

# Evaluación de las Redes Neuronales Artificiales Perceptron Multicapa y Fuzzy-Artmap en la Clasificación de Imágenes Satelitales

## *Evaluation of Satellite Image Classification using Multilayer Perceptron and Fuzzy-ArtMap models*

Guillermo Antonio  
Toro Bayona

Ingeniero Catastral y Geodesta.  
Especialista en SIG.  
Especialista en Construcción  
de Software.  
memo.toro@gmail.com

Iván Alberto  
Lizarazo Salcedo

Ingeniero Civil.  
Especialista en SIG.  
MSc en Geographic  
Information Science.  
PhD en Geografía.  
ilizarazo@udistrital.edu.co

## Resumen

Este documento reporta una comparación cuantitativa y cualitativa del desempeño de las redes neuronales artificiales Perceptron Multicapa y Fuzzy-Artmap para clasificación de coberturas del suelo a partir de imágenes satelitales multi-espectrales. Se describen parámetros y condiciones que ayudan a producir imágenes clasificadas con buena exactitud temática. Adicionalmente, se hace una comparación entre los dos modelos de redes neuronales que describen sus ventajas y desventajas.

**Palabras clave:** Clasificación de imágenes satelitales, Fuzzy-Artmap, Perceptron Multicapa.

## Abstract

In this paper a quantitative and qualitative comparison between performance of Multilayer Perceptron and Fuzzy-Artmap neural networks for classification of land cover from multispectral satellite images is reported. It describes parameters and conditions that help to produce accurate classified images. Additionally, it makes a comparison between the two types of neural networks models describing both their advantages and disadvantages.

**Key words:** Satellite image classification, Fuzzy-Artmap, Multilayer Perceptron.

## 1. Introducción

El proceso para la extracción de información temática de cobertura del suelo derivado de imágenes satelitales es conocido como clasificación. Este proceso busca la asignación de píxeles de la imagen a un número determinado de clases (coberturas del suelo) basándose en su nivel digital [14], es decir, el valor numérico que representa la intensidad radiométrica recibida por un sensor óptico-electrónico [9].

Los algoritmos convencionales (por ejemplo ISODATA y Máxima Verosimilitud) llevan a cabo este proceso usando supuestos estadísticos [9] que en ocasiones son de difícil cumplimiento (distribución normal de datos), debido a las características de la imagen [29]. Por este motivo, se han buscado metodologías alternativas que superen estos inconvenientes y obtengan mejores resultados en la clasificación de cobertura del suelo [9] [15].



Fecha recibido: Marzo 08 de 2012  
Fecha modificado: Abril 27 de 2012  
Fecha aceptado: Mayo 15 de 2012

Las redes neuronales artificiales se consideran métodos alternativos para el procesos de clasificación al superar inconvenientes de los algoritmos convencionales de clasificación [2] [21] [29] y han demostrado buenos resultados en clasificación de imágenes [17].

A continuación, se mostrarán los métodos y resultados de aplicar las redes neuronales Perceptron Multicapa y Fuzzy-Artmap en un experimento de clasificación de la cobertura del suelo. Los motivadores de este experimento académico fueron: realizar pruebas de clasificación de imágenes con dichos algoritmos y contrastar sus resultados con indicadores de calidad temática, identificar ventajas y desventajas y finalmente observar su aplicabilidad para clasificación de imágenes satelitales en coberturas del suelo.

## 2. Generalidades del estudio

### 2.1. Datos

- Imagen de satélite multi-espectral Landsat TM del 30 de agosto de 1997 correspondiente a la Sabana de Bogotá (Path 008–Row 057) a 28.5 metros de resolución por píxel.
- Imagen SRTM correspondiente al modelo digital de elevación de la Sabana de Bogotá (Path 008–Row 057) a 90 metros de resolución.
- Mapas de coberturas y usos de suelo de la zona de estudio [10].

### 2.2. Software y Hardware

- Software ENVI Versión 4.1, Software ClasserScript Versión 1.1 [18], Software Erdas Imagine 8.6, Software ArcGIS Versión 9.0, Software TextPad Versión 4.7.3.
- Computador personal con procesador Athlon XP de 2.6 GHz, 512 Mb de Memoria RAM y tarjeta de video de 64 Mb.

### 2.3. Zona de Estudio

La zona de estudio es la región geográfica conocida como Sabana de Bogotá, la cual está ubicada en el centro geométrico de Colombia sobre la cordillera oriental en el extremo sur del altiplano cundiboyacense. La Figura 1 ofrece una localización a nivel Departamental.

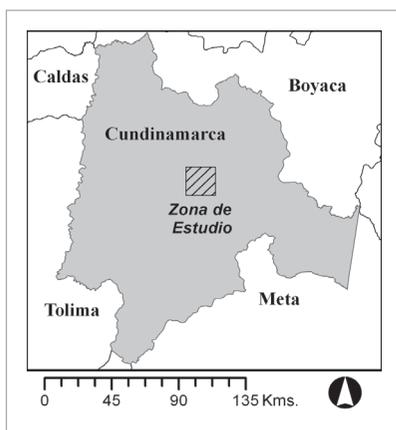


Figura 1. Localización a Nivel Departamental de la Zona de Estudio. Sabana de Bogotá.

Se utilizó una imagen de satélite Landsat 5 que cubre un área de alrededor de 398 km<sup>2</sup> y abarca la totalidad de los municipios de Chía, Cajicá y Sopo, con algunas zonas de los Municipios de Tocancipa, Tabio y Bogotá D.C. La imagen consta de 7 Bandas Espectrales con una dimensión de 700 x 700 píxeles como lo muestra la Figura 2.

Basado en estudios de la CAR (Corporación Autónoma Regional) [10] y en trabajo de campo se seleccionó el sistema de clasificación del CIAF (Centro de Investigación y Desarrollo en Información Geográfica) [11]. La Tabla I muestra las coberturas identificadas con sus respectivos códigos y la gama de colores utilizados para la producción de los mapas temáticos.

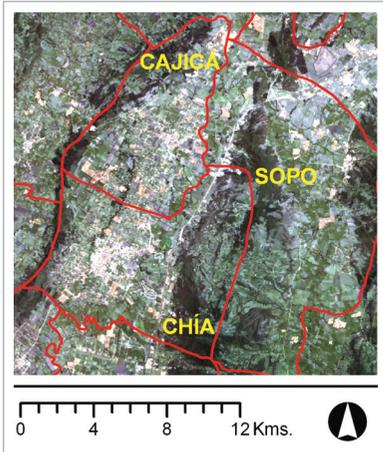


Figura 2. Zona de estudio en composición de color verdadero RGB-321 de la imagen Landsat5 TM.

Gran Grupo	Grupo	Subgrupo	Color
C. Rasgos Culturales	C.1. Urbanos	C.1.1. Residencial	Magenta 1
A. Tierras Agrícolas	A.1. Cultivos y Praderas	A.1.2. Pastos	Verde 1
		A.1.3. Cultivos Semiperennes	Verde 3
	A.2. Explotación Agropecuaria Confinada	A.2.1 Viveros e Invernaderos	Azul 1
B. Tierras de Bosque	B.2. Bosque Húmedo	B.2.2. Bosque Plantando	Naranja 4
P. Tierras Pastizales	P.1 Zonas Húmedas	P.1.2. Arbustos	Naranja 1

### 3. Métodos utilizados

En esta sección se revisan los elementos básicos para comprender el funcionamiento de las redes neuronales utilizadas en el experimento. Para profundizar en el tema de configuración de los parámetros de estas redes se recomienda consultar las referencias que se dan en el texto.

Las redes neuronales son algoritmos de procesamiento que permite reconocer patrones en los datos, a partir de modelos que simulan los sistemas biológicos de aprendizaje [1] [8]. De manera general, una red neuronal está compuesta por unidades de procesamiento llamadas neuronas, distribuidas en diferentes capas, conectadas entre sí por una serie de pesos que establecen las relaciones entre ellas [2] [21].

Los datos a clasificar son ingresados en la capa de entrada, y se transmiten a las siguientes capas a través de las conexiones y sus pesos, mediante una serie de reglas y funciones matemáticas [20] [25]. El entrenamiento consiste en encontrar la mejor configuración de pesos que permita asociar los datos de la capa de entrada y con los de la capa de salida obteniendo el mínimo error posible de reconocimiento.

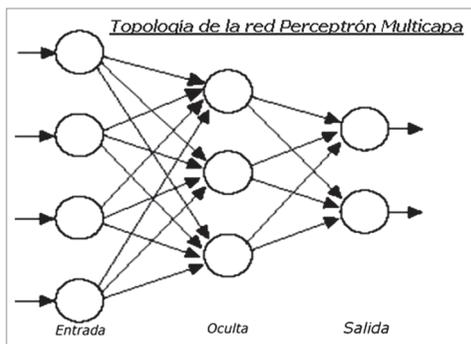


Figura 3. Arquitectura de una red neuronal Perceptrón Multicapa [30].

#### 3.1. Perceptron Multicapa

El modelo Perceptron Multicapa se compone de capa de entrada, capas ocultas y capa de salida (Figura 3) las cuales están compuestas por una serie de neuronas que se encargan de recibir, procesar y enviar datos hacia otras neuronas procesando la información mediante distintas funciones matemáticas [23] [29].

Las neuronas de la capa de entrada reciben los niveles digitales que presenta un píxel de imagen en sus diferentes bandas multi-espectrales, por lo tanto, existirá una

relación directa entre el número de neuronas de la capa de entrada y el número de bandas de la imagen a clasificar [22]. Por su parte las capas ocultas son las encargadas de representar el nivel de complejidad que puede existir en la relación entre la capa de entrada y la capa de salida [1]. El número usual de capas ocultas está entre uno y dos, de forma que sea posible resolver la compleja separabilidad de las coberturas [3] [29]. Por último, la capa de salida se encarga de producir el resultado de clasificación de la red neuronal; por esta razón el número de neuronas que componen esta capa está en directa relación con el número de clases de cobertura que se deseen identificar.

Las conexiones que conectan las neuronas se modelan mediante pesos numéricos que establecen el grado de correlación de cada muestra que se va a clasificar con sus respectivas clases; estos pesos son ajustados durante la etapa de entrenamiento de la red. Cada neurona envía a las neuronas de la siguiente capa un valor conocido como valor de activación [29].

En la etapa de entrenamiento se busca establecer la mejor relación entre las muestras y sus respectivas clases a través de un método de aprendizaje [23]. En este estudio el método de aprendizaje utilizado fue el algoritmo de retro-propagación, el cual sigue las siguientes etapas: inicia cuando una muestra de un píxel es capturada por la capa de entrada, luego el valor de activación de cada una de estas neuronas es calculado progresivamente a través de una función de activación desde la capa de entrada hasta la capa de salida [22]; seguidamente en la etapa comprobación. El valor de activación de las neuronas de salida se comparado con el dato de salida esperado. Si la salida calculada por la red neuronal difiere de la salida esperada, esta diferencia es conocida como el error de la red neuronal [20] [29]. Este error es corregido de manera distribuida a través de la actualización de los pesos de la red neuronal en una etapa de regreso (por lo cual recibe el nombre de retro-propagación) de la capa de salida hacia la capa de entrada. Todo el proceso que se repite hasta que la red ajuste los pesos con un parámetro de error permisible [8].

### 3.2. Fuzzy-Artmap

En las redes neuronales basadas en la retro-propagación de errores, ciertos patrones aprendidos se pueden ir perdiendo a medida que transcurre el entrenamiento, debido a los pequeños ajustes que se van realizando en los pesos de las conexiones con cada iteración [4] [29]. En contraste, la Teoría de la Resonancia Adaptativa [5] [6], utiliza modelos de redes neuronales con reglas de aprendizaje competitivo de manera que el ajuste ocurre únicamente entre las conexiones de las neuronas de entrada y la neurona ganadora en la capa de salida. Los modelos ART [7] contienen dos capas de procesamiento de datos, la capa de entrada F1 y la capa de clasificación F2, que están conectadas por dos grupos de pesos, unos que conectan F2 con F1, y otros que conectan F1 con F2. Estos últimos corresponden a la memoria de largo plazo.

Adicionalmente las neuronas en F2 se conectan entre sí mediante una pequeña conexión llamada parámetro de competencia. El aprendizaje competitivo se basa en que las neuronas de la capa de salida compiten entre sí con el objetivo de ganar la oportunidad de interactuar con las neuronas de la capa de entrada. El resultado de este tipo de aprendizaje es que únicamente las conexiones entre las neuronas de entrada y la neurona ganadora son ajustadas [4] [5].

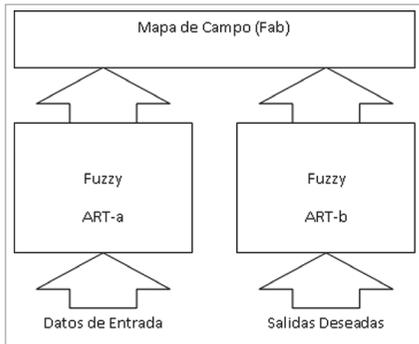


Figura 4. Estructura de capas de una red neuronal Fuzzy-Artmap [29].

Por su parte la variante conocida como modelo neuronal Fuzzy-Artmap posee dos módulos de operación basados en el modelo neuronal ART, llamados ART-a y ART-b, estos dos módulos son relacionados y a través de un modulo intermedio llamado mapa de campo el cual se denota como Fab. El módulo ART-a es usado para el reconocimiento de los datos de entrada, y el módulo ART-b es el encargado de reconocer los datos de salidas o clases deseadas para cada entrada presentada en el módulo ART-a [6] [29]. La arquitectura de la red Fuzzy-ARTMAP es mostrada en la Figura 4.

### 3.3. Indicadores de Calidad

Para evaluar la calidad de las imágenes clasificadas se seleccionaron los indicadores derivados de la matriz de confusión [9] [15]. Los indicadores son porcentaje de clasificación correcta, exactitud de productor, exactitud de usuario e índice kappa. El porcentaje de clasificación correcta es calculado por la división del total de píxeles correctamente clasificados (equivalente a la suma de la diagonal principal de la matriz de confusión) por el número total de píxeles [9].

Por su parte la exactitud del productor indica la probabilidad de un píxel de referencia de ser clasificado correctamente, siendo esto una medida de omisión [13]. La exactitud de usuario se refiere a un indicador del error por exceso que mide la probabilidad de que un píxel clasificado pertenezca realmente a esa categoría en el terreno [13]. Finalmente el índice kappa expresa la reducción proporcional en el error generado por un proceso de clasificación comparado con el error de una clasificación completamente al azar [14].

### 3.4. Muestras de Entrenamiento

Las regiones que se identificaron en la zona fueron establecidas gracias al reconocimiento de campo y los estudios realizados previamente por la CAR [10]. Las diferentes regiones de interés fueron ubicadas en la imagen correspondiente a la zona de estudio basado en el cálculo del índice de factor óptimo, el cual muestra la composición de color con tres bandas que permite diferenciar mejor las coberturas presentes en la imagen basados en la desviación y correlación entre las diferentes combinaciones [9].

Las propiedades de las diferentes regiones de interés como ya se mencionó, se muestran en la Tabla I; las regiones son visibles en la Figura 5. Los datos de entrenamiento de la red fueron capturados directamente sobre la imagen en el software especializado, de manera que se definieron regiones para cada una de las clases compuestas por píxeles, dichos píxeles y sus diferentes niveles digitales conformaron las muestras de entrenamiento presentadas a la red.

La evaluación de la separabilidad de las diferentes muestras de entrenamiento es mostrada en la Tabla II para la imagen. Allí se muestra que todas las clases presentan una apropiada separabilidad con la Divergencia Transformada [9]. Las clases Arbustos y Bosques presentan una separabilidad baja debido a que estas clases presentan una respuesta espectral muy similar.

Tabla II. Separabilidad de Clases por Divergencia Transformada

Subgrupo	Subgrupo	Valor
C.1.1. Residencial	A.1.2. Pastos	2.00
	A.1.3. Cultivos Semiperennes	1.99
	A.2.1. Viveros e Invernaderos	1.99
	B.2.2. Plantado	2.00
	P.1.2. Arbustos	2.00
A.1.2. Pastos	A.1.3. Cultivos Semiperennes	2.00
	A.2.1. Viveros e Invernaderos	2.00
	B.2.2. Plantado	2.00
	P.1.2. Arbustos	2.00
A.1.3. Cultivos Semiperennes	A.2.1. Viveros e Invernaderos	1.99
	B.2.2. Bosque Plantado	2.00
	P.1.2. Arbustos	2.00
A.2.1. Viveros e Invernaderos	B.2.2. Bosque Plantado	2.00
	P.1.2. Arbustos	2.00
B.2.2. Bosque Plantado	P.1.2. Arbustos	1.99

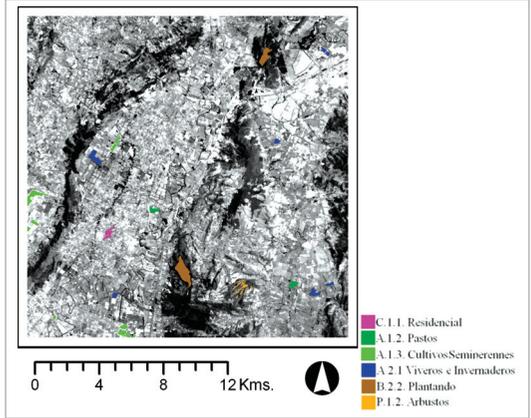


Figura 5. Imagen en escala de grises con superposición de regiones de interés.

### 3.5. Muestras de Evaluación

Para la selección de los píxeles de referencia, se utilizó el método de distribución aleatoria estratificada el cual genera puntos de manera aleatoria sobre la imagen, pero tiene en cuenta la distribución de clases en la capa temática incluyendo un número mínimo de puntos por clase. Estos píxeles serán útiles en el proceso de evaluación de calidad de la imagen clasificada para poder comparar píxeles de una región clasificada contra su esperada clasificación.

En cuanto al tamaño de la muestra de evaluación, la literatura menciona un mínimo número de píxeles por clase, el cual puede ser de 50 píxeles por clase para imágenes o sub-escenas pequeñas [13] [20]. Otros autores recomiendan que sean entre 0.1% y el 0.5% de los píxeles que componen en la totalidad la imagen que se ha clasificado [9].

Para este estudio se tomó el 0,1% de del número total de píxeles de la imagen con un mínimo de 10 píxeles por clase, lo cual es equivalente a 490 píxeles de referencia debido a que es una sub-escena de 700 x 700 píxeles. Al final de las diferentes pruebas de clasificación, se asignó para cada pixel de referencia el valor correcto de clase a partir de información considerada como verdadera, la cual fue tomada de los mapas clasificados de la zona de estudio realizados por la CAR [10]. A partir de dichos valores es posible construir la matriz de confusión y obtener los indicadores de calidad mencionados anteriormente.

## 4. Resultados

En esta sección se muestran los resultados que se obtuvieron al aplicar la red neuronal Perceptron Multicapa y Fuzzy-Artmap en dos escenarios de clasificación: el primer escenario aplica clasificación únicamente con información espectral, el segundo escenario aplica clasificación con información espectral más información auxiliar derivada de las texturas y el modelo digital de elevación.

### 4.1. Clasificación con Perceptron Multicapa usando información espectral

Se utilizó el paquete de software ENVI 4.1. La Tabla III muestra el resultado de los valores de la mejor clasificación lograda por la red neuronal Perceptron Multicapa. Un número de iteraciones cercano a 5.000 fue el indicado para que se alcanzara el error mínimo establecido. Se realizaron pruebas con un número mayor de iteraciones, pero no aportaron a una reducción del valor de error.

El valor del criterio mínimo de error fue seleccionado como 0.01, ya que estudios realizados con esta red neuronal [3] [29], mencionan valores de 0.1 a 0.05, siendo así el valor usado aun más exigente, por lo que se necesitó un número mayor de iteraciones.

Para la función de activación se seleccionó la función de tipo sigmoideal, ya que se realizaron pruebas con la función hiperbólica pero dicha función no logró reducir el error al valor mínimo, y al contrario generó clasificaciones de muy poca exactitud temática. Con la función sigmoideal, el aprendizaje fue más estable debido al comportamiento suavizado de la función [19].

El parámetro de umbral de contribución indica el tamaño de la contribución de los pesos en el valor de activación. Valores muy altos, cercanos a 1 generaron clasificaciones con un alto grado de generalización y gráficas de entrenamiento con alta presencia de oscilaciones. Valores entre 0.2 y 0.4 hicieron que la gráfica de entrenamiento de la red neuronal redujera la presencia de oscilaciones, lo que indica que el error se va modificando paulatinamente y no con alteraciones pronunciadas.

Para el parámetro de tasa de aprendizaje, valores entre 0.1 y 0.2 redujeron el número de oscilaciones entre iteraciones e hicieron que el cambio de los valores de las conexiones fuese suave, pero asegurando la estabilidad del aprendizaje de la red. En este sentido se siguió la recomendación de preferir un alto número de iteraciones para reducir el error en lugar de conseguir cambios rápidos en las conexiones [29].

El momento de entrenamiento asegura la reducción de las oscilaciones entre iteraciones. Valores entre 0.6 y 0.8 mostraron una reducción considerable en el número de oscilaciones [29]. Usando los parámetros indicados anteriormente, se lograron generar clasificaciones de buena exactitud temática como se muestra en la Tabla III y se visualiza en la Figura 6. Valores en la exactitud temática de 87.14% y el índice kappa de 0.8407 representan un resultado efectivo de clasificación con información únicamente de tipo espectral.

Las coberturas que presentaron problemas de mezcla espectral como el uso residencial no fueron clasificadas correctamente en su totalidad, ya que se presenta confusión entre construcciones y algunas zonas de cultivos, lo cual hace difícil su adecuada delimitación [16]. En coberturas como viveros e invernaderos y arbustos, se presenta-

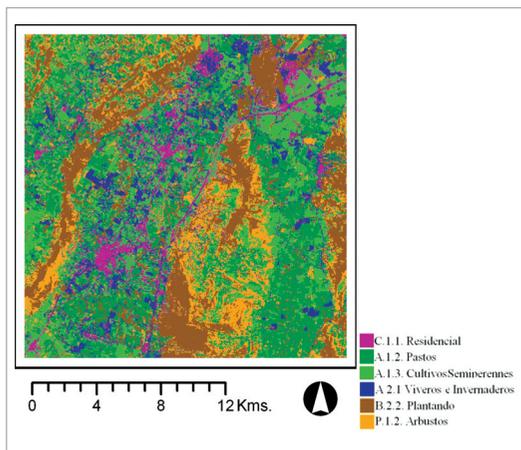


Figura 6. Imagen clasificada con red neuronal Perceptron Multicapa con información espectral únicamente.

Tabla III. Parámetros de Entrenamiento Clasificación Perceptron Multicapa con Información Espectral

Elemento	Ítems	Valor
Parámetros de Entrenamiento	Numero de Bandas de Entrada	6
	Numero de Clases a Extraer	6
	Función de Activación	Sigmoideal
	Umbral de Contribución	0,2
	Tasa de Entrenamiento	0,3
	Momento de Entrenamiento	0,8
	Mínimo Error Permissible	0.01
	Numero de Capas Ocultas	1
	Numero de Iteraciones	5.000
Evaluación Detallada	Error Mínimo Alcanzado	0.009985
	Iteraciones Ejecutadas	4.601
	Tiempo de Computo (Minutos)	35
	Exactitud Temática (%)	87.14%
	Coefficiente Kappa	0.8407
Exactitud de Productor	C.1.1.Residencial	53.33%
	A.2.1.Viveros e Invernaderos	74.58%
	P.1.2.Arbustos	80.77%
Exactitud de Usuario	C.1.1.Residencial	51.61%
	A.2.1.Viveros e Invernaderos	84.62%
	P.1.2.Arbustos	88.73%

ron resultados de clasificación competitivos al obtener exactitudes de productor y de usuario alrededor del 80%.

## 4.2. Clasificación con Perceptron Multicapa adicionando información auxiliar

En este escenario se adicionaron a las bandas espectrales la siguiente información de tipo auxiliar (7 bandas nuevas) [25]: análisis de texturas de valor medio, segundo momento angular, disimilaridad [26], índice de verdor de la transformación TasseledCap [9], el índice de vegetación NDVI [14] e imágenes de pendiente y aspecto derivadas del modelo digital de elevación [12] [22].

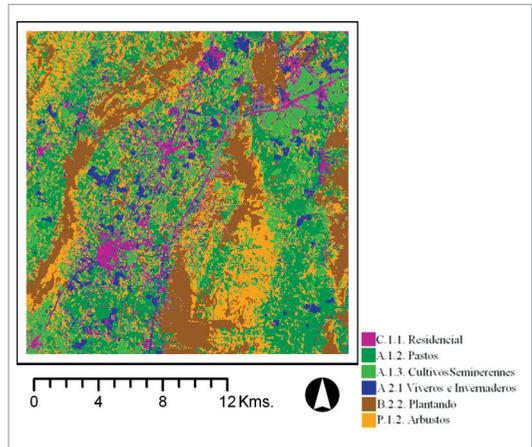
En estas pruebas se aplicaron valores para la tasa de aprendizaje entre 0.2 y 0.3, valores para el umbral de contribución entre 0.1 y 0.2 y el momento de entrenamiento entre 0.7 y 0.8. Así se aseguró un proceso de clasificación bastante estable, con poca presencia de oscilaciones fuertes y reducción del error aun mínimo establecido. El criterio de error mínimo se estableció con un umbral menor, para comprobar que la red consiguiera reducirlo con la ayuda de la información auxiliar. El valor de error obtenido fue de 0.002, mostrando que se logró refinar mejor aún las características de cada clase y cada muestra de entrenamiento. El detalle de los parámetros usados en esta prueba con información auxiliar se observan en la Tabla IV.

Un efecto de aumentar el nivel de exigencia de error mínimo fue el incremento en el número de iteraciones de aprendizaje de la red neuronal. Se definieron máximo 10.000 iteraciones, de las cuales se alcanzaron alrededor de 7.000 y 8.000 entre las diferentes pruebas. Como muestra la Tabla IV con 6 bandas espectrales más las 7 bandas de información auxiliar mencionadas, los resultados alcanzados en la evaluación de calidad mostraron que la implementación de información auxiliar en la red neuronal Perceptron Multicapa presenta mejores resultados. Los indicadores de exactitud temática de 95.10% y un índice kappa de 0.9354 reflejan las mejoras en el desempeño de la red.

De igual forma, una imagen con un porcentaje de clasificación correcta que supere el 90% es considerado un buen producto del proceso de clasificación y un buen insumo para la producción de cartografía temática de cobertura y usos del suelo. El resultado de esta clasificación en una imagen se observa en la Figura 7.

**Tabla IV. Parámetros de Entrenamiento**  
Clasificación con Información Auxiliar

Elemento	Ítem	Valor
Parámetros de Entrenamiento	Numero de Bandas de Entrada	13
	Numero de Clases a Extraer	6
	Función de Activación	Sigmoidal
	Umbral de Contribución	0.2
	Tasa de Entrenamiento	0.3
	Momento de Entrenamiento	0.8
	Mínimo Error Permissible	0.002
	Numero de Capas Ocultas	1
Evaluación Detallada	Numero de Iteraciones	10.000
	Error Mínimo Alcanzado	0.002
	Iteraciones Ejecutadas	7005
	Tiempo de Computo (Minutos)	65
	Exactitud Temática (%)	95.10%
Exactitud de Productor	Coefficiente Kappa	0.9354
	C.1.1.Residencial	83.33%
	A.2.1.Viveros e Invernaderos	88.37%
	P.1.2.Arbustos	95.24%
	Exactitud de Usuario	C.1.1.Residencial
A.2.1.Viveros e Invernaderos		92.68%
P.1.2.Arbustos		99.17%



**Figura 7.** Imagen clasificada con red neuronal Perceptron Multicapa con mejores resultados de clasificación al incorporar información auxiliar.

### 4.3. Clasificación con Fuzzy-Artmap usando información espectral

Para encontrar un conjunto de valores para los parámetros de entrenamiento con este modelo de red, se realizaron pruebas con el software ClasserScript [18], el cual es el paquete especializado en la aplicación de redes neuronales Artmap. La Tabla V presenta los valores asignados a los diferentes parámetros de la red neuronal para llevar a cabo el proceso de clasificación en este escenario. Valores altos en el parámetro de vigilancia, el cual es el encargado de establecer si las neuronas seleccionadas como ganadoras están lo suficientemente relacionadas, produjeron clasificaciones con bajo grado de generalización, lo que conlleva a que posiblemente cada muestra de entrenamiento sea reconocida por la red como una clase. Valores entre los 0.6 y 0.7 presentaron resultados adecuados en la imagen clasificada [7] [27] [28].

Para la tasa de aprendizaje, valores pequeños que oscilan entre 0.1 y 0.3 presentaron un buen comportamiento en el entrenamiento de la red, generando clasificaciones con un alto grado de confiabilidad, como la que observa en la Figura 8. Valores altos hicieron que la red cambiara los pesos de las conexiones de manera abrupta, produciendo así imágenes con agrupaciones incorrectas [7] [24].

En cuanto a los parámetros de competencia, valores pequeños hicieron que la red realizara una etapa de entrenamiento estable [24]. Valores menores a 0.0001 condujeron a que la selección de la neurona ganadora de cada módulo estuviera en mayor relación con los valores de activación que con las conexiones existentes entre ellas mismas a nivel de capa [7] [27] [28].

En cuanto a las épocas de entrenamiento, se observó que con una sola época la red neuronal logró identificar adecuadamente las muestras de entrenamiento y clasificar los píxeles de la imagen apropiadamente. La exactitud temática alcanzada por esta clasificación fue de 81.22%, indicando una confiabilidad de asignación correcta de píxeles a las respectivas clases identificadas en la etapa de entrenamiento. Este valor se interpreta como el 81.22% de la imagen está correctamente clasificada como se observa en la Figura 9; el porcentaje restante, corresponde a los errores de clasificación que cometió el modelo de red neuronal. La Tabla V muestra el desempeño de la red neuronal Fuzzy-Artmap en cuanto resultados adecuados de clasificación entre las coberturas con problemas de píxeles mezcla con clases de viveros e invernaderos y cultivos semiperennes [16] [19].

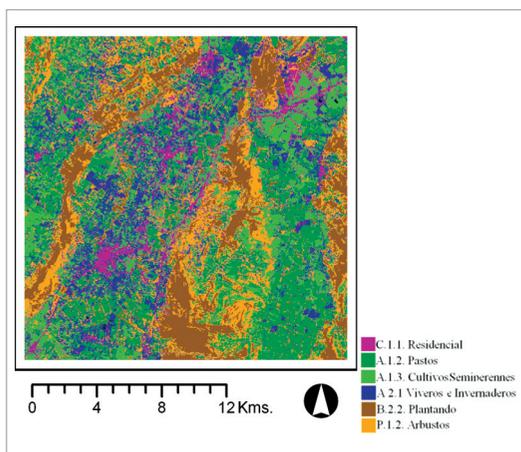


Figura 8. Imagen clasificada con modelo Fuzzy-Artmap con información espectral únicamente.

Tabla V. Parámetros de Entrenamiento y Clasificación con Fuzzy-Artmap		
Elemento	Ítems	Valor
Parámetros de Entrenamiento	Numero de Bandas de Entrada	6 Bandas Normalizadas
	Numero de Clases a Extraer	6 (Seis)
	Modelo de Red Neuronal	Fuzzy-ARTMAP
	Parámetro de Vigilancia	0.6
	Parámetro Alpha	0.0001
	Tasa de Aprendizaje	0.3
	Parámetro De Competencia	-0.001
	Épocas de Entrenamiento	1
	Porcentaje Matriz de Confusión (Muestras de Entrenamiento)	99.1%
Evaluación Detallada	Exactitud Temática	81.22%
	Índice Kappa	0.7721
	Tiempo de Entrenamiento	0.2 seg.
	Tiempo de Clasificación	2.0 seg.
Exactitud de Productor	Cultivos Semiperennes	100.00%
	Viveros e Invernaderos	66.00%
Exactitud de Usuario	Cultivos Semiperennes	80.39%
	Viveros e Invernaderos	89.41%

### 4.4. Clasificación con Fuzzy-Artmap adicionando información auxiliar

En este escenario, además de las 6 bandas espectrales de la imagen, se adicionaron 7 bandas consideradas de información auxiliar mencionadas en el numeral 4.2. Los valores de los parámetros de entrenamiento en este caso se listan en la Tabla VI.



Figura 9. Comportamiento de viveros e invernaderos asignados a Clase 0 en Fuzzy-Artmap.

Se encontraron valores de 87.96% y 0.8478 en la exactitud temática e índice kappa, lo que indica que al incluir esta información en el proceso de entrenamiento se mejora el porcentaje de clasificación correcta [24]. Esta mejora en los resultados se ilustra en la clasificación que se observa en la Figura 10.

### 5. Conclusiones

A partir de los resultados obtenidos en este estudio, se pueden establecer algunas conclusiones acerca de la conveniencia de la aplicación de las redes neuronales Perceptron Multicapa y Fuzzy-Artmap en la clasificación de cobertura del suelo utilizando imágenes satelitales multi-espectrales.

En primer lugar se puede afirmar que la utilización de información de tipo auxiliar derivada del procesamiento digital del imágenes de satélite ayudaron a mejorar la los porcentajes de clasificación correcta.

Por otra parte, el tiempo computacional de la aplicación de la red Fuzzy-Artmap, con y sin información auxiliar es muy bajo, los proceso de entrenamiento y de clasificación toman alrededor de unos pocos segundos. Esta característica la hace competitiva con los algoritmos tradicionales y con el Perceptron Multicapa, aunque los procesos de depuración de datos que hay que llevar a cabo para su aplicación son complicados, ya que este

Tabla VI. Parámetros de Entrenamiento y Clasificación con Información Auxiliar con Fuzzy-ARTMAP

Elemento	Ítem	Valor
Parámetros de Entrenamiento	Numero de Bandas de Entrada	3 Bandas Normalizadas
	Numero de Clases a Extraer	6 (Seis)
	Modelo de Red Neuronal	Fuzzy-Artmap
	Parámetro de Vigilancia	0.6
	Parámetro Alpha	0.0001
	Tasa de Aprendizaje	0.3
	Parámetro de Competencia	-0.001
	Épocas de Entrenamiento	1
	Porcentaje Matriz de Confusión (Muestras de Entrenamiento)	99.8%
Evaluación Detallada	Exactitud Temática	87.96%
	Índice Kappa	0.8478
	Tiempo de Entrenamiento	0.03 seg.
	Tiempo de Clasificación	10.00 seg.
Exactitud de Productor	Cultivos Semiperennes	89.08%
	Viveros e Invernaderos	96.18%
Exactitud de Usuario	Cultivos Semiperennes	89.83%
	Viveros e Invernaderos	82.35%

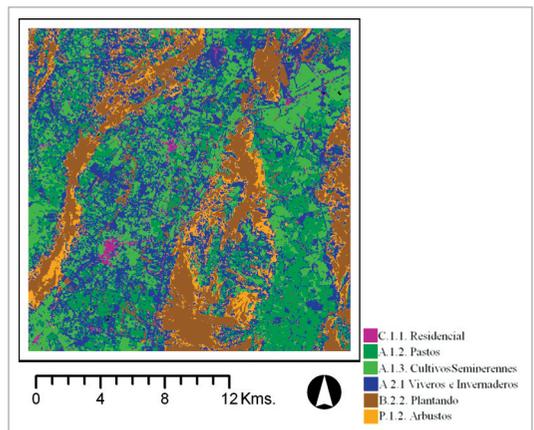


Figura 10. Imagen clasificada con modelo red neuronal Fuzzy-Artmap más información auxiliar.

algoritmo no se encuentra implementado en los programas de procesamiento digital de imágenes más utilizados. Como conclusión final, los dos modelos de redes neuronales aplicados en este estudio son clasificadores que ofrecen resultados de calidad adecuada para procesos de clasificación de coberturas del suelo sobre imágenes de satélite multi-espectrales, más aún cuando se utiliza la información de auxiliar mencionada en este estudio.

## 5.1. Ventajas y desventajas

### 5.1.1. Comparación cuantitativa

A partir de los indicadores estadísticos de exactitud temática aplicados a las diferentes clasificaciones generadas por los clasificadores neuronales Perceptron Multicapa y Fuzzy-Artmap, se pueden realizar una serie de comparaciones desde el punto de vista cuantitativo para estimar los mejores resultados de calidad según el algoritmo seleccionado. Para las dos redes neuronales, la evaluación de las exactitudes de usuario y de productor dejó evidencia de algunos inconvenientes que se tienen cuando las muestras no son idealmente separables o presentan algún tipo de mezcla entre ellas.

La red neuronal Perceptron Multicapa alcanza un mejor resultado, pues obtiene un 95.10% de clasificación correcta en comparación con el modelo de red neuronal Fuzzy-Artmap que obtuvo un 87.96%. Si se mira el índice kappa, la red neuronal Perceptron Multicapa obtuvo un 93.54%, el cual es un valor adecuado y acorde a los resultados de la exactitud temática. Por el contrario, el modelo de red neuronal Fuzzy-Artmap obtuvo un valor por debajo del valor umbral, el cual fue de 84.77%.

### 5.1.2. Comparación cualitativa

Como cualidades de la red Perceptron Multicapa se destaca que supera inconvenientes presentes en los clasificadores convencionales basados en estadísticas. Lo anterior dado que descubre patrones directamente sobre el conjunto de datos de entrenamiento, sin tener en cuenta ningún supuesto estadístico. Una desventaja de la red neuronal Perceptron Multicapa es el costo computacional: aunque este modelo presentó los mejores resultados de indicadores de calidad temática, todo el proceso consumió un número alto de iteraciones, lo que conllevó a un mayor consumo de tiempo.

Por su parte, la red neuronal Fuzzy-Artmap es un modelo de red neuronal que ofrece resultados de calidad cuando se realiza proceso de clasificación con implementación de información de tipo auxiliar [12]. Una desventaja de este modelo de red neuronal es su limitada disponibilidad en herramientas tecnológicas, ya que no se encuentra implementado en software especializados en procesamiento digital de imágenes de percepción remota. Sobre este punto se resalta que la manipulación errónea en la preparación de los datos para el software ClasserScript puede llevar a resultados inesperados.

## Referencias bibliográficas

- [1] Bollela, Ana. "Redes Neuronales". Universidad ORT. Uruguay. 2003
- [2] Camara, Gilberto; Vieira, Antonio. "Geocomputation Techniques For Spatial Analysis: Is It Case For Health Data Set?" Image Processing Division, National Institute for Space Research, Brazil. 2001.
- [3] Cardenas, Luis. "Optimal Design of Neural Network for Land-Cover Classification from Multi-spectral Imagery". Centro de Investigaciones de Geografía y Geomática. México. 2003.
- [4] Carpenter, Gail. "Default ARTMAP. Department of Cognitive and Neural System. 2003

- [5] Carpenter, Gail. Gopal; Sucharita, Macomber, Scout. Martens, Siegfried, Woodcock, Curtis. "A Neural Network Method for Mixture Estimation for Vegetation Mapping" Remote Sensing Environ. New York 1999
- [6] Carpenter, Gail. Gopal; Sucharita, Macomber, Scout. Martens, Siegfried, Woodcock, Curtis. "A Neural Network Method for Efficient Vegetation Mapping" Remote Sensing Environ. New York. 1999
- [7] Carpenter, Gail. Grossber, Stephen. Shock, Byron. Woodcock, Curtis. "A Neural Network Method for Land Use Change Classification with Application to the Nile River Delta". Department of Cognitive and Neural System. 2001
- [8] Cepeda Caballero, Jahir. "Redes Neuronales Estáticas – Sistemas Expertos e Inteligencia Artificial". Corporación Colombiana de Colombia IDEAS. 2002.
- [9] Chuvieco, Emilio. "Fundamentos de Teledetección Espacial". Ediciones Rialp S.A. Reimpresión corregida 568 pp. Madrid, España. Madrid. 2000
- [10] Corporación Autónoma Regional (C.A.R). Ecoforest Ltda. Swedforest Scandiaconsult "Inventario y Diagnostico de los Recursos Naturales y Renovables del Área Jurisdiccional de la Corporación Autónoma Regional C.A.R. – Cundinamarca" 1995.
- [11] Forero, María Cristina. "Levantamiento de Cobertura Terrestre y Uso de la Tierra". Revista CIAF Volumen 9. Bogotá, 1984.
- [12] Gecek, Deniz. "Improvement of Image Classification with the Integration of Topographical Data. Geodetic and Geographic Information Technology. Ankara. Turkey. 2000"
- [13] Jensen, John. "Introductory Digital Image Processing: A Remote Sensing Perspective". Prentice Hall. Second Edition. 1996.
- [14] Leica Geosystems. "Erdas Field Guide. Fifth Edition Translation". Estados Unidos de America. 2000, p 213
- [15] Lin, Hue; Chenghu, Zhou. "Geo-Interpretation Model for Land-Cover / Land-Use Classification". Lab Resource and Environment Information System, CAS, Beijing, China, Department of Geography, Chinese University of Hong Kong. 2000.
- [16] Liu, Xiao Hang, "Change Detection for Urban Growth Modeling. An Artificial Neural Network Approach". 4th International Conference on Integrating GIS and Environmental Modeling. Canada. September 2000.
- [17] Lizarazo, Iván. Mesa, Samuel, Cuitiva, Ricardo. "Clasificación de la cobertura y del uso del suelo urbano usando imágenes de satélite y algoritmos supervisados de inteligencia artificial". Revista la UD y la Geomática, Vol. 1, núm. 2, Segundo semestre 2008.
- [18] Martens, Siegfried. "ClasserScript Ver. 1.1 User's Guide". Boston University. 2005.
- [19] Mas, Jean. "An Artificial neural Networks Approach to Map land Use Land Cover using LANDSAT Imagery and Ancillary Data." Universidad Autónoma de México. IEEE. 2003
- [20] Mendoza, E.H. Santiso, J.R. Santa Rosa, A.N.C. "Land Use Land Cover mapping In Brazilian Amazon using Neural Network with Aster Terra Data" INPE. 2003.
- [21] Nouza, David. Laclir; Verne, Schwab, Matthew. "Using Neural Network to Evaluate Land Use Change". D. Nouza et al. 2000
- [22] Perez, Magda Liliana. "Aporte de las Clasificaciones por Métodos Convencionales, redes Neuronales y Análisis de Texturas en Estudios Geográficos. Caso de Uso "Sinergia entre Imagen Landsat y Radarsat de la Sabana de Bogotá". Instituto Geográfico Agustín Codazzi. 2003"
- [23] Quero Reboul, José Manuel. "Redes Neuronales". Departamento de Ingeniería Electrónica. Universidad de Sevilla. 2001.
- [24] Rajasekaran, S. Vijayalakshimi, Pai. "Image Recognition Using Simplified Fuzzy-ARTMAP Augmented with a Moment based Feature Extractor. International Journal of Pattern Recognition and Artificial Intelligence. 2000"
- [25] Schroeder, Thomas. "Input / Output Data Definition Of Artificial Neural Network For Computing Pigment Concentrations From Remote The Sensing Reflectance At Sea Level Above Case-1 Water". Freie Universitat Berlin. 2003
- [26] Shah, S.K. "Image Classification Based On Textural Features Using Artificial Neural Network (Ann)". Department of Electrical Engineering MS University of Baroda, Kalabhavan. 2003.
- [27] Shock, B.M.; Carpenter, G.A.; Gopal, S; Woodcock, C.E. "Artmap Neural Network Classification of Land Use Change". Proceedings of the World Congress of Computers in Agriculture and Natural Resources. 2002.
- [28] Sinha; Ashok. Dudhani, Surekha. "Fuzzy Neural Network Modeling of Land Use/cover using IRS-1D Image. Galgoita College of Eng & technology. India. 2004"
- [29] Tso, Brandt; Mather, Paul. "Classification Methods for Remotely Sensed Data". First Published by Taylor and Francis. 2001.
- [30] Ríos de la Torre, Ignacio; Calderón Osorno, José Luis; Durán Camarillo, Edmundo René. Polilibro Redes Neuronales Artificiales 1. <http://hugo-inc.net/16.net/RNA/Unidad%201/1.8.html>

## Guillermo Antonio Toro Bayona

Nació en Bogotá, Colombia. Es Ingeniero Catastral y Geodesta. Y Especialista en Sistemas de Información Geográfica de la Universidad Distrital Francisco José de Caldas. Especialista en Construcción de Software de la Universidad de los Andes. Se desempeñó como ingeniero en el Centro de Investigación y Desarrollo de Información Geográfica del Instituto Geográfico Agustín Codazzi durante 3 años. Posteriormente se desempeñó en las áreas de Desarrollo de Software para el sector Bancario, Gobierno, Telecomunicaciones y Retail durante los últimos 3 años. [memo.toro@gmail.com](mailto:memo.toro@gmail.com)

## Iván Alberto Lizarazo Salcedo

Nació en Bucaramanga, Colombia. Es Ingeniero Civil de la Universidad Industrial de Santander. Especialista en Sistemas de Información Geográfica de Universidad Distrital Francisco José de Caldas. MSc en Geographic Information Science en la Universidad de Londres. PhD en Geografía en la Universidad de Londres. Ha sido consultor en el área de Geomática por 20 años en diferentes entidades del sector privado y público. Ampla experiencia como docente en SIG, Procesamiento Digital de Imágenes, Calidad de Información Geográfica y Gestión de Proyectos de Tecnología Informática. Actualmente se desempeña como profesor del proyecto Curricular de Ingeniería Catastral y Geodesia e integrante del Grupo de Investigación NIDE de la Universidad Distrital Francisco José de Caldas, Bogotá, Colombia. [ilizarazo@udistrital.edu.co](mailto:ilizarazo@udistrital.edu.co)