

## Extracción de parámetros de nubes mediante redes neuronales artificiales.

Abidán Cerdeña, Albano González y Juan C. Pérez

Dep. Física Fundamental y Exp., Electrónica y Sistemas. Universidad de La Laguna. Tenerife. Avda. Francisco Sánchez s/n, 38200 La Laguna, Tenerife, Canarias. [acerdana@ull.es](mailto:acerdana@ull.es), [aglezf@ull.es](mailto:aglezf@ull.es), [jcperez@ull.es](mailto:jcperez@ull.es).

### Resumen

En este trabajo se presenta un método para la extracción de las propiedades microfísicas y microfísicas de estratocúmulos marinos a partir de imágenes obtenidas por el sensor NOAA-AVHRR. Este método se basa en la inversión de un modelo de transferencia radiativa llevada a cabo a través del uso de redes neuronales artificiales. Antes de proceder a su aplicación a imágenes nocturnas y diurnas, fue necesario hallar la estructura óptima de las redes en ambos casos. Los resultados obtenidos se aproximan con éxito a las medidas *in situ* tomadas en Tenerife que se usaron para la validación del método.

### 1. Introducción

Las nubes ejercen una gran influencia sobre los procesos radiativos que se desarrollan en la atmósfera [1]. Debido a su importancia, para llevar a cabo un estudio de la evolución climática terrestre es necesario un análisis de las diferentes propiedades de las nubes. En este sentido, son numerosos los trabajos realizados en las últimas décadas a cerca de su comportamiento radiativo, y el desarrollo de métodos para la extracción de sus propiedades ópticas y microfísicas. Las técnicas de teledetección por satélite han llegado a convertirse en una herramienta muy importante para la caracterización de las nubes y la determinación de sus efectos climáticos a escala global, permitiendo la determinación de parámetros nubosos tales como la temperatura, el radio efectivo o el contenido en agua. Ciertas características de los estratocúmulos marinos, como pueden ser su persistencia temporal o su gran extensión horizontal, además de convertirlos en importantes moduladores del equilibrio radiativo atmosférico, facilitan la aplicabilidad de estas técnicas de teledetección a su análisis.

El objetivo de este artículo es proporcionar un método para la determinación de los parámetros característicos de los estratocúmulos marinos, tales como el espesor óptico, el radio efectivo y su temperatura. Para ello se hará uso de imágenes diurnas y noc-

turnas tomadas por el sensor AVHRR, a bordo de los satélites NOAA. En primer lugar se explicará el modelo de transferencia radiativa utilizado, para posteriormente introducir las redes neuronales como herramienta para la extracción de parámetros. Finalmente se presentarán los resultados obtenidos y las conclusiones.

### 2. Modelo de transferencia radiativa

Para el cálculo teórico de las radiancias que alcanzan la parte superior de la atmósfera es necesario el uso de un modelo numérico en el que se tenga en cuenta una serie de aproximaciones que permitan caracterizar el sistema formado por la cubierta nubosa, la superficie subyacente y la atmósfera. En particular, consideraremos un modelo de nube plano-paralela y verticalmente homogénea.

En este estudio se utiliza el paquete libRadtran (Kylling and Mayer, 1993-2004, accesible en <http://www.libradtran.org>) para el cálculo de radiancias, el cual hace uso del método DISORT 2.0 [2]. Este método divide la atmósfera en un conjunto de capas homogéneas adyacentes, y calcula los efectos de la absorción, dispersión y emisión dentro de cada una de ellas. También se recurre a la teoría de Mie para el cálculo de ciertos parámetros tales como el albedo de scattering simple o la distribución angular de la energía dispersada, asumiendo gotas de agua esféricas cuya distribución de tamaños obedece a una distribución de tipo gamma. La absorción molecular fue parametrizada a través del modelo de transferencia radiativa SBDART [3], mientras que el scattering Rayleigh se calculó de acuerdo con el trabajo desarrollado por Nicolet [4]. En cuanto a los perfiles atmosféricos de presión, temperatura y concentración de gases se tomaron de la atmósfera estándar para latitudes medias compilada por Anderson et al [5]. En relación a la superficie, se ha tomado la función de reflectividad bidireccional para el mar sugerida por Cox y Munk [6].

### 3. Extracción de parámetros

Tal y como se ha señalado anteriormente, nuestro objetivo es la determinación de los parámetros de los estratocúmulos marinos. Para ello es necesario invertir el modelo explicado en la sección previa. Sin embargo, debido a la complejidad de dicho modelo, para llevar a cabo esta inversión se ha de recurrir a métodos numéricos. En particular, se pretende evaluar la capacidad de las técnicas basadas en redes neuronales para extraer estos parámetros.

#### 3.1. Redes neuronales

Una de las principales características de las redes neuronales es su habilidad para establecer una relación entre las variables de entrada y las de salida. Esta relación se crea tras un proceso de aprendizaje durante el cual se introduce en la red una serie de valores de entrada y los correspondientes resultados que debieran obtenerse. Tras este proceso de entrenamiento la red adquiere la capacidad de generalizar ante cualquier conjunto de valores nuevos que se le presenten.

Las neuronas que conforman la red están conectadas entre sí a través de uniones caracterizadas por pesos. Son estos parámetros, junto con los valores de *bias* asociados a cada unidad, los que definen la configuración de la red y la bondad de los resultados obtenidos. Cada nodo transforma la suma pesada de las salidas de las neuronas de la capa anterior de acuerdo con una función de transferencia determinada. A la hora de seleccionar esta función de transferencia principalmente se ha de tener en cuenta el problema que se desea resolver. En este caso, la función debía ser continua y monótona, eligiéndose la función logística.

Uno de los parámetros más importantes a considerar cuando se procede al diseño de una red neuronal es el número óptimo de unidades ocultas. Así, un número excesivo o deficiente de las mismas influye decisivamente en los resultados obtenidos, produciéndose una memorización de los patrones de entrenamiento o un aprendizaje pobre, respectivamente. En ambos casos la capacidad de generalización de la red se ve drásticamente disminuida. En cuanto a la arquitectura de la red propuesta, además de la capa de entrada y la de salida, se usaron dos capas ocultas, facilitándose así el ajuste de máximos y mínimos locales de la función.[7] El incremento del tamaño de la red lleva consigo una disminución de la probabilidad de alcanzar la red óptima, aumentando la importancia del problema del mínimo local.

Las redes neuronales fueron entrenadas usando el algoritmo de *retropropagación con momento*, en el que la modificación de la matriz de pesos viene dada por la expresión:

$$W(t+1) = W(t) - \eta \cdot \nabla(E) + \mu \cdot \Delta(W(t-1)) \quad (1)$$

donde  $W(t)$  es la matriz de pesos en la iteración  $t$ ,  $\mu$  el momento,  $\eta$  el ritmo de aprendizaje y  $\nabla(E)$  el gradiente de la superficie de error definida por el conjunto de pesos.

El aprendizaje de la red se realizó con un entrenamiento de tipo *on-line*, en el que la actualización de la matriz de pesos se hace una vez que todos los patrones hayan sido presentados a la red.

Los patrones de entrenamiento obtenidos con el modelo de transferencia radiativa fueron divididos en dos grupos: un conjunto de entrenamiento, y otro de validación[8]. El primero de ellos se usa para ajustar los pesos, y el segundo para evaluar la capacidad de generalización de la red durante dicho proceso.

### 4. Aplicación de las redes neuronales

El sensor AVHRR posee cinco canales, dos situados en el visible y tres en el infrarrojo, entre los cuales destaca la sensibilidad del canal 3 (3.78  $\mu\text{m}$ ) al tamaño de las gotas. Debido a su ubicación espectral, la radiancia recibida por este sensor a través de una nube semitransparente durante el día se puede considerar como suma de tres contribuciones: La radiación solar reflejada por la nube, aquella que es emitida por la propia capa nubosa, y la que proviene de la superficie subyacente.

En cuanto a la contribución debida a la emisión de la superficie, para calcularla se hace uso de aquellos píxeles de la imagen que se puedan considerar despejados. Estos datos son usados para interpolar las temperaturas de brillo a los restantes píxeles en los tres canales infrarrojos.

La arquitectura de la red neuronal variará según se esté tratando con imágenes de satélite nocturnas o diurnas. Para las primeras, únicamente se tendrá información en los canales infrarrojos 3, 4 y 5, donde la radiancia del canal 3 es debida sólo a la emisión térmica de la superficie terrestre y la atmósfera. Por lo tanto, en este caso la red necesita seis entradas, las temperaturas de brillo de la superficie para los tres canales, y las otras tres medidas por el sensor. Las salidas son tres, una por cada parámetro nuboso a calcular. Para la fase de aprendizaje se creó una *lookup-table* con 30000 patrones, dividiéndose en dos grupos: el de entrenamiento con 20000 datos, y el de valida-

ción con 10000. La determinación de la red neuronal óptima se llevó a cabo entrenando varias de diferentes tamaños, con una y dos capas ocultas, y usando varias inicializaciones aleatorias de la matriz de pesos. De esta manera se intenta disminuir la probabilidad de que el algoritmo de entrenamiento quede atrapado en un mínimo local de la superficie de error. Para comparar la capacidad de generalización de las diferentes redes se estudió el error de validación promedio. Una vez fijada la topología se variaron los parámetros críticos del algoritmo de entrenamiento para determinar los valores del ritmo de aprendizaje y del momento que permitían obtener mejores resultados. La red neuronal definitiva para imágenes nocturnas tiene dos capas ocultas, la primera con 100 neuronas y la segunda con 20.

Para las imágenes diurnas se tiene información de los cinco canales del AVHRR, y en este caso sí se ha de considerar que las medidas del canal 3 tienen una contribución solar. Por otro lado, también hay que incluir en el modelo la influencia de la geometría del sistema sol-satélite-Tierra, y el día del año en que se tomó la imagen. Esto aumenta el número de parámetros de entrada de la red neuronal, complicando su estructura. Además el modelo debe tener en cuenta la posibilidad de que se den situaciones en las que se producen efectos de reflexión especular de la radiación solar en la superficie del océano.

Puesto que el espesor óptico se puede aproximar como función únicamente de las radiancias del canal 1, se consideró la posibilidad de usar dos redes independientes: una que permitiese extraer el espesor óptico y otra para el radio efectivo y la temperatura de la nube. La primera tendría como entradas los ángulos cenitales del satélite y del sol, el azimutal entre ambos, el día del año asociado a la imagen, y las medidas del canal 1. En la segunda, además de los tres ángulos y el día, habría que introducir las temperaturas de brillo de los canales 3, 4 y 5, las temperaturas de brillo de superficie para cada uno de esos tres canales, y el espesor óptico. Con esto se pretendía acelerar el proceso de entrenamiento de las redes neuronales y simplificar las mismas. Sin embargo, esta división no favorecía los resultados obtenidos para el radio efectivo, que tendían a sobreestimarse.

Por ello se decidió usar una única red para determinar los tres parámetros. Así, la red definitiva debía tener once entradas y tres salidas. En este caso, al tener que considerar más factores, el número de datos que se debían generar con el modelo era mayor. En total se utilizó una *lookup-table* con 82500 patrones,

dividida en un conjunto de entrenamiento de 54000 datos y otro de validación con 28500. Al igual que en el caso anterior, la selección de la red óptima se llevó a cabo entrenando redes neuronales de diferentes tamaños, con una y dos capas ocultas. La red con la que se obtuvo un menor error de validación, y por lo tanto una mayor capacidad de generalización, fue aquella que tenía dos capas ocultas, la primera con 90 neuronas y la segunda con 40.

## 5. Resultados

Las redes neuronales entrenadas fueron aplicadas a imágenes de la región de las Islas Canarias, y los resultados obtenidos se compararon con medidas realizadas desde tierra, en la parte norte de la isla de Tenerife. Estas medidas fueron adquiridas durante una campaña desarrollada por el Dr. R. Borys y Dr. D. Lowenthal [9] durante los periodos de verano de los años 1995 y 1996. Las propiedades microfísicas de las nubes se obtuvieron a través del uso de un sensor óptico *PMS Forward Scattering Spectrometer Probe (FSSP-100HV)*.

En la Tabla 1 se presentan los resultados para el radio efectivo obtenidos para diferentes imágenes nocturnas tomadas con pocas horas de diferencia respecto a las medidas in situ. Además, se proporcionan los radios efectivos medidos promediados en el tiempo. En cuanto a los valores extraídos de las imágenes, éstos se calculan promediando en una región cercana al punto de medida.

Cuadro 1: *Comparación de las medidas in situ y los resultados obtenidos a partir de imágenes nocturnas.*

Día	Medida in situ( $\mu\text{m}$ )	Radio extraído ( $\mu\text{m}$ )
11 Junio 1995	5.4	5.7
29 Junio 1995	5.7	6.5
30 Junio 1995	5.1	7.0
5 Julio 1995	4.8	5.5
5 Julio 1996	9.1	8.6
8 Julio 1996	7.9	8.7
19 Julio 1996	5.9	6.8
20 Julio 1996	5.8	5.6
25 Julio 1996	6.3	6.8
26 Julio 1996	7.7	7.6

Tal y como se ve en la Tabla 1, los valores obtenidos se aproximan a las medidas realizadas, reproduciendo la variación del radio efectivo que se produce entre los diferentes días. Las diferencias entre ambos

valores no siempre se producen en el mismo sentido, desechando una sobreestimación o subestimación sistemática.

En la Tabla 2 se muestran los radios efectivos obtenidos a partir de imágenes diurnas. En este caso, debido a que las medidas in situ se realizaban por la noche, la separación temporal entre imágenes y medidas es mayor. Por ello las áreas seleccionadas para promediar los resultados se sitúan al noreste de la isla de Tenerife, en la dirección del viento dominante, y más alejada de la misma que en el caso anterior.

Cuadro 2: Resultados obtenidos a partir de imágenes diurnas.

Día	Medida in situ( $\mu\text{m}$ )	Radio extraído ( $\mu\text{m}$ )
5 Julio 1996	9.1	10.5
7 Julio 1996	7.6	9.7
8 Julio 1996	7.9	8.0
18 Julio 1996	5.5	6.1
20 Julio 1996	5.8	5.7
25 Julio 1996	8.3	7.6
26 Julio 1996	7.7	6.3

Como sucediese con las imágenes nocturnas, los resultados de la red neuronal se aproximan a las medidas in situ. Se ha de tener en cuenta la variación del radio efectivo dentro de la caja elegida para calcular el promedio, ya que, tal y como se pudo constatar, hay cierta influencia del área que cubre dicha caja sobre los valores obtenidos.

## 6. Conclusiones

La extracción de las características de estratocúmulos marinos a partir de imágenes de satélite hace necesario el uso de métodos numéricos, como las redes neuronales artificiales. El proceso de entrenamiento y diseño de una de estas redes puede requerir cierto tiempo, pero una vez concluida la fase de aprendizaje su aplicación a la imagen de interés consume un tiempo de computación escaso. Esta es una de las principales ventajas de este método, importante para el caso en que se desee hacer un estudio temporal usando cierto volumen de imágenes. Además, tal y como se ha mostrado en este trabajo, la capacidad de generalización de una red neuronal permite obtener unos buenos resultados de las propiedades de las nubes.

## 7. Agradecimientos

Este estudio ha sido financiado gracias al Ministerio de Ciencia y Tecnología de España (Proyecto de Investigación REN2003-08013) y al Fondo Europeo de Desarrollo Regional (FEDER).

## 8. Referencias

- [1] Ramanathan, V., "The role of earth radiation budget studies in climate and general circulation research", *J. Geophys. Res.*, 92, 4075-4095, 1987.
- [2] Stamnes, K., S. Tsay, W. Wiscombe, and K. Jayaweera, "Numerically stable algorithm for discrete-ordinate method radiative transfer in multiple scattering and emitting layered media", *Applied Optics*, 27, 2502-2509, 1988.
- [3] Ricchiazzi P., S. Yang, C. Gautier, and D. Sovie, "Sbdart: A research and teaching software tool for plane-parallel radiative transfer in earth's atmosphere", *Bull. Am. Meterol. Soc.*, 79, 2101-2114, 1998.
- [4] Nicolet, M., "On the molecular scattering in the terrestrial atmosphere: An empirical formula for its calculation in the homosphere", *Planet. Space Sci.*, 32, 1467-1468, 1984.
- [5] Anderson, G.P., S.A. Clough, F.X. Kneizys, J.H. Chetwynd, and E.P. Shettle, "AFGL atmospheric constituent profiles (0-120 km)", *AFGL Tech. Rep.*, HANScom Airforce Base, Massachusetts, 1986.
- [6] Cox, C. and W. Munk, "Measurement of the roughness of the sea surface from photographs of the sun's glitter", *J. Opt. Soc. Atm.*, 44, 838-850, 1954.
- [7] Chester, D.L., "Why two hidden layers are better than one", *Proc. of the Int. Joint Conference on Neural Network, IEEE Publications*, 1, 265-268, 1990.
- [8] Prechtel, L., "Early stopping, but when?", *Lecture Notes in Computer Sci.*, 1524, 57-69, 1999.
- [9] Borys, R.D., D.H. Lowenthal, M.A. Wetzel, F. Herrera, A. González, and J. Harris, "Chemical and microphysical properties of marine stratus clouds in the north atlantic", *J. Geophys. Res.*, 103, 22073-22085, 1998.