

# Un método para combinar datos espectrales e información auxiliar en una red artificial neuronal

Jean-François Mas

Instituto de Geografía  
Universidad Nacional Autónoma de México  
Unidad Académica Morelia  
Aquilés Serdán 382 Col. Centro 58000  
Morelia Michoacán, México  
jfm@igiris.igeograf.unam.mx

**Abstract.** This paper describes a neural networks approach to incorporate ancillary information such as a digital elevation model or a soil map into the classification of a multispectral image. As a first step, an outdated land use/cover map was compared with ancillary data within a geographic information system (GIS) in order to establish the relationships between the distribution of land covers and these ancillary variables. A multilayer perceptron was used to generate fuzzy maps which indicate the membership of each land use/cover class from the ancillary maps. A second multilayer perceptron was used to classify a recent Landsat image in order to produce fuzzy maps based upon spectral information. Finally, the fuzzy maps derived respectively from the ancillary data and the multispectral data were combined in order to produce the final map. This method was applied to map the land use/cover of a tropical coastal region of Mexico. In comparison with spectral classification, this procedure allowed a statistically significant increase of global accuracy from 72 to 81%.

**Palabras-chave:** image processing, neural networks, ancillary data, land cover, processamento de imagens, redes neurais, dados auxiliares, cobertura da terra.

## 1. Introducción

Un problema comúnmente encontrado al clasificar datos de percepción remota es la confusión espectral: diferentes coberturas presentan respuestas espectrales similares y no resultan correctamente separadas. Este problema es particularmente importante en las regiones con una alta biodiversidad donde existe una gran variedad de tipos de vegetación. Existe una estrecha relación entre variables ambientales como el relieve o el tipo de suelo, entre otras, y la distribución de las coberturas del suelo. Por lo tanto, la utilización de estas variables en el proceso de clasificación puede contribuir al mejoramiento del mapeo de las coberturas del suelo. Por otro lado, en México, existen mapas de uso del suelo y vegetación de muy buena calidad que fueron elaborados por el Instituto Nacional de Estadísticas, Geografía e Informática (INEGI) con base en fotointerpretación y trabajo de campo pero que muchas veces se encuentran desactualizados. Hasta la fecha, la actualización de estos mapas se llevó a cabo con base en la interpretación visual de imágenes de satélite recientes con el fin de poder tomar en cuenta la cartografía existente (Mas et al., 2002; Takaki Takaki y Victoria Hernández, 2004). Sin embargo, la producción cartográfica por interpretación visual es un proceso largo y costoso por lo cual es importante desarrollar métodos más automatizados que permitan clasificar imágenes tomando en cuenta además de la información espectral otros tipos de datos así como la cartografía existente.

Existen numerosos trabajos en los cuales se buscó incorporar información auxiliar para mejorar el desempeño de clasificadores espectrales (Hutchinson, 1982; Kontoes et al., 1993, Mas y Ramírez, 1996). Sin embargo, debido al supuesto paramétrico de los algoritmos más comúnmente utilizados (como la máxima verosimilitud), es difícil la incorporación de los datos auxiliares durante el proceso de clasificación (Hutchinson, 1982). El uso de reglas booleanas post-clasificadoras a partir de los datos auxiliares, es más común pero a menudo no

permite reflejar propiamente la complejidad de las relaciones entre la distribución de las coberturas del suelo y las variables ambientales (Hutchinson, 1982; Mas y Ramírez, 1996). Recientemente, el uso de algoritmos de inteligencia artificial como las redes neuronales ha abierto nuevas perspectivas para clasificar imágenes satelitales y datos auxiliares porque no hacen hipótesis sobre la distribución de los datos (Civco, 1993; Foody, 1995; Atkinson y Tatnall, 1997). El objetivo de este trabajo, es desarrollar un método para incorporar información auxiliar derivada de un modelo digital de elevación (MDE) y de mapas temáticos en el procedimiento de clasificación de una imagen multiespectral.

## 2. Área de estudio

El área de estudio está ubicada entre las coordenadas  $18^{\circ} 02'$  y  $19^{\circ} 10'$  de latitud norte y  $91^{\circ} 01'$  y  $92^{\circ} 29'$  de longitud oeste. Tiene una superficie de aproximadamente  $19.200 \text{ km}^2$  y corresponde a la región de la Laguna de Términos en el Estado de Campeche, México (**Figura 1**). Es un mosaico de pastizales, tulares, cultivos, manglares y selva tropical. La región es predominantemente plana con pequeñas elevaciones que alcanzan 130 m en la parte sureste. Los suelos están dominados por el gleysol (80% de la superficie), se encuentran igualmente suelos de tipo solonchak, rendzina, regosol y vertisol. La distribución de los principales tipos de uso del suelo y vegetación dependen principalmente de la topografía, del tipo de suelo, de la distancia a la línea de costa y de la accesibilidad (Mas y Puig, 2001). La región presenta tasas de cambio de las coberturas del suelo muy elevadas principalmente por las actividades agropecuarias (Isaac-Márquez, 1993).



**Figura 1.** Ubicación del área de estudio

## 3. Materiales y métodos

Se utilizó una porción de imagen Landsat ETM+ (21/47) del 3/4/2000. Esta imagen fue corregida geoméricamente con un error cuadrático de menos de un píxel. Se utilizaron también mapas topográficos, edafológico, de uso del suelo y vegetación escala 1:250.000 en formato digital del INEGI. Se interpolaron las curvas de nivel del mapa topográfico para generar un modelo digital de elevación (MDE). Se generaron también mapas de distancia a las carreteras y a la costa.

Las redes neuronales (RN) son algoritmos matemáticos que imitan el funcionamiento del cerebro. Permiten la generación de clasificaciones difusas (*fuzzy*) en las cuales cada objeto (o píxel) puede presentar una pertenencia a diferentes clases (Civco, 1993). Existe un gran variedad de tipos de RN, se utilizaron aquí perceptrones multicapas (PM) que es el tipo de RN más comúnmente empleado en percepción remota (Foody, 2001). En el PM, las unidades de procesamiento (neuronas) están dispuestas en capas, una capa de entrada, una o dos capas ocultas y una de salida. El aprendizaje es supervisado, es decir que tiene una fase de entrenamiento como el método de la máxima verosimilitud. Más detalles sobre RN pueden encontrarse en Openshaw y Openshaw (1997) y Bishop (1995) entre otros.

Se llevaron a cabo dos clasificaciones en paralelo usando dos perceptrones independientes:

El primero PM clasificó las coberturas del suelo con base en las variables auxiliares. El entrenamiento se efectuó con base en el mapa de vegetación y uso del suelo del INEGI (1984). En otras palabras, el clasificador “aprendió” la distribución de los tipos de coberturas con respecto a estas variables y generó mapas difusos que presentan la “posibilidad” de encontrar cada tipo de cobertura en función de estas variables. Cabe mencionar que el hecho de entrenar con la totalidad del mapa permite evitar los problemas relacionados con los datos de entrenamiento no exhaustivos (Foody, 1995).

El segundo PM clasificó la imagen multispectral con base en campos de entrenamiento definidos en la imagen. El clasificador asoció por lo tanto cada tipo de cobertura con una respuesta espectral. Como el primero, permitió generar mapas difusos para cada categoría de cobertura.

En una etapa siguiente, los dos mapas difusos se combinaron para obtener una imagen clasificada en la cual cada píxel presenta un valor de pertenencia que refleje a la vez su respuesta espectral y su condición respecto al relieve. Dos coberturas del suelo que presentan una cierta similitud espectral pueden ser separadas si su distribución espacial en cuanto a una o varias variables auxiliares es diferente. La combinación de los dos mapas se realizó utilizando el operador “AND” que el mínimo de los dos valores difusos (Zadeh, 1978).

Para estimar la fiabilidad temática de las imágenes clasificadas, se utilizó un muestreo aleatorio de 488 puntos que se interpretaron en fotografías aéreas digitales. Se elaboraron matrices de confusión y se calcularon índices de fiabilidad como la fiabilidad global, del productor y del usuario (Stehman, 1997). Con el fin de evaluar el mejoramiento obtenido a través de la incorporación de las variables auxiliares se comparó la fiabilidad obtenida con la clasificación únicamente espectral y la clasificación derivada de la combinación entre la información espectral y las variables auxiliares. Ya que se utilizaron los mismos datos de referencia para evaluar la fiabilidad de los mapas en comparación, se empleó el método propuesto por Foody (2004) para tomar en cuenta la falta de independencia entre los datos de referencia. El método consiste en evaluar si existe una diferencia significativa entre dos proporciones con base en la prueba de McNemar. Es una prueba no paramétrica basada en una matriz de confusión de dos por dos que expresa las relaciones entre las confusiones de las dos clasificaciones en comparación (**Tabla 1**).

**Tabla 1.** Elementos de la matriz utilizada en la prueba de McNemar

	Clasificación 2	
Clasificación 1	Correcto	Incorrecto
Correcto	$f_{11}$	$f_{12}$
Incorrecto	$f_{21}$	$f_{22}$

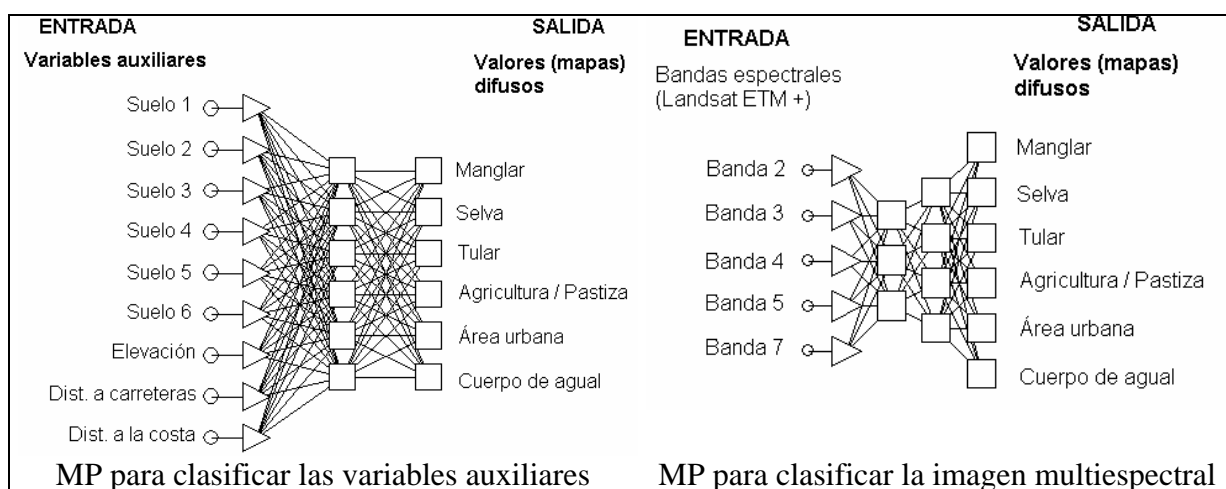
La ecuación de la prueba se calcula como indicado a continuación y expresa la diferencia en los errores cometidos en las dos clasificaciones. Esta variable sigue una distribución de chi cuadrado con un grado de libertad de uno y se compara con una tabla de los valores de chi cuadrado para determinar si esta diferencia (en este caso la diferencia de fiabilidad) es estadísticamente significativa.

$$z^2 = \frac{(f_{12} - f_{21})^2}{f_{12} + f_{21}} \quad (1)$$

#### 4. Resultados


Se generó una base de datos en el sistema de información geográfica que comprende la imagen multispectral Landsat ETM+, el mapa de uso del suelo y vegetación, el modelo de elevación digital, el mapa de suelos, la distancia a las carreteras y la distancia a la costa.

Las clasificaciones se llevaron a cabo tomando en cuenta las siguientes categorías: 1) selva, 2) manglar, 3) tular, 4) agricultura y pastizales, 5) cuerpo de agua y 6) áreas urbanas. Para evitar el sobreentrenamiento de los PM, se utilizó una mitad de los datos como entrenamiento, y lo demás para verificar el comportamiento del aprendizaje. La estructura de los PM se determinó de manera empírica. El primero (datos auxiliares) tiene nueve nodos de entrada (uno por variable auxiliar), seis en la capa oculta y seis de salida (uno por categoría). El segundo presenta cinco nodos de entrada (bandas espectrales ETM 2,3,4,5 y 7), dos capas ocultas con respectivamente tres y cuatro nodos, y seis de salida (**Figura 2**).



**Figura 2.** Estructura de los PM utilizados en el estudio

Una vez entrenados, se utilizaron los PM para generar mapas difusos para cada tipo de cobertura. En la **figura 3**, que representa los mapas difusos para el manglar derivados, respectivamente, de la información auxiliar y de la imagen Landsat. Se puede observar que la combinación de ambos mapas permite eliminar errores relacionados con pixeles clasificados espectralmente como manglar pero ubicados en las partes más elevadas y alejadas de la costa. Al contrario, áreas de manglar que fueron convertidas a uso agropecuario presentan altos valores en el mapa difuso derivado de los datos auxiliares pero valores muy bajos en el mapa derivado de la imagen y, por lo tanto, no se clasifican en manglar.



**Figura 3.** Mapas difusos de la distribución del manglar derivados de las variables auxiliares (arriba) y de la imagen multispectral (abajo). Los tonos más claros indican valores de pertenencia más elevados.

La clasificación espectral alcanzó una fiabilidad global de 74% (67% sin tomar en cuenta la categoría “cuerpo de agua”) mientras la incorporación de la información auxiliar permitió incrementar esta fiabilidad a 82% (79% sin tomar en cuenta la clase “cuerpo de agua”). La comparación de la fiabilidad obtenidas por a) el clasificador espectral y b) la combinación de la clasificación espectral con la clasificación auxiliar permite comprobar que el incremento de la fiabilidad combinando las dos fuentes de información es significativo ( $z^2 = 22$ , diferencia significativa a 1%). Un análisis más detallado de esta comparación así como las matrices de confusión se encuentran en Mas (2004).

**Tabla 2.** Matriz utilizada en la prueba de McNemar

Clasificación espectral + datos auxiliares	Clasificación espectral	
	Correcto	Incorrecto
Correcto	332	66
Incorrecto	22	68

## 5. Conclusiones

El método propuesto en este artículo permite combinar información auxiliar de todo tipo (variables continuas como elevación o pendientes y variables discretas derivadas de mapas temáticos) e información espectral durante el proceso de clasificación. La ventaja que muestra con respecto a métodos anteriormente presentados en la literatura es que permite expresar las relaciones entre la distribución de las coberturas del suelo y las variables auxiliares de manera muy compleja gracias al uso de las redes neuronales (Lek et al., 1996) y específicamente para el área de estudio porque el entrenamiento se efectúa con mapas desactualizados del área de estudio. Este método permite rescatar la información sobre la distribución de las coberturas que está contenida en cartografías anteriores y puede utilizarse como un método de actualización de los mapas de uso del suelo y vegetación.

Sin embargo, el desempeño del proceso de clasificación depende de la calidad de los mapas utilizados en el entrenamiento de la red neuronal. Un mapa erróneo tiene por consecuencia un aprendizaje sesgado y un mapa difuso de salida inexacto. Este tipo de aprendizaje sesgado podría también presentarse en caso que la distribución de los tipos de cobertura haya drásticamente cambiado entre la fecha de elaboración del mapa que sirve en el entrenamiento y de la fecha de actualización. Finalmente, cabe señalar que aún con el incremento de la fiabilidad de la clasificación que logró obtener este método, quedan errores que un intérprete experimentado hubiera probablemente evitado. No obstante, este método es un primer paso hacia la automatización de los procesos de actualización cartográfica y puede auxiliar al intérprete para volver más eficiente su labor.

## 6. Agradecimientos

Este trabajo se llevó a cabo en el ámbito del proyecto “Clasificación de imágenes de percepción remota con tecnologías de vanguardia (conjuntos difusos, redes neurales y clasificación por objeto)” ref. 2002-C01-0075 financiado por CONACYT-SEMARNAT.

## Referencias

- Atkinson, P.M.; Tatnall, A.R.L. Neural networks in remote sensing. **International Journal of Remote Sensing**, v. 18, n. 4, p. 699-709, 1997
- Bishop, C.M. **Neural Networks for Pattern Recognition**. Oxford University Press, Oxford, 1995, 482 p.
- Civco, D.L. Artificial neural networks for land-cover classification and mapping. **International Journal of Geographical Information Science**, v. 7, n.2, p. 173-186, 1993.
- Foody, G.M. Land cover classification by an artificial neural network with ancillary information. **International Journal of Geographical Information Science**, v. 1, n. 5, p. 527-542, 1995.
- Foody, G.M. Thematic mapping from remotely sensed data with neural networks: MLP, RBF and PNN based approaches. **Journal of Geographical Systems**, n. 3, p. 217-232, 2001.
- Foody, G.M. Thematic Map Comparison: Evaluating the Statistical Significance of Differences in Classification Accuracy. **Photogrammetric Engineering and Remote Sensing**, v. 70, n. 5, p. 627-633, 2004.
- Hutchinson, C.F. Techniques for Combining Landsat and Ancillary Data for Digital Classification Improvement. **Photogrammetric Engineering and Remote Sensing**, v. 8, n. , p. 123-130, 1982.
- INEGI. **Carta de uso del suelo y vegetación**, escala 1:250,000, hoja Ciudad del Carmen, 1984.
- Isaac-Márquez, R. **Evaluación del cultivo de arroz como fuente de contaminación e impacto ambiental para la Laguna de Términos, Campeche, México**, 1993. Tesis profesional, Escuela de Biología, Universidad Autónoma de Guadalajara, México.
- Kontoos, C.; Wilkinson, G.; Burrell, A.; Goffredo, S; Mégier, J. An Experimental System For The Integration of GIS Data in Knowledge-based Analysis for Remote Sensing of Agriculture. **International Journal of Geographical Information System**, v. 7, n. 3, p. 247-262, 1993.
- Lek, S.; Delacoste, M.; Baran, P.; Dimopoulos, I.; Lauga, J.; Aulancier, S. Application of neural networks to modelling non-linear relationships in ecology. **Ecological Modelling**, 90:39-52, 1996.
- Mas, J.F.; Puig, H. Modalités de la déforestation dans le Sud-ouest de l'Etat du Campeche, Mexique. **Canadian Journal of Forest Research**, v. 31, n. 7, p. 1280-1288, 2001.
- Mas, J.F.; Ramírez, I. Comparison of land use classifications obtained by visual interpretation and digital processing. **ITC Journal**, n. 3-4, p. 278-283, 1996.
- Mas, J.F. Mapping land use/cover in a tropical coastal area using satellite sensor data, GIS and artificial neural networks. **Estuarine, Coastal and Shelf Science**, v. 59, n. 2, p. 219-230, 2004.
- Mas, J.F.; Velázquez, A.; Palacio-Prieto, J.L.; Bocco, G.; Peralta, A.; Prado, J. Assessing forest resources in Mexico: Wall-to-wall land use/cover mapping. **Photogrammetric Engineering and Remote Sensing**, v. 68, n. 10, p. 966-968, 2002.
- Openshaw, S.; Openshaw, C. **Artificial intelligence in geography**. Ed. Wiley & sons, 1997, 329 p.
- Stehman, S.V. Selecting and Interpreting Measures of Thematic Classification Accuracy. **Remote Sensing of Environment**, v. 62, p. 77-89, 1997.
- Takaki Takaki F.; Victoria Hernández, A., 30 años de levantamientos cartográfico de la cobertura del suelo y vegetación de México, XV Congreso Mexicano de Botánica, Querétaro, Querétaro; Octubre 14 - 19, 2001.
- Zadeh, L.A. Fuzzy sets as a basis for theory of possibility. **Fuzzy sets and Systems**, n. 1, p. 3-28, 1978.