

Detección de nubes a partir de redes neuronales perceptrón multicapa en imágenes Landsat

Cloud detection from multilayer perceptron neural networks on Landsat images

Gabriela Lucia Chamorro Yela¹, Francisco Luis Hernández Torres²

“Cómo citar este artículo: Chamorro Yela, G. y Hernández Torres, F. (2017). Detección de nubes a partir de redes neuronales perceptrón multicapa en imágenes Landsat. *Análisis Geográficos*, 52, 107-123.

Resumen

Se presenta la metodología empleada para detectar nubes en imágenes del satélite Landsat, las cuales complican el uso de datos en el dominio óptico de los satélites puesto que influyen en su análisis, causan corrección atmosférica inexacta, sesgan los valores del índice de vegetación de diferencia normalizada (NDVI) y generan errores en la clasificación de la cubierta terrestre y confusión en los cambios de coberturas vegetales. El modelo obtenido se convierte en una herramienta de apoyo para posteriores estudios en múltiples disciplinas, ya que facilita el proceso de análisis de diferentes fenómenos o estudios que se estén desarrollando. Para esto, se tomó como ejemplo la zona comprendida entre las cordilleras Central y Occidental cercana al municipio de Puerto Berrío, Antioquia, de donde se tiene información referente a 12 imágenes del satélite Landsat 7. Para la detección de nubes se empleó el análisis de redes como una herramienta potente para clasificar diferentes elementos, hacer un proceso computacional más eficiente, integrar información desde múltiples fuentes para incorporar nuevas características y además prescindir del uso de modelos estadísticos, a diferencia de otros enfoques. El proceso permitió entrenar la red con un EMC del 0,0339 con 7 neuronas en la capa oculta, con menos de 100 iteraciones para cada una de las imágenes empleadas, y se obtuvo una exactitud del 91%, mejor que los resultados alcanzados con el método de umbrales desarrollado en estudios anteriores, cuya exactitud fue del 87,37%.

Palabras clave: Landsat ETM+, redes neuronales, máscara de nubes, cobertura terrestre.

¹ Universidad del Valle, Cali, Colombia. Correo: gabriela.chamorro@correounivalle.edu.co.

² Universidad del Valle, Cali, Colombia. Correo: francisco.hernandez@correounivalle.edu.co.



Abstract

In the following article the methodology comes to detect clouds using Landsat satellite images, which complicates the use of data in the optical domain of the satellites, as influencing their analysis, causing inaccurate atmospheric correction, skewing values index normalized difference vegetation (NDVI), misclassification and land cover changes confusion vegetable coverages. The resulting model becomes a support tool for further studies in multiple disciplines to facilitate the process of analyzing different phenomena or studies being developed. For this is taken as an example, the area between the Central and Occidental mountain ranges near the town of Puerto Berrío, Antioquia, where there is information relating to 12 Landsat 7 satellite images. Cloud detection network analysis is used as a powerful tool to classify different elements, making more efficient computational process, integrating information from multiple sources to incorporate new features and also dispense with the use of statistical models unlike other approaches. The process allowed train the network with EMC 0.0339 with 7 neurons in the hidden layer, with less than 100 iterations for each of the images used. The method obtained an overall accuracy of 91% better than the results achieved with the method of thresholds developed in previous studies, the accuracy was 87.37%.

Keywords: *Landsat, neural networks, clouds mask, land cover.*



Introducción

El uso de imágenes de satélite ha tenido gran importancia a escala local, regional y nacional para entender los fenómenos que intervienen en distintas áreas como la agricultura, la geología (Van der Meer *et al.*, 2012), las ciencias forestales (Qi, Li, Liu & Jin, 2014), la gestión del medio ambiente, la gestión del riesgo (Van Westen, 2013) e incluso en la planificación urbana (Behling *et al.*, 2015), debido a su gran potencial en la captura de información. Las nubes y las sombras asociadas a estas imágenes, con frecuencia, obstruyen el área de observación de la superficie terrestre causando valores atípicos en los datos de reflectancia (Fisher & Danaher, 2011; Sano *et al.*, 2007).

Aunque no existe un consenso universal sobre la forma fundamental de clasificar las nubes, generalmente se pueden identificar tres tipos: altas, medias y bajas (Tapakis & Charalambides, 2013), con diferentes dimensiones, opacidad y propiedades. Dentro de las nubes bajas se encuentran los cúmulos, que son relativamente fáciles de identificar debido a su alta reflectancia en las bandas visibles, mientras que las nubes altas como los cirros, de aspecto semitransparente, son mucho más difíciles, ya que parte de la luz que llega a la nube se puede reflejar también en la superficie. La presencia de nubes y sus sombras complica el uso de datos en el dominio óptico de los satélites de observación de la Tierra. El efecto de brillo de las nubes y sus sombras influyen en el análisis de los datos causando corrección atmosférica inexacta y sesgando los valores en los índices de la cubierta terrestre, ya que los niveles digitales de las nubes y las sombras pueden adoptar

una respuesta espectral similar a la de otros objetos presentes en la superficie, y es por esto que pueden generar confusión en el momento de clasificar (Hagolle *et al.*, 2010). Debido a esto, muchos estudios se han desarrollado como insumo para la detección de nubes, las cuales involucran diferentes variables.

Panem *et al.* (2005) integraron modelos radiométricos y geométricos en una máscara con el fin de calcular el estado de confianza para permitir el almacenamiento automático de las nubes que han sido correctamente identificadas, mientras se realiza un proceso iterativo con redes neuronales para aquellas máscaras que han sido mal identificadas, estableciendo nuevos pesos en la capa oculta de la red.

Lewis, Cote y Tatnall (1995) adoptaron una técnica automatizada para la detección de nubes con redes neuronales con el objeto de definir los umbrales que permiten establecer los valores mínimos y máximos correspondientes al borde de la nube y al borde de su sombra respectivamente. Séptimo Torres *et al.* (2003) desarrollaron el algoritmo de retropropagación de Rumelhart para la identificación de nubes considerando, como variables de entrada, la información de brillo y variabilidad de cada pixel; además, crearon como variables de salida las clases de nubes, sombras y áreas de no nube.

Li *et al.* (2012) tuvieron en cuenta el índice tasseled cap (TC) y el índice de vegetación de diferencia normalizada (NDVI, por la sigla en inglés de *normalized difference vegetation index*) para obtener una máscara de nubes de la zona, la cual se evalúa visualmente, y también aplicaron el algoritmo automático de evaluación nubosidad (ACCA).



Walder y Maclaren (2000) desarrollaron un modelo de red neuronal para identificar las categorías de mar, tierra, nube alta y media. Este modelo se compara con dos métodos de detección de nubes: uno es el de la regla empírica de Walder, y el segundo es la función de Gabor. Los resultados indican que la clasificación con redes neuronales tiene una precisión del 80%, lo cual supera los dos métodos mencionados anteriormente.

Li y Tang (2013) desarrollaron dos algoritmos para detección de nubes utilizando las bandas visibles y del infrarrojo cercano. El primer algoritmo se basa en los tres componentes (brillo, verdor y humedad) de la transformación tasseled cap (TC) y el segundo algoritmo de redes neuronales realiza un ajuste de pesos para destacar los índices de verdor y humedad.

Lee *et al.* (1990) implementaron las bandas visibles del Landsat MSS para clasificar la textura de las nubes a partir de redes neuronales, comparándolas con el método del vecino más cercano. Este usa el método matriz de co-ocurrencias de niveles de gris (GLCM) de la imagen para representar las tres clases de nubes (cúmulos, extracúmulos y cirros) como capas de entrada. Los resultados indican que la red neuronal logra mayor precisión en la clasificación que el método del vecino más cercano.

Para detectar las nubes en las imágenes, Zhu y Woodcock (2012) plantean el método de función de máscara (fmask), el cual emplea la reflectancia de las imágenes Landsat TM/ETM + de las bandas 1, 2, 3, 4, 5 y 7; además se considera la temperatura (banda 6), el índice de nieve de diferencia normalizada (NSDI, por la sigla en inglés de *normalized difference*

snow index) y el índice de vegetación de diferencia normalizada (NDVI).

Davis *et al.* (2001) desarrollaron un modelo de detección, para lo cual usaron la banda roja para identificar el brillo de las nubes, la banda infrarrojo térmico para el cálculo de la temperatura y determinaron la blancura de las nubes calculando el NDVI.

Tian *et al.* (1998) plantearon un modelo de red neuronal que atiende las variaciones temporales de las nubes. Para ello utilizaron un modelo gaussiano que simplifica el número de neuronas y facilita el procesamiento de la información; posteriormente calcula el conjunto de parámetros de entrenamiento empleando el enfoque de estimación de máxima verosimilitud (EM).

En este artículo se presenta la metodología empleada para detectar nubes y sombras usando imágenes del satélite Landsat. Inicialmente se obtuvo el NDVI y el tasseled cap, como indicadores de las cubiertas diferentes a las nubes; posteriormente se empleó el análisis de red neuronal perceptrón multicapa (MLP) para la identificación de las cubiertas y la posterior generación de la máscara de nubes.

Materiales y métodos

Los datos de entrada son 12 imágenes satelitales del Landsat 7 ETM+ correspondientes a los años de 2000, 2001 y 2002, del municipio de Puerto Berrío en Antioquia, disponibles en la página <http://reverb.echo.nasa.gov/>. Las características básicas de este sensor se presentan en la tabla 1.



Tabla 1. Características de los datos del sensor Landsat 7

| | Descripción | Longitud de onda (μm) | Resolución (m) |
|---------|-------------|------------------------------------|----------------|
| Banda 1 | Azul | 0,45-0,52 | 30 |
| Banda 2 | Verde | 0,53-0,61 | 30 |
| Banda 3 | Rojo | 0,63-0,69 | 30 |
| Banda 4 | IRC | 0,78-0,90 | 30 |
| Banda 5 | SIR | 1,55-1,75 | 30 |

Fuente: United States Geological Survey (USGS), 2015.

Durante el proceso de clasificación se llevaron a cabo cuatro pasos principales, que se detallan en los apartados siguientes: 1) preprocesamiento de imágenes, 2) cálculo del índice de vegetación de diferencia normalizado, 3) transformación tasseled cap, 4) clasificación de la imagen con redes neuronales perceptrón multicapa (MLP), 5) generación de la máscara de nubes y 6) validación del algoritmo.

Preprocesamiento

Consiste en convertir los valores de la imagen (niveles digitales [ND]) a niveles de radiancia en $\text{W}/\text{m}^2 \text{sr} \mu\text{m}$ para corregir las anomalías que los afectan, como, por ejemplo, la distorsión del aspecto, las fallas en el sensor y las anomalías atmosféricas. Posteriormente se realiza el cálculo de radiancia a reflectancia para convertir los ND en parámetros físicos, y de esa manera conocer el comportamiento físico de una cubierta observada de modo absoluto. Estas correcciones se hacen con el fin de que la información que proporcionan los ND sea confiable y lo más parecida a la realidad de la zona.

Cálculo del índice de vegetación de diferencia normalizada

Se implementa para mejorar la discriminación de cubiertas vegetales, medir el vigor de las plantas y la producción de la biomasa (Gitelson, Peng & Huemmrich, 2014). Además caracteriza la evolución del estado del suelo a lo largo del tiempo debido a los cambios en su uso, estación fenológica, situación hídrica del territorio y ambiente climático de la zona. Este índice se deriva de la combinación de bandas captadas en la zona del rojo y del infrarrojo cercano del espectro del satélite Landsat 7 (ecuación 1).

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad (1)$$

Donde:

NDVI = índice de vegetación de diferencia normalizado

NIR = reflectancia de la banda infrarrojo cercano

R = reflectancia de la banda roja



Los valores obtenidos del NVDI varían entre -1 y 1, donde los valores positivos corresponden a zonas de vegetación, puesto que las plantas absorben fuertemente la radiación en la región visible del espectro, mientras que los valores negativos generados por una mayor reflectancia en el infrarrojo cercano pertenecen a nubes, nieve, agua, zonas de suelo desnudo y rocas (Hmimina *et al.*, 2013).

Cálculo de la transformación tasseled cap

El TC se emplea para analizar y representar cambios de vegetación y de desarrollo urbano detectados por el sensor del satélite Landsat ETM+. Reduce la información contenida en las bandas multispectrales azul, verde, rojo, infrarrojo cercano y medio a tres componentes principales: brillo, verdor y humedad. La transformación tasseled cap se puede expresar empleando la ecuación 2:

$$TWC = (B1 * 0.1509) + (B2 * 0.1973) + (B3 * 0.3279) + (B4 * 0.3406) + (B5 * 0.7112) + (B7 * 0.4572) \quad (2)$$

Donde:

TWC = tasseled cap

B1 = banda azul del Landsat 7 ETM+

B2 = banda verde del Landsat 7 ETM+

B3 = banda roja del Landsat 7 ETM+

B4 = banda infrarrojo cercano del Landsat 7 ETM+

B5 = banda infrarrojo medio Landsat 7 ETM+

B7 = banda infrarrojo cercano del Landsat 7 ETM+

Clasificación de la imagen con redes neuronales perceptrón multicapa

La red perceptrón multicapa (MLP) se caracteriza por su capacidad de procesamiento. Su potencial reside en la habilidad para entrenar la red y superar aquellas con una sola capa de salida, y por ello ha demostrado su capacidad para trabajar con éxito en un amplio rango de aplicaciones, incluyendo clasificación de imágenes, sistemas de base de conocimiento, codificación de información y muchos otros problemas de clasificación y percepción (Besogain Olabe, 2008). Para su configuración se definen los siguientes parámetros: el número de capas, el número de neuronas por capa y el algoritmo de aprendizaje.

Número de capas

Para una red MLP se recomienda utilizar tres capas: una entrada, una capa de salida y una capa oculta (Caicedo & López, 2009). El utilizar más de una capa oculta aumenta drásticamente la carga computacional de la red, razón por la cual se plantea una configuración de tres capas.

En la capa de entrada se presentan a la red los datos que, con certeza, corresponden al fenómeno que se desee identificar. En este sentido, se realiza un muestreo de más de cincuenta puntos sobre las coberturas de nubes, sombras, vegetación, agua y zona urbana, para identificar el valor de cada pixel por cada una de ellas, en las bandas visibles, infrarrojo cercano, el NDVI y las tres componentes del tasseled cap (brillo, verdor y humedad), para un total de 8 posibles patrones de entrenamiento con los cuales se podría entrenar la red.



Las muestras fueron obtenidas considerando dos parámetros con una cantidad igual de puntos o muestras por clase para evitar tendencias en la clasificación y que correspondieran a diferentes fechas.

En la capa oculta se condensan las variables de la capa de entrada con los respectivos pesos asignados aleatoriamente; estos reflejan la conexión y fortaleza entre las neuronas. Posteriormente se aplica una función de transferencia o de activación, la cual asocia aleatoriamente un peso a cada una de las variables de entrada y es responsable de la bondad del comportamiento de la red neuronal. Para este caso, la función a emplear es de tipo sigmoideal (ecuación 3), pues garantiza la capacidad de procesamiento no lineal (Flórez & Fernández, 2008).

$$Y_n = f(x) = Th(x) = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (3)$$

Donde:

- Y_n, f, Th(x)** = respuesta ante la entrada x
- x** = valor de entrada al nodo
- n** = número que identifica la capa correspondiente a la neurona

La capa de salida muestra la respuesta de la red a una entrada. En ella se utiliza la función de activación tipo lineal (ecuación 4) y se definen dos salidas (nube y cualquier otra cobertura), que puede ser sombra, vegetación, agua o zona urbana, etc.

$$Y_n = f(x) = x \quad (4)$$

Número de neuronas en cada capa

Cada capa de la red está compuesta por neuronas que permiten su funcionamiento; así, por ejemplo, en la capa de entrada corresponden a los 8 patrones de entrenamiento, y por lo tanto para ella se define un máximo de 8 neuronas.

Para identificar si el número de neuronas de la capa de entrada era adecuado, se realizó el entrenamiento de varias redes neuronales, definiendo tres configuraciones diferentes (tabla 2). Donde B1 hasta B4 hacen referencia a las bandas azul, verde, roja e infrarrojo cercano del Landsat ETM+ respectivamente, y las siglas NDVI, B, V y H corresponden al índice de vegetación y a los tres componentes de la transformación tasseled cap (brillo, verdor y humedad).

Tabla 2. Configuraciones para la capa de entrada

| Configuración | N° de neuronas en la capa de entrada | B1 | B2 | B3 | B4 | NDVI | B | V | H |
|---------------|--------------------------------------|----|----|----|----|------|---|---|---|
| 1 | 4 | X | X | X | X | | | | |
| 2 | 4 | | | | | X | X | X | X |
| 3 | 8 | X | X | X | X | X | X | X | X |



En el caso del número de neuronas para la capa oculta, se evaluó su funcionamiento con la mitad de la dimensión del vector de entrada, es decir, se inició el proceso con tres neuronas y se fueron aumentando paulatinamente, hasta verificar que su desempeño mejorara utilizando el error medio cuadrático (EMC) como indicador. En el momento en que los errores no decrecieron sustancialmente, se definió el número de neuronas que conformaría esta capa.

En la capa de salida se definen dos neuronas: la primera se especializa en la detección de nubes, mientras que la otra se encarga de la clasificación de otras coberturas diferentes.

Algoritmos de aprendizaje

Para determinar el algoritmo de aprendizaje que configurará la red, se evaluó el rendimiento de los algoritmos: backpropagation, gradiente descendente con eta variable y Levenberg-Marquardt. El criterio de decisión se fundamenta en la velocidad de convergencia de cada uno de ellos durante el proceso de aprendizaje, es decir, hacer que los pesos sinápticos de la red se adapten de una forma más eficiente y rápida, buscando el menor EMC.

La figura 1 muestra el comportamiento del EMC de validación con respecto al número de iteraciones.

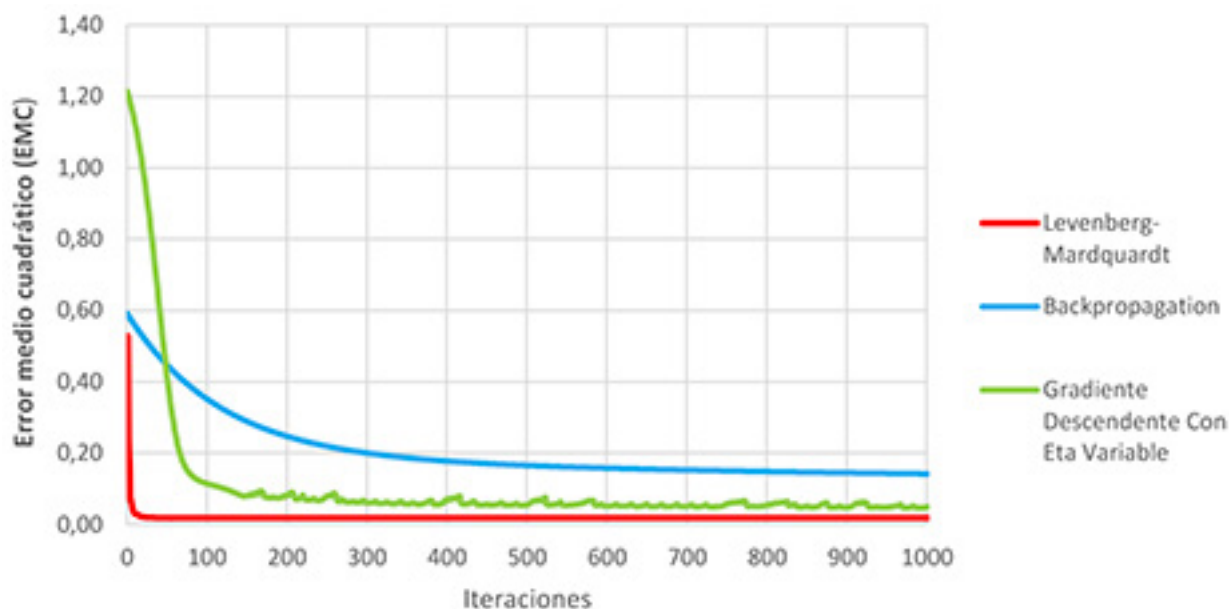


Figura 1. Rendimiento de los algoritmos de aprendizaje de la red respecto al número de iteraciones y el EMC
Fuente: elaboración propia.

Generación de la máscara de nubes

Finalmente se realizó la simulación con cada variable utilizando la red obtenida. Estas variables, al estar estructuradas de forma matricial, fueron organizadas en forma de vector para poder realizar la simulación. El resultado de esta simulación fue una matriz de dos columnas por el total de píxeles que componen la imagen con valores de ceros y unos, donde el valor cero indica no nube y el valor de uno expresa presencia de nubes. Posterior a esto se reorganizaron los datos para recuperar la forma de matriz y se hizo una reclasificación de los valores, en la cual las nubes se establecieron como uno y el resto de clases se definieron como cero, obteniendo de esta manera la máscara de nubes.

Validación

La validación de máscaras de nubes es un proceso complejo, principalmente por la falta de máscaras de nubes confiables para comparar (Zhu & Woodcock, 2012). Debido a esto, la evaluación de la calidad de un producto de máscara de nubes debe considerarse como una comparación de productos, en lugar de una validación.

En este estudio, el proceso de validación consistió en la implementación de diversos mecanismos de comparación entre los productos de máscaras de nubes de RNA y el método de umbrales empleados en anteriores estudios. Estos corresponden a comparaciones visuales e índices de error y concordancia.

Resultados

Configuración de la red neuronal

Como se mencionó anteriormente, se definieron 8 posibles patrones en la capa de entrada (tabla 2). A partir de los datos de entrenamiento, se realizó el proceso de aprendizaje con diferente número de neuronas en la capa oculta, con el fin de identificar qué configuración permite obtener un menor EMC. El cálculo del EMC se realizó a partir del 30% del total de muestras empleadas para el entrenamiento.

La figura 2 muestra el comportamiento del EMC de validación con respecto al número de neuronas en la capa de entrada y la capa oculta. Para la configuración de 4 neuronas en la capa de entrada (B1-B4), se observa un decrecimiento constante hasta la quinta neurona; a partir de esta, su EMC no disminuye significativamente y llega a un mínimo de 0,0378 con 12 neuronas en la capa oculta. En cuanto la configuración con 4 (NDVI, brillo, verdor y humedad) y 8 (B1-B4, NDVI y brillo, verdor y humedad) neuronas en la capa de entrada, se observa que el comportamiento es semejante, ya que los valores de EMC presentan casi el mismo decrecimiento con cada una de las neuronas en la capa oculta. Sin embargo, la configuración con 8 neuronas en la capa de entrada presenta el EMC más bajo, cuyo valor es 0,0339; a partir de este los decrecimientos no son significativos.

Lo anterior indica que los 8 componentes en la capa de entrada, además de presentar el EMC más bajo de los tres posibles conjuntos de entrada, brinda a la red la información complementaria y significativa para mejorar la clasificación e identificar



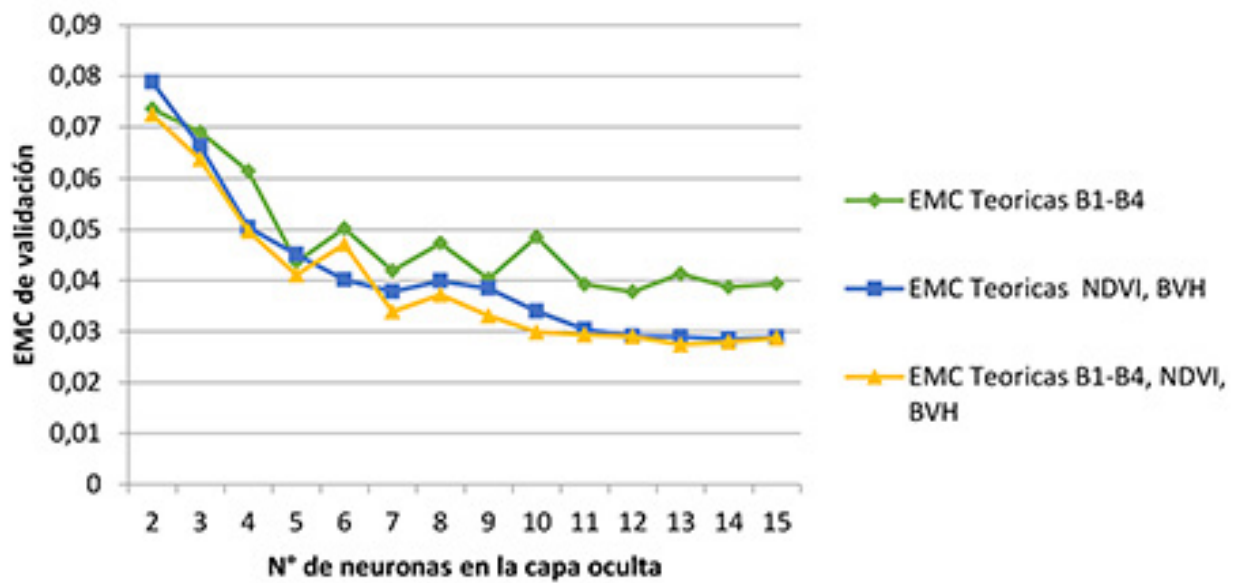



Figura 2. Comportamiento del EMC respecto al número de neuronas en la capa de entrada y la capa oculta
Fuente: elaboración propia.



las nubes de manera eficiente. Por tanto se define que la configuración más adecuada para la detección de nubes corresponde a 8 neuronas en la capa de entrada, 7 neuronas en la capa oculta y 2 neuronas en la de salida.

Figura 3. Comparación entre la imagen original y los métodos de clasificación empleados
Fuente: elaboración propia.



Análisis visual entre la red neuronal y el método de umbrales

Para establecer la precisión de los resultados obtenidos se realizó un análisis entre la imagen original, la red neuronal MLP y el método de umbrales desarrollados en estudios anteriores. La figura 3 presenta los resultados para cada caso.

En la figura 3 se observa que las tres máscaras presentan un comportamiento similar en la identificación de las nubes. No obstante, el método que presentó mayor dificultad fue el de umbrales (figura 3b), ya que evidencia cierto ruido entre la nube, la zona urbana y en los cuerpos de agua, sobrestimando la presencia de nubes en el sector y, por tanto, las sombras asociadas a ellas. Por su parte, el método de RNA (figura 3c) discriminó la mayor parte de las nubes presentes de la zona. Con la claridad, el método de umbrales presentó dificultades en los contornos de las nubes, mientras que el RNA fue mucho más preciso. La máscara de umbrales no delimita la zona urbana, considerando nubes sobre esta superficie, cuando en realidad estas coberturas se encuentran libres de nubes, tal como se aprecia en la figura 3a.

Índices globales respecto a datos muestreados

Se realizó un muestreo sobre cada imagen, en el cual se hizo una verificación

visual para cada pixel, evaluando la presencia o ausencia de nubes. Con el muestreo se obtuvieron 3383 pixeles sin nubosidad y 4517 con nubosidad.

La tabla 3 muestra la matriz de confusión obtenida para las máscaras de RNA y el método de umbrales respectivamente. Se observa que el método que presentó menor sobrestimación es el de RNA con 13 pixeles, mientras que el que pasó por alto la mayor cantidad de pixeles con nubes fue el de umbrales con 940 pixeles y el que presentó menor confusión fue el de RNA con 125 pixeles.

Tabla 3. Matriz de confusión para los datos muestreados de la máscara de RNA y de IBCM

| | RNA | | Umbrales | |
|---------|---------|------|----------|------|
| | No nube | Nube | No nube | Nube |
| No nube | 3370 | 13 | 3319 | 64 |
| Nube | 125 | 4392 | 940 | 3577 |

La tabla 4 muestra el error global de clasificación y los errores de omisión para los dos métodos a partir de las matrices de confusión. El método que presentó el menor error global fue el de RNA, con un 1,75%. Se observa que el RNA presentó los menores errores de omisión y comisión para ambas clasificaciones (nube y no nube). Por otro lado, se observa que el método de umbrales presentó errores de omisión en pixeles libres del 22,07% y comisión de pixeles nubosos del 20,81%.

Tabla 4. Error global de clasificación, errores de omisión y comisión y coeficiente kappa para los tres métodos

| Método | Error global (%) | Comisión libre (%) | Omisión libre (%) | Comisión nube (%) | Omisión nube (%) |
|----------|------------------|--------------------|-------------------|-------------------|------------------|
| RNA | 1,75 | 0,38 | 3,58 | 2,77 | 0,30 |
| Umbrales | 12,71 | 1,89 | 22,07 | 20,81 | 1,76 |



Cálculo de coeficiente kappa

Como segundo método de comparación, se utilizó el coeficiente kappa para expresar los resultados estadísticamente. El coeficiente kappa asigna valores entre -1 y +1: mientras más cercano a 1, el grado de precisión es mayor; por el contrario, mientras más cercano a -1, mayor es

el grado de discordancia interobservador. Un valor de $\kappa = 0$ refleja que la concordancia observada es precisamente la que se espera. La tabla 5 presenta los valores de coeficiente kappa obtenidos en la clasificación para el total de imágenes empleadas en el estudio, a partir del muestreo realizado para la validación.

Tabla 5. Comparación de redes y métodos de clasificación con coeficiente kappa

| ID | Imagen | Número de muestras | Umbral | RN | Mejor método |
|----|------------------|--------------------|--------|------|--------------|
| 1 | LE70080562000099 | 200 | 0,88 | 0,73 | Umbral |
| 2 | LE70080562000147 | 263 | 0,97 | 0,98 | RN |
| 3 | LE70080562000227 | 219 | 0,96 | 0,98 | RN |
| 4 | LE70080562000275 | 208 | 0,91 | 0,83 | Umbral |
| 5 | LE70080562001021 | 171 | 1,00 | 1,00 | Ambos |
| 6 | LE70080562001053 | 149 | 0,93 | 0,98 | RN |
| 7 | LE70080562001069 | 200 | 0,97 | 0,97 | RN |
| 8 | LE70080562001101 | 200 | 0,90 | 0,71 | Umbral |
| 9 | LE70080562001213 | 202 | 0,72 | 0,94 | RN |
| 10 | LE70080562001309 | 207 | 0,86 | 0,98 | RN |
| 11 | LE70080562001357 | 172 | 0,95 | 0,98 | RN |
| 12 | LE70080562002152 | 170 | 0,77 | 1,00 | RN |

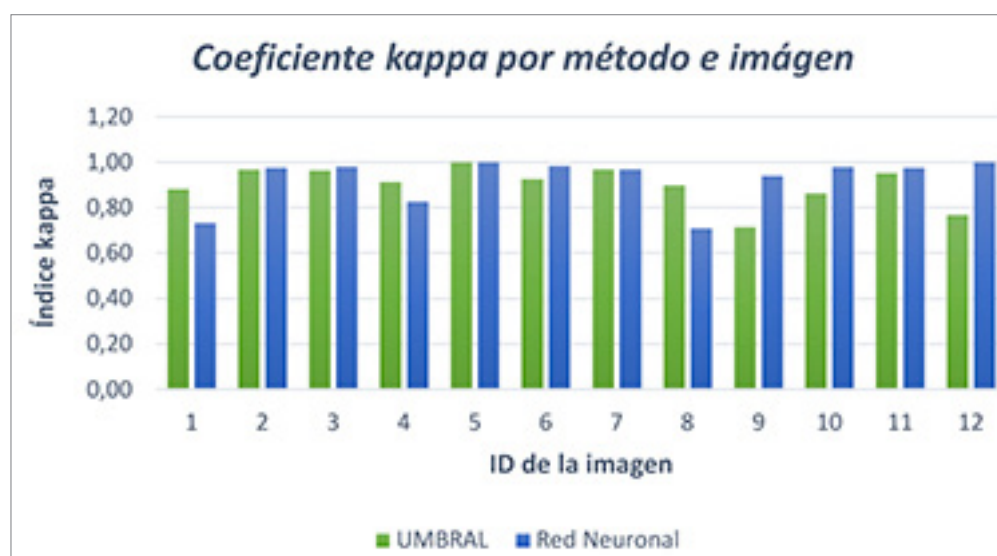


Figura 4. Comparación entre métodos de clasificación empleando el coeficiente kappa

Fuente: elaboración propia.

En cuanto a la concordancia con los datos muestreados, los resultados fueron de 0,96 y 0,75 para RNA y umbrales respectivamente. De acuerdo con Landis y Koch (1977), quienes establecen la valoración del coeficiente kappa, se dice que la concordancia es muy buena para RNA y buena para el método de umbrales. Con lo anterior podemos afirmar que el número de muestras para entrenar la red es indiferente.

Discusión

Con respecto a la precisión, Taravat *et al.* (2015) realiza una evaluación de la precisión de clasificación de la RNA MLP con una exactitud global promedio del 88,96% y unos errores de omisión y comisión del 11,04% y 3,88% respectivamente. En el caso del método propuesto en este proyecto, la exactitud global para RNA fue del 91%, un error de omisión del 0,30% y de comisión del 2,77%. No obstante, estos indicadores no permiten la determinación de la precisión del método en la totalidad de las imágenes porque fueron extraídos a partir de un muestreo de píxeles.

Pese a que diferentes autores implementan el índice de vegetación junto con el tasseled cap en una capa de entrada de la red por separado, en el desarrollo de este método se demostró que la combinación de ellos, junto con las bandas visibles e infrarrojo cercano, clasifica satisfactoriamente todas las variables planteadas, puesto que el NDVI, junto con el componente de verdor del tasseled, discriminó las diferentes coberturas de la zona, y los componentes de brillo y humedad del tasseled realizaron un aporte importante en la detección de nubes junto con las demás bandas.

Al comparar estos resultados con los obtenidos en estudios como el de Torres *et al.* (2003), que establecen diferentes números de neuronas para los tipos de nubes (cirros, cúmulos y extracúmulos), en esta metodología se estableció solo una capa oculta con 7 neuronas para todas las imágenes en general, lo que posiblemente generalizaría y además limitaría la precisión del método al caracterizar diferentes clases de nubes.

Diferentes autores evitan el uso del NDVI y el tasseled cap como elementos para caracterizar las nubes, puesto que generan confusión al detectar las sombras usando el método de umbrales, y además solo se obtiene una precisión global no mayor al 0,9% de tolerancia. Mientras tanto, el método de redes neuronales es más robusto y permisivo a cualquier variable o elemento que se desee integrar y alcanza precisiones mejores, siempre y cuando el número de neuronas que conforman la red sea adecuado.

Conclusiones

El proceso permitió clasificar los elementos de nubes para un total de 7 neuronas en la capa oculta y con menos de cien iteraciones para cada una de las imágenes empleadas en el estudio y un EMC del 0,0339, lo que indica que el método es muy robusto y eficiente para este tipo de tareas y alcanza una exactitud global del 91% comparado con el método de umbrales desarrollado en estudios anteriores, cuya exactitud fue de 87,37%.

Definir las variables de entrada que comprendería la red es un proceso dispendioso que implica mucho tiempo, pero, a pesar de ello, se obtuvo un modelo muy acorde con la realidad, que permitió



conocer de manera exacta y precisa todas las variables que fueron consideradas para el desarrollo del proyecto con ayuda del coeficiente kappa.

El algoritmo de enmascaramiento para la nube con redes neuronales muestra un buen desempeño en la detección de nubes al combinar los tres componentes tasseled cap normalizados, más la información derivada de las bandas espectrales del satélite Landsat y el índice de vegetación.

El número de iteraciones de la red está ligado al límite de error permitido por el

operador, es decir, a la exactitud o precisión que se quiera obtener en los resultados.

Es importante destacar que la determinación de un número apropiado de neuronas ocultas en un sistema de red neuronal eficaz es bastante difícil. Un número insuficiente de neuronas en la capa oculta puede no representar la relación no lineal entre las variables de entrada y reducir la velocidad de convergencia. Por otra parte, el excedente de neuronas en la capa oculta puede generar cálculos inútiles en el proceso de aprendizaje.



Bibliografía

- Behling, R., Bochow, M., Förster, S., Roessner, S. & Kaufmann, H. (2015). Automated GIS-based derivation of urban ecological indicators using hyperspectral remote sensing and height information. *Ecological Indicators*, 48, 218-234. <http://doi.org/10.1016/j.ecolind.2014.08.003>.
- Besogain Olabe, X. (2008). *Redes neuronales artificiales y sus aplicaciones* (libro del curso). Disponible en: https://ocw.ehu.eus/pluginfile.php/9047/mod_resource/content/1/redes_neuro/contenidos/pdf/libro-del-curso.pdf.
- Davis, A. B., Brumby, S. P., Harvey, N. R., Lewis, H. K. & Rohde, C. A. (2001). Genetic refinement of cloud-masking algorithms for the multi-spectral thermal imager (MTI). *Proc. Geoscience and Remote Sensing Symposium (IGARSS), 2001 IEEE International Symposium*, Sydney, Australia, 9-13 July.
- Caicedo Bravo, E. & López Sotelo, J. (2009). *Una aproximación práctica a las redes neuronales artificiales*. Cali: Programa Editorial Universidad del Valle.
- Fisher, G. & Danaher, T. (2011). Automating woody vegetation change detection at regional scales: The problem of clouds and cloud shadows. *34th International Symposium on Remote Sensing of Environment*, Sydney, Australia, 10-15 April. Recuperado de <http://www.isprs.org/proceedings/2011/ISRSE-34/211104015Final00271.pdf>.
- Flórez López, R. & Fernández Fernández, J. (2008). *Las redes neuronales artificiales: fundamentos teóricos y aplicaciones prácticas*. La Coruña: Netbiblo.
- Gitelson, A., Peng, Y. & Huemmrich, K. F. (2014). Relationship between fraction of radiation absorbed by photosynthesizing maize and soybean canopies and NDVI from remotely sensed data taken at close range and from MODIS 250m resolution data. *Remote Sensing of Environment*, 147, 108-120. doi: 10.1016/j.rse.2014.02.014.
- Hagolle, O., Huc, M., Villa Pascual, D. & Dedieu, G. (2010). A multi-temporal method for cloud detection, applied to Formosat-2, Venus, Landsat and Sentinel-2 images. *Remote Sensing of Environment*, 114(8), 1747-1755. <http://dx.doi.org/10.1016/j.rse.2010.03.002>.
- Hmimina, G., Dufrêne, E., Pontailier, J. Y., Delpierre, N., Aubinet, M., Caquet, B., De Grandcourt, A. et al. (2013). Evaluation of the potential of MODIS satellite data to predict vegetation phenology in different biomes: an inves-





- tigation using ground-based NDVI measurements. *Remote Sensing of Environment*, 132, 145-158. doi: <http://dx.doi.org/10.1016/j.rse.2013.01.010>.
- Landis, J. & Koch, G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33(1), 159-174.
- Lee, J., Weger, R. C., Sengupta, S. K. & Welch, R. M. (1990). A neural network approach to cloud classification. *IEEE Transactions on Geoscience and Remote Sensing*, 28(5), 846-856. doi: 10.1109/36.58972.
- Lewis, H. G., Cote, S. & Tatnall, A. R. L. (1995). A neural network approach to cloud classification from multi-temporal satellite imagery. In *Fourth International Conference on Artificial Neural Networks* (pp. 116-121), Piscataway, USA, Institute of Electrical and Electronics Engineers. doi: 10.1049/cp:19950539.
- Li, D. & Tang, P. (2013). A sensor-based scheme for assessing cloud coverage in HJ-1 CCD data. In *Proc. Geoscience and Remote Sensing Symposium (IGARSS), 2013 IEEE International Symposium*. doi: 10.1109/IGARSS.2013.6721218.
- Li, D., Tang, P., Ge, Y. & Yang, J. (2012). An adaptive and automated method for masking cloud on Landsat data. *Proc. Geoscience and Remote Sensing Symposium (IGARSS), 2012 IEEE International Symposium*. doi: 10.1109/IGARSS.2012.6352687.
- Panem, Ch., Baillarin, S., Latry, C., Vadon, H. & Dejean, P. (2005). Automatic cloud detection on high resolution images. In *Proc. Geoscience and Remote Sensing Symposium (IGARSS), 2005 IEEE International Symposium*. doi: 10.1109/IGARSS.2005.1526222.
- Qi, Y., Li, F., Liu, Z. & Jin, G. (2014). Impact of understorey on overstorey leaf area index estimation from optical remote sensing in five forest types in northeastern China. *Agricultural and Forest Meteorology*, 198-199, 72-80. doi: 10.1016/j.agrformet.2014.08.001.
- Sano, E. E., Ferreira, L. G., Asner, G. P. & Steinke, E. T. (2007). Spatial and temporal probabilities of obtaining cloud-free Landsat images over the Bra-



zilian tropical savanna. *International Journal of Remote Sensing*, 28(12), 2739-2752. <http://dx.doi.org/10.1080/01431160600981517>.

Tapakis, R., & Charalambides, A. G. (2013). Equipment and methodologies for cloud detection and classification: A review. *Solar Energy*, 95, 392-430.

Taravat, A., Proud, S., Peronaci, S., Del Frate, F. & Oppelt, N. (2015). Multilayer perceptron neural networks model for Meteosat second generation SEVIRI daytime cloud masking. *Remote Sensing*, 7(2), 1529-1539. doi:10.3390/rs70201529.

Tian B., Azimi-Sadjadi, M. R., Vonder Haar, T. H. & Reinke, D. (1998). A temporal adaptive probability neural network for cloud classification from satellite imagery. *1998 IEEE International Joint Conference on Neural Networks Proceedings. IEEE World Congress on Computational Intelligence*. doi: 10.1109/IJCNN.1998.687118.

Torres Arriaza, J. A., Guindos Rojas, F., Peralta López, M. & Cantón, M. (2003). An automatic cloud-masking system using backpro neural nets for AVHRR scenes. In *IEEE Transactions on Geoscience and Remote Sensing*, 41(4), 826-831. doi: 10.1109/TGRS.2003.809930.

Van der Meer, F. D., Van der Werff, H., Van Ruitenbeek, F., Hecker, C. A., Bakker, W. H., Noomen, M. F., Van der Meijde, M., Carranza, E. J., Boudewijn de Smeth, J. & Woldai, T. (2012). Multi-and Hyperspectral Geologic Remote Sensing: A Review. *International Journal of Applied Earth Observation and Geoinformation*, 14(1), 112-128.

Van Westen, C. J. (2013). Remote sensing and GIS for natural hazards assessment and disaster risk management. In: Shroder, J. y Bishop, M. P. (Eds.), *Treatise on Geomorphology* (vol. 3, Remote Sensing and GIScience in Geomorphology, pp. 259-298). San Diego, CA: Academic Press.

Walder, P. & Maclaren, I. (2000). Neural network based methods for cloud classification on AVHRR images. *International Journal of Remote Sensing*, 21(8), 1693-1708. <http://dx.doi.org/10.1080/014311600209977>.

Zhu, Z. & Woodcock, C. E. (2012). Object-based cloud and cloud shadow detection in Landsat imagery. *Remote Sensing of Environment*, 118, 83-94.

