las matrices de covarianzas de cada clase, para las bandas que se van a usar en la clasificación (Tadjudin y Landgrebe, 1998), (Kuo y Landgrebe, 2001).

La probabilidad que un píxel  $x$  sea miembro de una clase  $i$  está dada por la ecuación 2 (Jensen, 1996):

$$P(x) = 2\pi^{-p/2} |S_i|^{-1/2} \exp [-0.5((x - \mu_i)' S_i^{-1} (x - \mu_i))] \quad (2)$$

Donde  $x$  es el vector del cual que quiere medir distancia,  $p$  es el número de características del vector  $x$  (número de bandas),  $S_i$  representa la matriz de varianza-covarianza para la clase  $i$ ,  $|S_i|$  denota el determinante de la matriz y  $\mu_i$  es el vector de medias de la clase  $i$ .

#### 4.5. Lógica Difusa

La Lógica Difusa ha surgido como una herramienta para el control de subsistemas y procesos industriales complejos, así como también para la electrónica de entretenimiento y hogar, sistemas de diagnóstico y otros sistemas expertos. La lógica difusa es un campo relativamente nuevo que fue iniciado en 1965 por Lofti A. Zadeh, profesor de Ciencias de la Computación en la Universidad de California en Berkeley en los Estados Unidos. La lógica difusa es básicamente una lógica multivaluada que permite valores intermedios para poder definir evaluaciones convencionales como sí/no, verdadero/falso, negro/blanco, etc. Las nociones como "tibio" o "poco frío" pueden formularse matemáticamente y ser procesados por computadoras. De esta forma se ha realizado un intento de aplicar una forma más humana de pensar en la programación de computadoras.

Uno de los principales aportes de la lógica difusa es el de los *conjuntos difusos*, los cuales son una colección de elementos de un universo los cuales pueden pertenecer total o parcialmente al conjunto.

Los algoritmos de clasificación tradicionales asignan a un píxel una única clase, por tanto, las mezclas no se pueden dar. El algoritmo difuso cambia esta concepción, dándole a cada píxel un grado de pertenencia a cada una de las clases, así, un píxel puede pertenecer en un 80% a una clase, un 15% a otra, un 5% a otra y al resto de las clases con un grado de pertenencia de 0%.

Un algoritmo de clasificación usando lógica difusa fue propuesto por Wang (1990). Este algoritmo no necesita como casi todos los demás algoritmos de clasificación, que los datos de entrenamiento sean homogéneos, y además, las mezclas que se presentan en la mayoría de las píxeles de las imágenes, no permiten que se cumpla esta condición. Este método usa los conjuntos difusos para la representación de la información a través de todo el proceso de clasificación.

Este algoritmo asigna a los píxeles un grado de pertenencia a cada una de las clases, la suma de los grados de pertenencia de un píxel a cada clase debe ser 1. Las funciones de pertenencia que son los grados de pertenencia de cada uno de los píxeles de la imagen a cada una de las clases se estiman con base, está basado en el algoritmo de clasificación de la máxima probabilidad descrito anteriormente. Pero no se usa la media y la covarianza normal, sino que se usa una media y la covarianza difusas descritas en la ecuaciones 3 y 4 respectivamente.

$$\mu_c^* = \frac{\sum_{i=1}^n f_c(x_i)x_i}{\sum_{i=1}^n f_c(x_i)} \quad (3)$$

$$\Sigma_c^* = \frac{\sum_{i=1}^n f_c(x_i)(x - \mu_c^*)(x - \mu_c^*)^T}{\sum_{i=1}^n f_c(x_i)} \quad (4)$$

donde  $\mu_c^*$  es el vector medias difusas para la clase  $c$  y  $\Sigma_c^*$  es la matriz de covarianzas difusas de la clase  $c$ .  $n$  es el número total de píxeles de entrenamiento.  $x_i$  es un píxel, es decir es un vector de valores ( $1 \leq i \leq n$ ). Por último  $f_c(x_i)$  es el grado de pertenencia del píxel  $x_i$  a la clase  $c$ .

Para encontrar la media difusa (ecuación 3) y la covarianza difusa (ecuación 4) de cada clase, es necesario conocer el grado de pertenencia del píxel  $x_i$  a la clase  $c$  (ecuación 5).

$$f_c(x) = \frac{P_c^*(x)}{\sum_{i=1}^m P_i^*(x)} \quad (5)$$

donde

$$P_c^*(x) = (2\pi)^{-N/2} |\Sigma_c^*|^{-1/2} \exp [-0.5(x - \mu_c^*)^T \Sigma_c^{*-1} (x - \mu_c^*)] \quad (6)$$

y  $N$  es el número de bandas que se van a usar en la clasificación,  $m$  es el número de clases, y  $1 \leq i \leq m$ .

Ahora que se conocen los valores de pertenencia de cada píxel, la media y covarianza difusa pueden ser calculadas de acuerdo con las ecuaciones 3 y 4. Sin embargo para calcular los valores de pertenencia (ecuaciones 5 y 6) se requieren los valores de la media y la covarianza. Chen (1999) propuso un algoritmo iterativo para la consecución de los valores de pertenencia de los datos de entrenamiento. El algoritmo consiste en calcular en primera medida los valores de la media y de la covarianza difusa con valores de pertenencia 1 para la clase a la que pertenece y 0 para las demás clases, como si no se estuviera trabajando con lógica difusa. Luego la media y covarianza difusa pueden ser calculada por medio de las ecuaciones 3 y 4. El algoritmo se repite hasta que los cambios ocurridos no sean significativos.

En este momento se tiene la media y la covarianza difusa, las cuales pueden ser utilizadas para calcular los grados de pertenencia de cada uno de los píxeles de la imagen a cada una de las clases. Como generalmente el resultado de un clasificador debe ser que un píxel pertenece a una clase determinada, se asume que un píxel pertenece a la clase que mayor grado de pertenencia posea.

#### 4.6. Redes Neuronales

Las redes neuronales artificiales (RNA), hoy en día son consideradas como modelos estadísticos de regresión no lineal no paramétricos y son una buena herramienta para aprender patrones, por lo cual pueden ser una buena herramienta para el proceso de clasificación.

Las RNA están compuestas por un conjunto de neuronas, las cuales están conectadas de tal forma que las entradas de una neurona es la salida de cierto número de neuronas, y esta a su vez retorna una señal, la cual será una entrada para otras neuronas (Eberhart y Dobbins, 1990); (Masters, 1993).

Las conexiones entre neuronas tienen asociado un valor de ponderación para la señal que reciben. Este factor de ponderación o peso  $w_i$  multiplica el valor de la señal de entrada de la neurona aumentándola o reduciéndola, de este modo la conexión puede ser inhibitoria o excitatoria. Ahora bien, la señal de entrada neta o ponderada para una neurona es la sumatoria del producto entre el peso

asociado a cada conexión de entrada y la señal que se desplaza por esa conexión. Matemáticamente la ecuación 7 lo explica:

$$Neta = \sum w_i x_i \quad (7)$$

Estas neuronas se encuentran agrupadas en capas, las cuales pueden recibir entradas (capas de entrada), entregar salidas (capas de salida), o ser indiferentes a las entradas y las salidas, con conexiones únicamente a otras capas (capas ocultas).

Las RNA son caracterizadas por tres elementos: la arquitectura, que corresponde a la forma en que las neuronas están interconectadas, la función de transferencia entre las capas y el algoritmo por medio del cual se realiza el proceso de aprendizaje.

### **Arquitectura**

En cuanto a la arquitectura las RNA, son una simulación abstracta de los sistemas nerviosos biológicos, formados por un conjunto de neuronas o nodos conectados unas con otras, de diferentes formas, éstas están descritas en (Eberhart y Dobbins, 1990), (Masters, 1993), (Freeman y Skapura, 1993), (Simmons, 1996), (Yao, 1999), (Welstead, 2002).

La arquitectura más usada en la actualidad en el problema de la clasificación es la de propagación hacia adelante (feedforward) con una capa interna (Ultsch et al., 1995). Esta arquitectura está conformada por una capa de entrada, donde los estímulos son recibidos y enviados a la capa oculta sin ningún procesamiento; una capa oculta, donde cada neurona recibe como entrada la suma neta de las señales provenientes de todas las neuronas de la capa de entrada ponderadas por los pesos asociados a las conexiones, además de una entrada constante proveniente de una neurona adaptativa, la salida neta de esta capa se produce al aplicar a la entrada neta una función de activación; y una capa de salida, cuyas neuronas tienen una entrada neta, igual a la suma de las salidas de las neuronas de la capa oculta ponderadas por los pesos asociados a las conexiones entre neuronas, más la entrada proveniente de la neurona adaptativa. A esta entrada neta, se le aplica una función de activación y los resultados de cada una de estas neuronas son las salidas de la RNA.

### **Función de transferencia y activación**

La función de transferencia le da a la red una característica importante, que es la acotación. Dependiendo de la función que se escoja, la red será acotada o no. Las funciones de activación más usadas son: la función de Transferencia Lineal, Sigmoidea o Logística, Sigmoidea Bipolar, la Arcotangente, y la función Gaussiana, entre otras (Masters, 1993).

### **Algoritmos de entrenamiento**

Para que una RNA Feed-Forward proporcione los resultados esperados, hay que entrenarla para que la red tenga el comportamiento deseado, este proceso se realiza por medio de unos algoritmos los cuales van actualizando los pesos de tal forma que el error entre los datos reales y las salidas de la red disminuya, estos son llamados algoritmos de entrenamiento.

Hay gran variedad de métodos tales como el de propagación hacia atrás (Backpropagation), estrategias de evolución y una gran cantidad de métodos híbridos.

#### **\*BackPropagation**

El algoritmo de entrenamiento basado en la propagación de errores hacia atrás conocido como Backpropagation, planteado a fines de los años 80 por Rumelhart, Werbos y otros, significó un avance en la búsqueda de técnicas de entrenamiento haciendo uso de métodos de optimización. Este algoritmo se basa en la modificación de los pesos de la RNA, cambiándolos un tamaño de paso  $\mu$  en la dirección contraria al gradiente de máximo ascenso del error. De esta forma para la iteración  $m+1$ , el nuevo vector de pesos se calcula de la siguiente forma:

$$W^{(m+1)} = W^{(m)} - I\mu(1 - \mu)\nabla Error \quad (8)$$

Donde  $W^{(m)}$  son los pesos de la red en la iteración  $m$ ,  $\mu$  es el término de momentum o paso,  $I$  es la tasa de aprendizaje y  $\nabla Error$  es el gradiente del error.

Para poder aplicar este algoritmo se generan unos pesos aleatorios y se realiza un proceso iterativo que ajuste del vector de pesos. Este proceso se realiza hasta que se cumpla un criterio de parada, tal como número máximo de iteraciones, convergencia de los pesos, intervención del usuario, entre otros.

La calidad de los resultados obtenidos depende del vector de pesos iniciales, del término de momentum y de la tasa

de aprendizaje. Si  $\mu$  es pequeño, el algoritmo avanza levemente hacia puntos de mínima, y si es grande puede saltarse zonas de buena calidad. La tasa de aprendizaje, mientras más alta, más inestable son los pesos.

#### \*Estrategias de Evolución

El algoritmo de estrategias de evolución simula el proceso de evolución de Darwin, en el cual el más apto de la especie sobrevive. La técnica consiste en aplicar operadores genéticos tales como selección, cruce y mutación a los miembros de la población (Back et al., 1991); (Beyer, 1995); (Beyer, 1996).

La técnica se utiliza en problemas de optimización, y eso precisamente es lo que se trata de hacer con los pesos de la RNA. Se construye un vector  $X$  que por cada variable  $w_i$  del problema, contiene dos variables, la primera es la variable original y la segunda es una variable de estrategia, la cual es recomendable iniciarla con un valor de 3 (Back et al., 1991). Además contienen una variable llamada aptitud, que se obtiene al evaluar la función que se va a optimizar con los  $w_i$ , teniendo en cuenta, que si es un problema de minimización, la aptitud puede tomarse como el valor inverso del resultado de la función. En nuestro caso esos  $w_i$  son los pesos de las conexiones de la RNA, y como lo que se quiere es minimizar el error, la aptitud de una especie será el inverso del error.

$$X = (w_1, w_2, \dots, w_n, \sigma_1, \sigma_2, \dots, \sigma_n)$$

El proceso de selección de padres para el cruce se realiza asignando una probabilidad por cada especie, dependiendo de su aptitud, es decir, mientras más aptitud tenga una especie, más será la probabilidad que tendrá éste de ser escogido para realizar un cruce. Una vez asignada esta probabilidad se realiza la selección aleatoria de los padres.

El proceso de reproducción se realiza escogiendo dos padres por el método de selección anteriormente descrito, para realizar una combinación de ellos. Existen diferentes formas de realizar este cruce. La mejor función para realizar el cruce entre las especies es la llamada pannímica intermedia (ecuación 9).

$$X_i = X_i^S + U(0, 1) * (X_i^T - X_i^S) \quad (9)$$

Donde  $X_i$  es el  $i$ -ésimo elemento del vector  $X$  de la nueva especie,  $S$  y  $T$ , representan los padres de la nueva especie, y  $U(0, 1)$  es un número aleatorio uniforme entre 0 y 1.  $i$

vadesde 1 hasta  $n$ , el resto del vector se inicializa con el valor inicial de  $\sigma_i$ , que es 3. Ahora se procede a mutar a los nuevos individuos, esto se hace se la siguiente forma:

$$\sigma'_i = \sigma_i * \exp(\tau * N_i(0, 1)) \quad (10)$$

$$w'_i = w_i + \sigma'_i * N_i(0, 1) \quad (11)$$

Donde  $N(0, 1)$  es una aleatorio normal con media 0 y varianza 1,  $\tau$  es una constante,  $w'_i$  es el nuevo valor de  $w_i$ , y  $\sigma'_i$  es el nuevo valor de  $\sigma_i$ .

Cuando todos los individuos de la población se han mutado (ecuaciones 10 y 11), se realiza un proceso de selección de los padres de la siguiente generación. Esto se realiza de acuerdo con la aptitud de los padres y los hijos, en donde se escogen los mejores de estos dos grupos.

Este proceso de evolución se realiza hasta que la población converga a un solo individuo, hasta que el error sea muy pequeño o hasta que el usuario decida terminar el proceso.

#### \*Algoritmos Híbridos

Un algoritmo que mezcla el algoritmo de backpropagation y la técnica de mínimos cuadrados minimiza el error mucho más que los algoritmos antes ilustrados. Consiste en propagar el error hacia atrás en los pesos que van desde la capa de entrada y la oculta, y los pesos que van desde la capa oculta hasta la capa de salida se calculan por medio del método de mínimos cuadrados. Este mismo algoritmo híbrido fue implementado para el de estrategias de evolución.

Estos dos algoritmos reducen en una cuarta parte el error que se obtenía con los métodos explicados anteriormente.

## 5. RESULTADOS

En este capítulo se mostrarán los resultados de varias pruebas que se realizaron con la nueva herramienta de clasificación. En los primeros resultados mostrados, se puede observar el tiempo de clasificación de la herramienta desarrollada, ER-Mapper y Envi, con una imagen grande (2631 columnas por 2925 filas). Los segundos resultados se realizaron a una imagen pequeña de 500 filas y 500 columnas, de tipo LandSat, para observar la calidad de los diferentes algoritmos de clasificación que se implementaron en la nueva herramienta de software.

## 5.1. Caso 1

En la tabla se muestra el tiempo que tomó cada una de las herramientas en el proceso de clasificación, para la cual se tomaron cuatro clases, la primera son los cuerpos de agua o ríos, la segunda es ciudad, la tercera es la zona boscosa y la tercera, zona de cultivos.

Este proceso se realizó a una imagen de tipo LandSat la

**TABLA 1.**

Tiempo de clasificación en segundos  
para una imagen de 2631 columnas  
por 2925 filas

	Envi	ER-Mapper	HidroSIG Java
Paralelepípedo	35s	25s	10s
Mínima distancia	42s	32s	11s
Máxima Probabilidad	75s	92s	48s
Lógica Difusa	*	*	49s
Redes Neuronales	*	*	108s**

\*Algoritmos no incluidos en estas herramientas de software

\*\* Este tiempo no incluye el proceso de entrenamiento de la RNA

Analizando los resultados obtenidos, se tiene que el módulo de HidroSIG Java en la parte de clasificación es muy rápido en comparación con otras herramientas. Comparando los tiempos con el Envi y el ER-Mapper en los algoritmos del paralelepípedo, mínima distancia y máxima probabilidad, se tiene que la nueva herramienta de software es 3.5 y 2.5 veces más rápida respectivamente, con el algoritmo del paralelepípedo; 3.81 y 2.90 veces más rápida con mínima distancia; y 1.56 y 1.91 veces más rápida respectivamente, con el algoritmo de máxima probabilidad.

Los resultados son muy similares en cada uno de los métodos, comparándolos visualmente. En el algoritmo de Máxima Probabilidad se obtuvieron mejores resultados que las demás herramientas de software, ya que delimitó


cual tiene 2631 columnas y 2925 filas, para un total de 7695675 píxeles. Esta prueba se realizó a los programas Envi, ER-Mapper y a la herramienta desarrollada. La herramienta Envi, es muy fácil de usar, es muy intuitiva, y se tomaron algunas de sus fortalezas en cuanto a la facilidad de uso, en la construcción del nuevo sistema. ER-Mapper en cambio es difícil de usar, no es muy intuitivo, hay que apegarse a un manual para poder realizar una clasificación.

mejor los cuerpos de agua (río). Este mismo resultado se vio claramente con los algoritmos de Lógica Difusa y Redes Neuronales.

## 5.2. Caso 2


A continuación se presenta la clasificación de una imagen de 500 filas por 500 columnas, correspondiente a la desembocadura del río Magdalena en el océano Atlántico, en donde se definieron regiones de entrenamiento tales como ciudad, río, ciénaga, mar, manglar muerto, playón, zona boscosa y cultivo.

Los resultados de los diferentes métodos son mostrados en las Figuras 4,5,6,7y8.



**FIGURA 4.**  
Resultado de la clasificación con el  
algoritmo del paralelepípedo






**FIGURA 5.**

Resultado de la clasificación con el algoritmo del Mínima distancia

En las tablas 2, 3, 4, 5 y 6 se puede observar los resultados de la prueba de validación los cuales fueron realizados con información introducida por el usuario.

Analizando los resultados obtenidos por cada uno de los métodos por inspección visual y teniendo en cuenta los resultados de validación, se tiene que el método del paralelepípedo es muy rápido, pero no proporciona buenos resultados, muchos píxeles quedan sin clasificar. El algoritmo de mínima distancia es muy rápido también

genera resultados aceptables. El algoritmo de máxima probabilidad es mucho mejor en resultados. El algoritmo que mejores resultados está proporcionando es el de lógica difusa, y dependiendo de la homogeneidad de las clases de entrenamiento, se demora un poco más o un poco menos que el algoritmo de máxima probabilidad. El algoritmo basado en redes neuronales artificiales trabaja muy bien con pocas clases, a medida que aumentan el número de clases la exactitud del método disminuye.




**FIGURA 6.**

Resultado de la clasificación con el algoritmo del Máxima Probabilidad



**FIGURA 7.**  
Resultado de la clasificación con el  
algoritmo del Lógica Difusa



**FIGURA 8.**  
Resultado de la clasificación con el  
algoritmo de Redes Neuronales  
Artificiales

	Datos Reales								
	Ciudad	Río	Ciénaga	Mar	Manglar	Playón	Bosque	Cultivo	Total
Ciudad	13037	5	7	0	0	2682	4	460	16195
Río	0	1712	2	0	0	0	0	0	1714
Ciénaga	1	285	5030	1	0	9	0	0	5326
Mar	0	0	0	9763	0	0	0	0	9763
Manglar	0	0	0	0	3075	0	54	0	3129
Playón	1445	411	197	1	0	4729	0	10	6793
Bosque	1	0	0	0	21	0	998	0	1020
Cultivo	202	0	0	0	0	0	5	27	234
No clase	3025	1327	2765	6571	1583	272	1438	247	17228
Total	17711	3740	8001	16336	4679	7692	2499	744	61402
Exactitud Total 62.49%									

Suma de la diagonal = 38371 Suma de datos = 61402  $38371/61402 = 0.6249$ .

**TABLA 2.**  
Validación del método del paralelepípedo

	Datos Reales								
	Ciudad	Río	Ciénaga	Mar	Manglar	Playón	Bosque	Cultivo	Total
Ciudad	15163	9	0	0	0	2248	0	2	17422
Río	16	3718	39	5	1	0	0	0	3779
Ciénaga	0	11	7833	10	249	0	0	2	8105
Mar	0	0	98	16321	489	0	0	0	16908
Manglar	2	0	19	0	3628	0	5	0	3654
Playón	1854	0	0	0	0	5339	0	0	7193
Bosque	267	2	12	0	312	16	2491	13	3113
Cultivo	409	0	0	0	0	89	3	727	1228
Total	17711	3740	8001	16336	4679	7692	4299	744	61402
Exactitud Total 89.93%									

**TABLA 3.**  
Validación del método de Mínima Distancia

	Datos Reales								
	Ciudad	Río	Ciénaga	Mar	Manglar	Playón	Bosque	Cultivo	Total
Ciudad	16735	50	164	18	11	2883	4	21	19886
Río	0	3622	1	0	0	0	0	0	3623
Ciénaga	0	68	7796	5	5	0	0	0	7874
Mar	0	0	0	16306	2	0	0	0	6308
Manglar	0	0	40	7	4644	0	346	0	5037
Playón	818	0	0	0	0	4805	0	0	5623
Bosque	1	0	0	0	10	0	1829	0	1840
Cultivo	157	0	0	0	7	4	320	723	1211
Total	17711	3740	8001	16336	4679	7692	2499	744	61402
Exactitud Total 91.95%									

**TABLA 4.**  
Validación del método de Máxima Probabilidad

**TABLA 5.**  
Validación del método de  
Lógica Difusa

	Datos Reales								
	Ciudad	Río	Ciénaga	Mar	Manglar	Playón	Bosque	Cultivo	Total
Ciudad	17347	43	264	28	7	3323	11	23	21046
Río	0	3652	2	0	0	0	0	0	3654
Ciénaga	0	45	7700	0	0	0	0	0	7745
Mar	0	0	0	16308	0	0	0	0	16308
Manglar	0	0	35	0	4656	0	361	0	5052
Playón	324	0	0	0	0	4369	0	0	4693
Bosque	0	0	0	0	10	0	2015	0	2025
Cultivo	40	0	0	0	6	0	112	721	879
Total	17711	3740	8001	16336	4679	7692	2499	744	61402
Exactitud Total 92.45%									

**TABLA 6.**  
Validación del método de  
Redes Neuronales

	Datos Reales								
	Ciudad	Río	Ciénaga	Mar	Manglar	Playón	Bosque	Cultivo	Total
Ciudad	15164	8	1535	0	0	2248	2	0	18957
Río	14	3718	41	5	1	0	0	0	3779
Ciénaga	3	8	6295	13	249	0	0	2	6570
Mar	0	0	103	15105	489	0	0	0	15697
Manglar	2	0	14	5	3628	0	521	0	4170
Playón	1851	0	3	0	0	5339	0	0	7193
Bosque	269	5	10	1208	312	20	1969	15	3808
Cultivo	408	1	0	0	0	85	7	727	1228
Total	17711	3740	8001	16336	4679	7692	2499	744	61402
Exactitud Total 84.59%									

## 6. CONCLUSIONES

Se implementaron diferentes algoritmos para la clasificación supervisada de imágenes de sensores remotos con diferentes cualidades, el paralelepípedo y el mínima distancia, por su rapidez en el proceso de clasificación, el algoritmo de máxima probabilidad ya que es el mejor clasificador de tipo estadístico y es el más conocido, un algoritmo basado en redes neuronales, el cual a pesar de que requiere de un proceso de entrenamiento, da resultados muy buenos, y por último se implementó un algoritmo basado en lógica difusa que también brinda resultados satisfactorios, ya que delimita mejor los objetos que se encuentran en la imagen.

Las herramientas de clasificación de imágenes de sensores remotos, Envi y ER-Mapper, se probaron con los algoritmos tradicionales (paralelepípedo, mínima distancia y máxima probabilidad) y mostraron en promedio ser: 2.96 y 2.44 veces más lentas respectivamente, comparadas con la herramienta desarrollada en este trabajo; los resultados obtenidos por las tres herramientas con dichos algoritmos de clasificación son similares; Envi es muy fácil de usar, y

es muy intuitivo y por último el ER-Mapper es muy complicado de manejar, para definir las regiones de entrenamiento hay que realizar muchos pasos.

El módulo de sensores remotos desarrollado para HidroSIG Java, ofrece la posibilidad de hacer clasificación supervisada en imágenes de satélite, mediante los algoritmos del paralelepípedo, mínima distancia, máxima probabilidad, lógica difusa y redes neuronales. La herramienta puede trabajar con diferentes formatos de imágenes tales como tif, gif, bmp y jpg y además puede trabajar con los formatos estándar de las imágenes LandSat y Spot.

## 7. BIBLIOGRAFIA

- Back T., Hoffmeister F., y Schwefel H. 1991. A survey of evolution strategies. En 4th International Conference on Genetic Algorithms, San Diego, CA.
- Beyer H., 1995. Toward a theory of evolution strategies: On the benefit of sex—theory. *Evolutionary Computation*, 3(1):81—111.
- Beyer H., 1996. Toward a Theory of Evolution Strategies:

- Self-Adaptation. *Evolutionary Computation*, 3(3):311—347.
- Caccetta P., 1997. Remote Sensing, Geographical Information System (GIS) and Bayesian Knowledge-Based Methods For Monitoring Land Condition. PhD tesis, Curtin University. <http://www.cmis.csiro.au/Peter.Caccetta/papers/thesis.ps.gz>.
- Correa P., 2002. Sistema de Información Geográfica para la gestión del recurso hídrico a nivel de cuenca. Universidad Nacional de Colombia, Medellín.
- Cortijo F., 1995. Un estudio comparativo de métodos de clasificación de imágenes multibanda. PhD tesis, Universidad de Granada. [http://decsai.ugr.es/~cb/entrada\\_tesis.html](http://decsai.ugr.es/~cb/entrada_tesis.html).
- Dai X., 2002. Improve classification of remote sensing data for land use/cover classification. <http://www.cse.psu.edu/~cg585/termPaper/Dai.pdf>.
- Eberhart R. y Dobbins R., 1990. Neural Network PC Tools. A Practical Guide. Academic Press, Inc., New York.
- Freeman J. y Skapura D., 1993. Redes Neuronales. Algoritmos, Aplicaciones y Técnicas de Programación. Addison-Wesley Iberoamerica, S.A., Wilmington, Delaware.
- Ho. beck J. y Landgrebe D., 1995. Classification of High Dimensional Multispectral Data. PhD tesis, School of Electrical and Computer Engineering.
- Hsieh P. y LandgrebeD., 1998. Classification of High Dimensional Data. PhDtesis, School of Electrical and Computer Engineering.
- Jensen J., 1996. Introductory Digital Image Processing. Prentice Hall, New Jersey.
- Jimenez L. y Landgrebe A., 1998. Supervised classification in high dimensional space: Geometrical, statistical and asymptotical properties of multivariate data. *IEEE Transactions on Systems, Man, and Cybernetics*, 28(1).
- Kuo B. y Landgrebe D., 2001. Improved Statistics Estimation and Feature Extraction for Hyperspectral Data Classification. PhD tesis, School of Electrical and Computer Engineering.
- Lee C. y Landgrebe D., 1998. Feature Extraction and Classification Algorithms for High Dimensional Data. PhD tesis, School of Electrical and Computer Engineering.
- Mantilla R., 1999. Análisis multiescala de propiedades morfométricas y de caudales máximos de cuencas hidrográficas de Colombia. Universidad Nacional de Colombia, Medellín.
- Masters T., 1993. Practical Neuronal Networks Recipes in C++. Academic Press, Inc., SanDiego C.A.
- Mather P. 1999. Computer Processing of Remotely-Sensed Images. John Wiley Sons, Chichester.
- Promcharoen S. y Rangsaneri Y., 1999. Supervised classification of multispectral satellite images using fuzzy logic and neural network. En Asian Conference on Remote Sensing. GIS Development. <http://www.gisdevelopment.net/aars/acrs/1999/ts5/ts5237.shtml>.
- Ramirez J., 2002. Extracción automática de redes de drenaje a partir de modelos digitales de terreno. Universidad Nacional de Colombia, Medellín.
- Sabins F., 1986. Remote Sensing principes and interpretation. W.H. Freeman and Company, New York.
- Shine J. y Wakefield G., 1999. A comparison of supervised imagery classification using analyst-chosen and geostatistically-chosen training sets. En 4th International Conference on GeoComputation. <http://www.geovista.psu.edu/sites/geocomp99/Gc99/044/>.
- Simpons P., 1996. Neuronal Networks, Theory, Technology and Applications. IEEE Technology Update Series, New York.
- Tadjudin S. y Landgrebe D., 1998. Classification of High Dimensional Data with Limited Training Samples. PhD tesis, School of Electrical and Computer Engineering.
- Ultsch A., Korus D. y Wehrmann A., 1995. Neural networks and their rules classification in marine geology. En Raum und Zeit in Umweltinformationssystemen, 9 th Intl Symposium on Computer Science for Environmental Protection. <http://citeseer.nj.nec.com/ultsch95neural.html>.
- Vélez J., Poveda G. y Mesa O., 2000. Balances hidrológicos de Colombia. Universidad Nacional de Colombia, Medellín.
- Welstead S., 2002. Neuronal Network and Fuzzy Logic Applications in C/C++. John Wiley and Sons, Inc., United States of America.

- Yao X., 1999. Evolving artificial neural networks.  
PIEEE: Proceedings of the IEEE, 87. [http://  
citeseer.nj.nec.com/yao99evolving.html](http://citeseer.nj.nec.com/yao99evolving.html).
- Zhang Q. y Landgrebe D., 2001. Design of an Adaptive  
Classification Procedure for the Analysis of  
Highdimensional Data with Limited Training Samples.  
PhD tesis, School of Electrical and Computer  
Engineering.