

## REDES NEURONALES ARTIFICIALES PARA LA CLASIFICACIÓN DE IMÁGENES SATELITALES

Jorge Enrique Rodríguez Rodríguez<sup>1</sup>

### RESUMEN

En este artículo se presenta el análisis hecho a un conjunto de datos que representan diferentes imágenes, clasificadas como: Tierra roja, Cosecha de algodón, Tierra gris, Tierra gris húmeda, Tierra con vegetación, Cada terreno gris húmedo. El artículo se estructura en: una introducción en la cual se destaca la importancia del modelo de los mapas auto-organizativos de Kohonen (SOM) y la red de resonancia adaptativa (ART2) para la clasificación de imágenes; descripción de los algoritmos utilizados por las dos redes neuronales artificiales en mención; información relevante al problema; uso de las redes SOM y ART2 en la clasificación de imágenes satelitales; y planteamiento de conclusiones y trabajos futuros.

### PALABRAS CLAVE

Red neuronal artificial, mapas auto-organizativos de Kohonen, red de resonancia adaptativa, aprendizaje computacional, clasificación de imágenes.

### ABSTRACT

In this paper is made the analysis to data set that represent different images, classified this way: red earth, cotton crop, gray earth, humid gray earth, earth with vegetation, humid gray land. The paper is structured in: an introduction of the importance on self-organizing maps and adaptative resonance network for the classification of images; an description of the algorithms used by the two neural networks; information of the problem; the use of the neural networks SOM and ART2 in the classification of satellite images; and obtain to conclusions and future works.

### KEY WORDS

Neural networks, self-organizing maps, adaptative resonance network, machine learning, images classification.

Fecha de recepción del artículo: 5 de agosto de 2008.

Fecha de aceptación del artículo: 3 de septiembre de 2008.

<sup>1</sup> Magister en Ingeniería de Sistemas. Especialista en Ingeniería de Software. Especialista en Diseño y Construcción de Soluciones Telemáticas. Ingeniero de Sistemas. Docente de la Universidad Libre.

## INTRODUCCIÓN

Existen evidencias que demuestran que en el cerebro hay neuronas que se organizan en muchas zonas, de forma que la información captada a través de los órganos sensoriales se representan en forma de mapas bidimensionales. Por ejemplo, en el sistema visual se han detectado mapas del espacio en zonas del córtex (capa externa del cerebro). Aunque en gran medida esta organización neuronal está predeterminada genéticamente, es probable que parte de ella se origine mediante el aprendizaje. Esto sugiere, por tanto, que el cerebro podría poseer la capacidad inherente de formar mapas topológicos de la información recibida del exterior. De hecho, esta teoría podría explicar el poder de operar del cerebro con elementos semánticos.

Algunas áreas del cerebro simplemente podrían crear y ordenar neuronas especializadas o grupos con características de alto nivel y sus combinaciones. Se trataría, en definitiva, de construir mapas espaciales para atributos y características.

A partir de estas ideas, T. Kohonen presentó en 1982 un sistema con un comportamiento semejante. Se trataba de un modelo de red neuronal con capacidad para formar mapas de características de manera similar a como ocurre en el cerebro. El objeto de Kohonen era demostrar que un estímulo externo (información de entrada) por sí solo, suponiendo una estructura propia y una descripción funcional del comportamiento de la red, era suficiente para forzar la formación de los mapas.

Por otro lado, cuando se desarrolla una red para organizar una tarea de clasificación de patrones, se suele reunir un conjunto de ejemplares que serán utilizados durante la fase de aprendizaje o entrenamiento de la red. Durante esta etapa la información es registrada en el sistema mediante el ajuste de los valores de los pesos de las conexiones entre las neuronas.

Una vez concluido el aprendizaje, la red está lista para funcionar y no se permite ningún cambio adicional de los pesos. Este procedimiento es factible si el problema que se pretende resolver por la red está bien limitado y puede definirse un adecuado conjunto de información de entrada que permita entrenar a la red para resolver el problema. Sin embargo, en muchas situaciones reales los problemas a resolver no tienen unos límites claros.

En respuesta a este dilema, Grossberg, Carpenter y otros colaboradores desarrollaron la denominada Teoría de Resonancia Adaptativa (ART). Esta teoría se aplica a sistemas competitivos en los cuales cuando se presenta cierta información de entrada sólo una de las neuronas de salida de la red (o una por cierto grupo de neuronas) se activa y alcanza su valor de respuesta máxima después de competir con las otras. Esta neurona recibe el nombre de vencedora. Se pretende entonces categorizar los datos que se introducen en la red. Las informaciones similares son clasificadas y hacen parte de la misma categoría y por tanto deben activar la misma neurona de salida, la neurona vencedora. Las clases de categorías deben ser creadas por la propia red, puesto que se trata de un aprendizaje no supervisado, a través de las correlaciones de los datos de entrada.

## 1. MAPAS AUTO-ORGANIZATIVOS DE KOHONEN - SOM

Los mapas de Kohonen son también denominados mapas auto-organizativos. Desarrollados por Teuvo Kohonen a partir de 1989, se basan en las redes neuronales para realizar un análisis y categorización automática del contenido semántico de documentos textuales. El resultado gráfico de este análisis es un mapa 2D de categorías en las que cada categoría ocupa un espacio proporcional a las frecuencias de sus componentes. Los patrones más frecuentes ocupan un espacio mayor a expensas de los menos habituales.

Kohonen estaba motivado por la idea de que "la representación del conocimiento en una particular categoría de cosas en general debiera asumir la forma de una mapa de características organizado geoméricamente sobre la parte correspondiente del cerebro". El algoritmo toma un conjunto N dimensional de objetos como entrada y entrena una red neuronal que converge finalmente a la forma de un mapa 2D. Parece ser, además, que los SOM se cuentan entre los modelos más realistas del funcionamiento cerebral.

¿Para qué sirven los mapas de Kohonen? Se pueden ver, por ejemplo, en el esquema que brinda la revista MappaMundi y el artículo de Martin Dodge sobre la aplicación ET-Map del Profesor Hsinchun Chen de la Universidad de Arizona. En este esquema el nivel superior es como un mosaico en el que los distintos dominios adoptan formas poligonales de lados paralelos. Cada dominio tiene una palabra que define la categoría. Si pulsamos sobre

un dominio determinado se abre una segunda pantalla que contiene otro mapa similar pero ahora ya restringido a los documentos de ese dominio particular. El proceso se repite hasta que llegamos al detalle suficiente como para que aparezca un listado tradicional con los documentos que componen ese subdominio concreto.

¿Son útiles los mapas de Kohonen? Los estudios (escasos y limitados) de usabilidad indican que cuando se sabe el documento que se busca resultan más útiles los sistemas tradicionales. Sin embargo, cuando se trata de ojear o para tener una idea global del contenido en general de una web o un conjunto de documentos los mapas de categorías pueden ser apropiados. Los mapas de Kohonen son una alternativa más de las que están floreciendo con el objetivo de hacer más digerible la representación de grandes conjuntos de información textual.

El desarrollo de ambientes de visualización basados en mapas auto-organizativos pretende descubrir estructuras y patrones en complejos conjuntos de datos espaciales, proveer reducción de datos y representaciones gráficas que puedan soportar el procesamiento, el análisis, la comprensión, y la construcción de conocimiento<sup>2</sup>.

El aprendizaje del modelo de Kohonen es no supervisado y de tipo competitivo. Las neuronas de la capa de salida compiten por activarse y sólo una de ellas permanece activa ante una determinada información de entrada a la red. Los pesos de las conexiones se ajustan en función de la neurona que haya resultado vencedora. El algoritmo de aprendizaje utilizado para establecer los valores de los pesos de las conexiones entre las N neuronas de entrada y las M de salida es el siguiente<sup>3</sup>:

1. Inicializar los pesos ( $w_{ij}$ ) con valores aleatorios pequeños y fijar la zona inicial de vecindad entre las neuronas de salida.
2. Presentar una entrada en forma de vector  $E_k = (e_1(k), \dots, e_N(k))$ , donde los componentes  $e_i(k)$  serán números reales.

3. Determinar la neurona vencedora de la capa de salida, la cual será la que tenga el valor más parecido al patrón de entrada  $E_k$ , para ello, se calculan las distancias o diferencias entre ambos vectores, y considerar una por una todas las neuronas de salida:

$$d_j = \sum_{i=1}^N (e_i^{(k)} - w_{ij})^2 \text{ donde } 1 \leq j \leq M, \text{ donde} \quad (1)$$

$e_i^{(k)}$ : componente i-ésimo del vector k-ésimo de entrada.

$w_{ij}$ : peso de la conexión entre la neurona i de la capa de entrada y la neurona j de la capa de salida.

4. Una vez localizada la neurona vencedora ( $j^*$ ), se actualizan los pesos de las conexiones entre las neuronas de entrada y dicha neurona, así como los de las conexiones entre las de entrada y las neuronas vecinas de la vencedora.

$$\text{donde } w_{ij}(t+1) = w_{ij}(t) + \alpha(t) [e_i^{(k)} - w_{ij}(t)] \quad (2)$$

$\alpha(t)$ : parámetro de ganancia o coeficiente de aprendizaje, con un valor entre 0 y 1, el cual decrece con cada iteración.

5. El proceso se debe repetir, al presentar todo el juego de patrones de aprendizaje.

El mapa construido (SOM) es una representación plana de los vectores prototipo, imaginados como puntos localizados en el espacio de datos. La eficiencia de esta representación es medida por dos índices:

- a. *Error de Cuantización*. Corresponde al promedio de la distancia Euclidiana de los vectores de datos a sus representantes más cercanos.
- b. *Error Topológico*. Indica cual es la fracción de vecinos en el mapa, los cuales no tienen regiones de Voronoi<sup>4</sup> en el espacio de datos.

<sup>2</sup> SKAPURA, D. Y FREEMAN J. "Redes neuronales, algoritmos, aplicaciones y técnicas de programación". España. Díaz de Santos, 1993, pp. 335-343.

<sup>3</sup> HAYKIN, S. Neural Networks "A comprehensive foundation". New Jersey – USA. Prentice Hall, 1999, p. 58.

<sup>4</sup> La región de Voronoi de un punto es el lugar geométrico de los puntos que están más cerca de dicho punto que de los otros puntos. En geometría computacional las regiones de Voronoi son las zonas del plano más cercanas a un conjunto dado de puntos. Esto a nivel práctico lo utilizan muchas empresas para definir sus zonas de cobertura. Por ejemplo, McDonalds lo utiliza para decidir donde tiene que poner una nueva sede. También se utiliza en planes de prevención de riesgos para saber a que zonas afectaría un escape de una central nuclear.

## 2. RED DE RESONANCIA ADAPTATIVA – ART2

Grossberg, Carpenter, y otros, desarrollaron la denominada teoría de la resonancia adaptativa – ART<sup>5</sup>. Esta red neuronal se basa en el principio de hacer resonar la información de entrada con las clases que reconoce la red. Si entra en resonancia con una clase, la red considera que pertenece a dicha clase y se realiza una adaptación que incluye algunas características de los nuevos datos a la categoría existente. Cuando no resuena con ninguno, la red se encarga de crear una nueva clase con el dato de entrada como ejemplo de la misma.

Esta teoría se aplica a redes neuronales con aprendizaje competitivo en los cuales cuando se presenta cierta información de entrada sólo una de las neuronas de salida se activa y alcanzar su valor de respuesta máximo después de competir con las otras. Esta neurona recibe el nombre de neurona vencedora<sup>6</sup>.

Existen tres elementos empleados en modelos con aprendizaje competitivo: un conjunto de neuronas iguales excepto los pesos que son definidos aleatoriamente y que por consiguiente responde diferentemente a cada de patrón de entrada; un límite impuesto sobre cada neurona; un mecanismo que permite a las neuronas competir para responder bien a un subconjunto dado de entradas, tal que solamente una neurona de salida o sólo una neurona por clase, es activada<sup>7</sup>.

Una red ART2 consta de dos capas entre las que se establecen conexiones hacia adelante y hacia atrás (*feedforward/feedback*), ver figura 1.

A continuación se presenta un resumen del funcionamiento de la red ART2<sup>8</sup>.

La capa F1 se encuentra dividida en seis subcapas, w, x, u, v, p y q. Todos los nodos que están marcados con una G (llamadas unidades de control de ganancia), envían una señal inhibitoria no especifica a todas las unidades

de la capa a la que llegan. Todas las subcapas de F1 así como la capa r del subsistema de orientación, tiene el mismo número de unidades. Las subcapas individuales de F1 están conectadas de unidad a unidad; esto es, las capas no están completamente interconectadas, con la excepción de las conexiones ascendentes que llegan a F2 y de las conexiones descendentes de F2.

El subsistema de orientación es el responsable al detectar falta de coincidencia entre las tramas ascendentes y descendentes de la capa F1. Ésta utiliza para determinar la coincidencia una magnitud que recibe el nombre de parámetro de vigilancia y suele identificarse mediante el símbolo p. El valor del parámetro de vigilancia mide hasta que grado discrimina el sistema entre distintas clases de tramas de entrada.

El control de ganancia se utiliza cuando se implementa una red ART2 donde la capa F2 podría recibir entradas de otra capa por encima de ella (dentro de una jerarquía de redes pertenecientes a un sistema mayor), así como de la capa F1 que está situada más abajo. Este control impide que una trama que entre por encima de la capa F2, se cruce o se compare con otra trama que ha entrado al mismo tiempo por la capa F1 (Figura 1).

El subsistema de atención está compuesto por las dos capas de elementos de procesamiento, F1 y F2, y un sistema de control de ganancia.

**Procesamiento en F1.** La actividad de las unidades de la subcapa F1 está gobernada por la ecuación de la forma:

$$Ex_i = -Ax_i + (1 - Bx_i)J_i - (C - Dx_i)J_i \quad (3)$$

En donde A, B, C, y D son constantes, ++ y -- representan factores excitatorios e inhibitorios netos, respectivamente. Las actividades de cada una de las seis capas de F1 se pueden resumir mediante las siguientes ecuaciones:

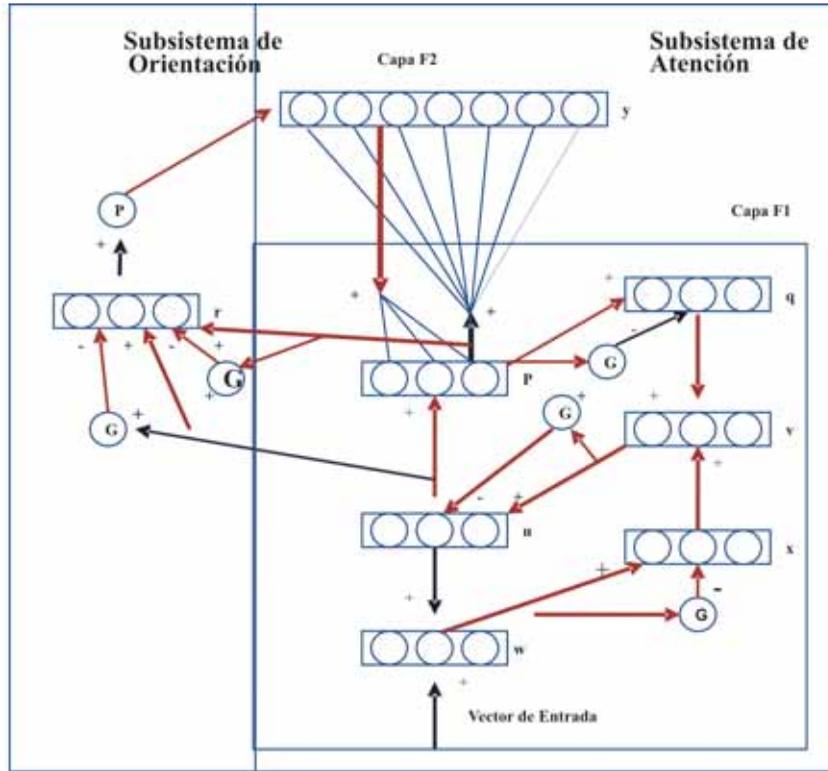
<sup>5</sup> KOHONEN, T., Self-Organizing Maps. Springer Series in Information Sciences, 30, Berlin 1995.

<sup>6</sup> Ibidem.

<sup>7</sup> HILERA, José., y MARTÍNEZ, Víctor. Redes Neuronales Artificiales. Wilmington – USA. Addison Wesley Iberoamericana, 1995, pp.219-220.

<sup>8</sup> DE MOYA, Marly y NIÑO, Fernando. Representación y Clasificación de Datos Geoespaciales Usando Redes Neuronales. Consultado En: [http://www.geocities.com/galsafa83/PAPER-CLEI\\_FORMATO.pdf](http://www.geocities.com/galsafa83/PAPER-CLEI_FORMATO.pdf)

Figura 1. Arquitectura de la red ART2<sup>9</sup>



$$w_i = I_i + au_i$$

$$x_i = \frac{w_i}{e + \|w\|}$$

$$v_i = f(x_i) + bf(q_i)$$

$$u_i = \frac{v_i}{e + \|v\|}$$

$$p_i = u_i + \sum_j g(y_j) \xi_{ij}$$

$$q_i = \frac{p_i}{e + \|p\|}$$

- (4) Los factores de las ecuaciones para todas las capas de F1 y para la capa r son:  $l_i$  es la  $i$ -ésima componente del vector de entrada. Los parámetros  $a$ ,  $b$ ,  $c$ ,  $d$  son constantes. La constante  $e$  recibe típicamente un valor positivo y considerablemente menor que 1, tiene el efecto de mantener finitas las activaciones cuando no está presente ninguna entrada en el sistema,  $y_j$  es la actividad de la  $j$ -ésima unidad de la capa F2 y  $g(y)$  es la función de salida de F2.
- (5)
- (6)
- (7) Las tres unidades de control de ganancia de F1 inhiben de manera no específica a las subcapas  $x$ ,  $u$  y  $q$ . La señal inhibitoria es igual al módulo del vector de entrada que llega a esas capas.
- (8) La forma de la función  $F(x)$  determina la naturaleza de la mejora de contraste que tiene lugar en F1. La elección lógica para esta función podría ser una sigmoide, aquí se presenta la opción de Carpenter:
- (9)

<sup>9</sup> Ibídem.

$$f(x) = \begin{cases} 0 & 0 \leq x \leq \theta \\ x & x > \theta \end{cases} \quad (10)$$

En donde  $\theta$  es una constante positiva y menor que 1.

Del análisis hecho a la capa F1 se puede llegar a la conclusión que esta capa lleva a cabo una normalización y una operación de mejora de contraste antes de intentar buscar coincidencias en sí, se debe considerar los detalles del resto del sistema.

**Procesamiento en F2.** El procesamiento de F2 está dado por la siguiente ecuación:

$$T_i = \sum_j p_j z_{ij} \quad (11)$$

La competencia de F2 da lugar a una mejora de contraste, en la cual se selecciona un único nodo ganador.

La función de salida de F2 está dada por:

$$g(y_j) = \begin{cases} d & T_i = \max_k \{T_k\} \neq k \\ 0 & \text{en caso contrario} \end{cases} \quad (12)$$

La ecuación 10 supone que el conjunto  $\{T_k\}$  contiene únicamente aquellos nodos que no hayan sido restaurados recientemente por el subsistema de orientación.

**Ecuaciones de LTM (memoria a largo plazo).** Tanto las ecuaciones ascendentes como las descendentes tienen la misma forma:

$$z_{ji} = g(y_j)(p_i - z_{ji}) \quad (13)$$

para los pesos ascendentes desde  $v_i$  en F1 hasta  $v_j$  en F2, y

$$z_{ij} = g(y_j)(p_i - z_{ij}) \quad (14)$$

para los pesos descendentes que van desde  $v_j$  en F2 hasta  $v_i$  en F1.

$$Z_{ji} = d(u_i + dz_{ij} - Z_{ji}) \quad (15)$$

y de forma similar

$$z_{ij} = d(u_i + dz_{ij} - Z_{ij}) \quad (16)$$

**El subsistema de orientación.** La ecuación de las actividades de los nodos de la capa r tiene la forma:

$$r_i = \frac{u_i + cp_i}{\|u\| + \|cp\|} \quad (17)$$

La condición para que produzca la restauración es

$$\frac{\rho}{\|r\|} > 1 \quad (18)$$

En donde  $\rho$  es el parámetro de vigilancia. El valor del parámetro de vigilancia mide hasta que grado discrimina el sistema entre distintas clases de tramas de entrada.

**Iniciación de LTM (memoria a largo plazo) ascendente.** Los valores iniciales para los vectores de pesos ascendentes está dada por la ecuación:

$$z_{ji}(0) \leq \frac{1}{(1-d)\sqrt{M}} \quad (19)$$

Donde M es el número de unidades de cada subcapa de F1.

### 3. INFORMACIÓN DEL PROBLEMA A RESOLVER

La información para el desarrollo de este documento fue tomada de una base de datos (Deposito UCI de aprendizaje computacional y teorías del conocimiento: <ftp://ftp.dice.ucl.ac.be/pub/neural-nets/ELENA/databases/REAL/satimage/>), esta base de datos se usa en el proyecto europeo StatLog; tal proyecto involucra aprendizaje computacional, estadística y algoritmos de redes neuronales sobre un conjunto de datos tomados de diferentes áreas del conocimiento (Medicina, Finanzas, Análisis de Imágenes e Ingeniería). Los datos satelitales son una de diferentes fuentes de información disponibles para una escena. La interpretación de una escena integra un espacio de datos de diferentes tipos

e incluye resoluciones multiespectrales y datos de radar, mapas topográficos y utilización de terrenos.

Esta base de datos es una subarea de la escena, consistente de 82 x 100 píxeles. La clasificación para cada píxel fue llevada a cabo bajo el fundamento de un sitio visitado por Ms. Karen Hall. Cada línea de datos corresponde a una matriz de 3 x 3 píxeles vencedores contenidos en una subarea de 82 x 100 píxeles; de igual forma, cada línea contiene los valores de los píxeles en cuatro bandas espectrales (convertidas a ASCII) de 9 píxeles vencedores de 3 x 3 y un número que indica el nombre de la clasificación del píxel central. El propósito es predecir esta clasificación, dado los valores multiespectrales.

La base de datos (satimage.dat) contiene 6435 patrones (también conocidos como instancias o muestras) con 36 atributos (4 bandas espectrales x 9 píxeles vencedores) más el nombre de la clase. Los atributos son numéricos, en el rango de 0 a 255 (8 bits). El nombre de la clase tiene un código, como se muestra en la Tabla 1.

**Tabla 1.** Conjunto de clases.

Número	Clase
1	Tierra roja
2	Cosecha de algodón
3	Tierra gris
4	Tierra gris húmeda
5	Tierra con vegetación
6	Cada terreno gris húmedo

Los datos están dados en orden aleatorio y ciertas líneas de datos han sido removidas para evitar reconstruir la imagen original desde el conjunto de datos.

#### 4. ¿CÓMO USAR UN SOM PARA CLASIFICAR DICHA MUESTRA DE DATOS?

Para tratar este problema se utilizó la herramienta software SOM PAK desarrollada por Teuvo Kohonen. Este software contiene todos los programas necesarios

para la correcta aplicación de los SOM. A continuación se hace una descripción de los comandos empleados para la solución al problema planteado:

#### 4.1 Randinit

Este comando o programa inicializa los vectores de referencia de valores aleatorios. Los vectores son conjuntos de valores aleatorios distribuidos en un área correspondiente a los datos. El tamaño del mapa es dado por la dimensión X (-xdim) y la dimensión Y (-ydim). La topología del mapa está dado por la opción (-topol) y la opción hexagonal (hexa) o rectangular (rect). La función de vecindad se define con la opción (-neigh) y la función de paso es la gaussiana<sup>10</sup>.

#### 4.2 Vsom

Este programa entrena el vector de referencia al usar el algoritmo SOM. Este programa busca las mejores unidades (valores) para cada vector de entrada y actualiza las unidades de acuerdo a la función de vecindad. El valor inicial de la tasa de aprendizaje es definido y luego decrece linealmente hasta terminar el entrenamiento. El valor inicial del radio de la vecindad también se define y luego decrece linealmente durante el entrenamiento.

#### 4.3 Vcal

Este comando etiqueta las unidades del mapa de acuerdo a los ejemplos almacenados en el archivo de entrada. Las mejores unidades del mapa corresponden a los datos de cada vector. Estas unidades se etiquetan teniendo en cuenta los valores del mapa más representativos.

#### 4.4 Visual

Este comando genera la lista de coordenadas correspondientes a las mejores unidades del mapa para los ejemplos de datos dados en el archivo (satimage.dat). Del mismo modo, genera la cuantificación individual del error. El comando Visual almacena los puntos de la imagen tridimensional en un estilo similar a los datos de entrada.

<sup>10</sup> En matemáticas la función gaussiana (en honor a Carl Friedrich Gauss), es una función definida por la expresión  $f(x) = ae^{-(x-b)^2/2c^2}$  donde a, b y c son constantes reales (a > 0).

Luego de analizados los resultados generados al ejecutar cada uno de los anteriores comandos, se construyó una matriz confusión donde se compara el número de muestras verdaderas de cada clase (1, 2, 3, 4, 5, y 7) con las obtenidas por la predicción. Igualmente, se construye una matriz para representar el porcentaje de las muestras que fueron estimadas correctamente.

Para lo anterior, se probó con cuatro configuraciones, al tener en cuenta la dimensión, la función de vecindad y el número de columnas (ver Tablas 2, 5, 8 y 11).

**Tabla 2.** Configuración 1 (modelo SOM).

Dimensión	6 x 6
Función de paso	Burbuja
Número de columnas	36

**Tabla 3.** Matriz de confusión para la configuración 1.

Clase	1	2	3	4	5	7	Total clases estimadas
1	1479	27	20	30	140	13	1709
2	0	602	0	0	5	0	607
3	33	0	1252	115	0	38	1438
4	6	6	78	388	29	297	804
5	15	67	0	4	380	33	499
6	0	1	8	89	153	1127	1378
Total clases verdaderas	1533	703	1358	626	707	1508	

**Tabla 4.** Matriz de porcentajes para la configuración 1.

Clase	1	2	3	4	5	7
1	96,48%	3,84%	1,47%	4,79%	19,80%	0,86%
2	0,00%	85,63%	0,00%	0,00%	0,71%	0,00%
3	2,15%	0,00%	92,19%	18,37%	0,00%	2,52%
4	0,39%	0,85%	5,74%	61,98%	4,10%	19,69%
5	0,98%	9,53%	0,00%	0,64%	53,75%	2,19%
6	0,00%	0,14%	0,59%	14,22%	21,64%	74,73%

Por ejemplo, si se toma la fila etiquetada con la clase 7 y la columna con la clase 1, se concluye, que: no hubo ninguna que se clasificara como 7 y que en verdad fuese 1. De igual forma, se observa que la peor clase clasificada fue la 5 con un 53,75% de verdad.

**Tabla 5.** Configuración 2 (modelo SOM).

Dimensión	12 x 12
Función de paso	Burbuja
Número de columnas	36

**Tabla 6.** Matriz de confusión para la configuración 2.

Clase	1	2	3	4	5	7	Total clases estimadas
1	1498	6	12	11	62	2	1591
2	1	660	0	3	22	0	686
3	19	0	1286	146	2	57	1510
4	2	1	21	260	1	89	374
5	13	34	7	28	541	60	683
6	0	2	32	178	79	1300	1591
Total clases verdaderas	1533	703	1358	626	707	1508	

**Tabla 7.** Matriz de porcentajes para la configuración 2.

Clase	1	2	3	4	5	7
1	97,72%	0,85%	0,88%	1,76%	8,77%	0,13%
2	0,07%	93,88%	0,00%	0,48%	3,11%	0,00%
3	1,24%	0,00%	94,70%	23,32%	0,28%	3,78%
4	0,13%	0,14%	1,55%	41,53%	0,14%	5,90%
5	0,85%	4,84%	0,52%	4,47%	76,52%	3,98%
7	0,00%	0,28%	2,36%	28,43%	11,17%	86,21%

Si se toma la fila etiquetada con la clase 4 y la columna con la clase 5, se observa que: hubo un 14% que se clasificó como clase 7 y en verdad pertenecen a la clase 5. En esta configuración la peor clase clasificada fue la 4 con un 41,53% de verdad.

**Tabla 8.** Configuración 3 (modelo SOM).

Dimensión	12 x 12
Función de paso	Burbuja
Número de columnas	4 (17, 18, 19 y 20)

**Tabla 9.** Matriz de confusión para la configuración 3.

Clase	1	2	3	4	5	7	Total clases estimadas
1	1467	7	13	5	63	1	1556
2	7	633	0	5	13	1	659
3	35	0	1275	132	5	34	1481
4	1	5	51	346	3	199	605
5	22	52	0	8	564	61	707
6	1	6	19	130	59	1212	1427
Total clases verdaderas	1533	703	1358	626	707	1508	

**Tabla 10.** Matriz de porcentajes para la configuración 3.

Clase	1	2	3	4	5	7
1	95,69%	1,00%	0,96%	0,80%	8,91%	0,07%
2	0,46%	90,04%	0,00%	0,80%	1,84%	0,07%
3	2,28%	0,00%	93,89%	21,09%	0,71%	2,25%
4	0,07%	0,71%	3,76%	55,27%	0,42%	13,20%
5	1,44%	7,40%	0,00%	1,28%	79,77%	4,05%
6	0,07%	0,85%	1,40%	20,77%	8,35%	80,37%

Al tomar la fila etiquetada con la clase 5 y la columna con la clase 7, se deduce que: hubo un 4,05% que se clasificó como clase 5 y en verdad pertenecen a la clase 7. Al igual que en la configuración 1 la peor clase clasificada fue la 4 con un 55,27% de verdad.

**Tabla 11.** Configuración 4 (modelo SOM).

Dimensión	20 x 20
Función de paso	Burbuja
Número de columnas	4 (17, 18, 19 y 20)

**Tabla 12.** Matriz de confusión para la configuración 4.

Clase	1	2	3	4	5	7	Total clases estimadas
1	1495	4	13	5	48	2	1567
2	2	647	0	5	24	1	679
3	14	0	1286	144	4	41	1489
4	4	5	45	312	4	146	516
5	18	40	2	4	564	38	666
6	0	7	12	156	63	1280	1518
Total clases verdaderas	1533	703	1358	626	707	1508	

**Tabla 13.** Matriz de porcentajes para la configuración 4.

Clase	1	2	3	4	5	7
1	97,52%	0,57%	0,96%	0,80%	6,79%	0,13%
2	0,13%	92,03%	0,00%	0,80%	3,39%	0,07%
3	0,91%	0,00%	94,70%	23,00%	0,57%	2,72%
4	0,26%	0,71%	3,31%	49,84%	0,57%	9,68%
5	1,17%	5,69%	0,15%	0,64%	79,77%	2,52%
6	0,00%	1,00%	0,88%	24,92%	8,91%	84,88%

Tomando la fila etiquetada con la clase 3 y la columna con la clase 4, se concluye que hubo un 23% que se clasificó como clase 3 y en verdad pertenecen a la

clase 4. Al igual que en la configuración 1 la peor clase clasificada fue la 4 con un 49,84% de verdad.

El modelo de mapas auto-organizativos de Kohonen es ideal para encontrar relaciones entre grupos complejos, debido a que se basa en el manejo de vecindad para agrupar; sin embargo, se identifica como limitante el alto costo computacional que emplea para construir los grupos<sup>11</sup>.

## 5. ¿CÓMO USAR UNA RED ART2 PARA CLASIFICAR DICHA MUESTRA DE DATOS?

El diseño de la red ART2 está formado por una capa de entrada con 4 neuronas y una capa de salida con 6 neuronas, más las capas suministradas por la herramienta JNNS para el modelo ART2.

Inicialmente los datos son normalizados entre 0 y 10 con el fin de que la función converja más rápido y así evitar pérdida de tiempo en el entrenamiento, debido a la gran cantidad de datos. Para esto se utiliza la siguiente función:

$$v = \frac{v_{\min}}{\max - \min} (new\_max - new\_min) + new\_min, \quad (20)$$

Para el entrenamiento de la red ART2 se utiliza la herramienta JNNS, este se hace con los 6435 datos inicialmente planteados en el archivo (satimage.dat), correspondientes a las clases 17, 18, 19 y 20, pero para el análisis de resultados se toma una muestra de 100 datos (tabla 14).

**Tabla 14.** Muestra de datos.

Instancia	Clase 17	Clase 18	Clase 19	Clase 20	Instancia	Clase 17	Clase 18	Clase 19	Clase 20
1	3,14	3,69	3,84	2,98	51	2,94	4,20	4,63	3,76
2	3,45	4,20	4,43	3,33	52	3,61	4,39	4,67	3,69
3	1,92	1,88	2,67	1,92	53	3,25	4,04	4,31	3,53
4	2,24	2,16	2,63	2,12	54	1,73	1,25	5,02	4,90
5	2,78	3,10	3,41	2,75	55	2,59	4,43	4,59	3,61

<sup>11</sup> BAUTISTA, S., REYES, A., y RODRÍGUEZ, J. Prototipo de software para la agrupación de datos con una red neuronal artificial con topología de Kohonen. Colombia. Tecnura ISSN 0123-92X – Año 8 No. 15. 2004, p. 65.

Tabla 14. Muestra de datos (cont.).

Instancia	Clase 17	Clase 18	Clase 19	Clase 20	Instancia	Clase 17	Clase 18	Clase 19	Clase 20
6	2,98	3,88	4,24	3,33	56	2,63	2,59	2,82	2,08
7	2,63	2,82	2,90	2,12	57	2,63	4,04	4,86	3,69
8	3,61	4,39	4,67	3,53	58	2,31	2,63	3,45	2,90
9	2,47	2,24	2,94	2,67	59	2,78	4,20	4,43	3,61
10	3,45	4,20	4,43	3,41	60	2,51	2,71	2,78	2,24
11	2,59	2,78	2,86	2,16	61	2,31	2,47	4,08	3,76
12	2,08	2,16	3,84	3,57	62	3,45	4,35	4,51	3,41
13	2,51	2,78	2,78	2,31	63	1,65	1,25	5,10	5,29
14	2,67	3,88	4,24	3,45	64	1,73	1,45	4,12	4,35
15	3,06	3,41	3,92	3,18	65	2,59	2,94	2,98	2,47
16	2,90	3,45	3,49	2,71	66	3,14	3,49	3,69	2,98
17	3,25	4,04	4,47	3,37	67	2,78	3,41	3,41	2,75
18	2,51	2,71	2,90	2,24	68	1,73	1,45	4,00	4,00
19	3,06	3,25	3,29	2,75	69	2,47	3,88	3,96	3,37
20	1,96	3,10	3,80	3,14	70	2,51	3,88	4,08	3,45
21	2,90	3,41	3,61	3,06	71	2,47	2,75	3,22	2,67
22	2,82	4,51	4,71	4,00	72	3,37	4,27	4,39	3,49
23	2,31	2,94	4,27	3,76	73	2,63	4,71	4,86	3,80
24	1,92	1,33	4,78	4,90	74	3,45	4,16	4,35	3,84
25	3,29	3,73	4,08	3,18	75	2,75	3,45	4,12	3,53
26	2,47	2,75	3,22	2,82	76	3,61	4,55	4,78	3,88
27	3,22	3,76	4,08	3,18	77	2,63	2,86	3,10	2,35
28	2,78	3,57	3,65	2,78	78	2,35	2,35	3,65	3,25
29	3,29	4,04	4,24	3,61	79	2,63	4,51	5,06	3,96
30	1,73	1,14	5,33	5,73	80	2,51	2,86	2,90	2,24
31	2,08	3,10	3,76	3,06	81	3,45	4,16	4,51	3,41
32	2,63	2,94	3,18	2,63	82	2,67	3,02	3,06	2,39
33	2,51	3,02	4,16	3,84	83	2,94	3,45	3,53	2,82
34	3,33	3,80	3,96	3,25	84	3,22	4,00	4,12	3,14
35	1,96	2,04	3,06	2,55	85	3,65	4,51	4,67	3,69
36	2,78	3,18	3,22	2,51	86	2,24	2,47	3,80	3,53
37	2,63	2,86	2,82	2,35	87	2,90	3,41	3,61	2,59
38	1,80	1,33	4,63	4,75	88	3,22	3,92	3,92	3,06
39	3,61	4,20	4,63	3,76	89	3,45	4,20	4,27	3,41
40	2,47	2,67	2,90	2,27	90	3,29	3,73	3,92	3,25
41	1,73	1,33	4,47	5,06	91	2,35	3,45	4,31	3,80
42	2,08	2,78	3,25	2,90	92	2,51	2,78	2,94	2,47
43	3,45	3,88	4,08	3,18	93	2,59	4,43	4,78	3,76
44	2,20	2,35	3,29	3,06	94	2,35	4,35	4,90	3,84
45	2,78	2,94	3,25	2,47	95	1,88	1,45	4,82	4,90

**Tabla 15.** Configuración 1 (modelo ART2).

D	v	p	a	b	C		Ciclos
0.9	1	0.987	10	10	0.1	0.5	10

De todas las pruebas ésta es la mejor, dado que fue donde se logró clasificar en las 6 clases.

**Tabla 16.** Configuración 2 (modelo ART2).

d	v	P	a	b	C		Ciclos
0.9	1.2	0.97	10	10	0.1	0.6	2

En esta configuración la clasificación no es la mejor, es decir que hubo clases en la que no se logró clasificar bien.

**Tabla 17.** Configuración 3 (modelo ART2).

d	V	P	a	b	C		Ciclos
0.9	1.2	0.99	10	10	0.1	0.8	2

Ésta fue la peor clasificación, dado que sólo clasificó en una clase.

**Tabla 18.** Configuración 4 (modelo ART2).

D	v	P	a	b	C		Ciclos
0.9	1	0.987	10	10	0.1	0.5	10

En ésta no se logró clasificar en la clase 19.

Al colocar el parámetro d relativamente bajo (menor a 0.7), la clasificación sólo se logra en una clase. Para las pruebas el parámetro de vigilancia p debe oscilar entre 0.9 y muy cerca de 1. Si se toma exactamente como 1, esto implicaría que todas las clases fuesen iguales

(en cuanto a características) y sólo la clasificación se daría en una sola clase. Del mismo modo si se toma un valor inferior a 0.9 también se obtiene una mala clasificación, esto se debe a que la similitud entre las diferentes clases es alta (cerca del 90%).

## 6. TRABAJOS FUTUROS

Se tiene previsto utilizar otras técnicas dentro de aprendizaje computacional (métodos bayesianos, algoritmos evolutivos y árboles de inducción) para clasificar imágenes satelitales, con el fin de medir la complejidad computacional de los algoritmos empleados en cada técnica y su efectividad en dicha clasificación frente a las topologías de redes neuronales artificiales presentadas en este artículo.

## CONCLUSIONES

Como se pudo observar en cada una de las matrices suministradas por el SOM, al aumentar la dimensión del mapa se disminuye el error, pero se aumenta el costo computacional; lo cual implica contar con computadoras con alta memoria en RAM y una alta velocidad en el procesador.

Según los valores obtenidos en las matrices de confusión, las clases 3, 4, y 7 son difícilmente diferenciables, debido a su uniformidad en las características del conjunto de datos.

Con el modelo ART2, se concluye, que la similitud de las diferentes clases (36) es aproximadamente del 90%.

La red neuronal ART2 es una buena opción para la agrupar datos de imágenes satelitales, dada su alta efectividad; sin embargo, la configuración del parámetro de vigilancia debe hacerse al utilizar heurísticas, o en el peor de los casos a través de la experimentación, lo cual implica que sí el parámetro empleado no es adecuado, la efectividad de agrupación es baja.

## **BIBLIOGRAFÍA**

BAUTISTA, S.; REYES, A., y RODRÍGUEZ, J. Prototipo de software para la agrupación de datos con una red neuronal artificial con topología de Kohonen. Colombia: Tecnura, ISSN 0123-92X, Año 8, No. 15, 2004.

HAYKIN, S. Neural Networks: "A comprehensive foundation". New Jersey - USA: Prentice Hall, 1999.

HILERA, José., y MARTÍNEZ, Víctor. Redes Neuronales Artificiales. Wilmington - USA: Addison Wesley Iberoamericana, 1995.

KOHONEN, T. Self-Organizing Maps. Springer Series in Information Sciences. 30, Berlín, 1995.

SKAPURA, D. y FREEMAN, J. Redes neuronales, algoritmos, aplicaciones y técnicas de programación. España: Díaz de Santos, 1993.

## **INFOGRAFÍA**

DE MOYA, Marly y NIÑO, Fernando. Representación y Clasificación de Datos Geoespaciales usando Redes Neuronales. Consultado En: [http://www.geocities.com/galsafa83/PAPER-CLEI\\_FORMATO.pdf](http://www.geocities.com/galsafa83/PAPER-CLEI_FORMATO.pdf)