

## UN MODELO ESPACIAL DEL RIESGO DE DEFORESTACIÓN

JEAN-FRANÇOIS MAS <sup>1</sup>

HENRI PUIG <sup>2</sup>

JOSÉ-LUIS PALACIO <sup>1</sup>

ATAHUALPA SOSA <sup>3</sup>

<sup>1</sup>Instituto de Geografía – Universidad Nacional Autónoma de México (UNAM)  
Circuito exterior – Cd Universitaria A.P. 20-850 CP 01000 México D.F. México  
jfm@s@igiris.igeograf.unam.mx

<sup>2</sup>Laboratoire d'Ecologie Terrestre  
UMR 5552 (C.N.R.S. / UPS) 13, Av. du Colonel Roche  
B.P. 4072 31029 Toulouse Cédex 4, France

<sup>3</sup>Centro de Ecología, Pesquería y Oceanografía del Golfo de México (EPOMEX),  
Universidad Autónoma de Campeche A.P. 520 24030 Campeche, Camp, México

**Abstract.** This study aims at predicting the spatial distribution of tropical deforestation. Landsat images dated 1974, 1986 and 1991 were classified in order to generate digital maps of deforestation which describe deforestation and forest persistence. The deforestation maps were overlaid with various spatial variables such as the proximity to roads and to human settlements, the forest fragmentation, the elevation, the slope and the soil type to determine the relationship between deforestation and these explanatory variables. A multi-layer perceptron estimated the propensity to deforestation as a function of the explanatory variables and was used to develop deforestation risk assessment maps. The comparison of risk assessment map and actual deforestation indicated that the model was able to classify correctly 69 % of the grid cells, for two categories: forest persistence *versus* deforestation. The artificial neural networks approach was found to have a great potential to predict land use/cover changes because it permits to develop complex, non-linear models.

**Keywords:** deforestation, modelling, geographic information system, artificial neural networks, Mexico.

### 1. Introducción

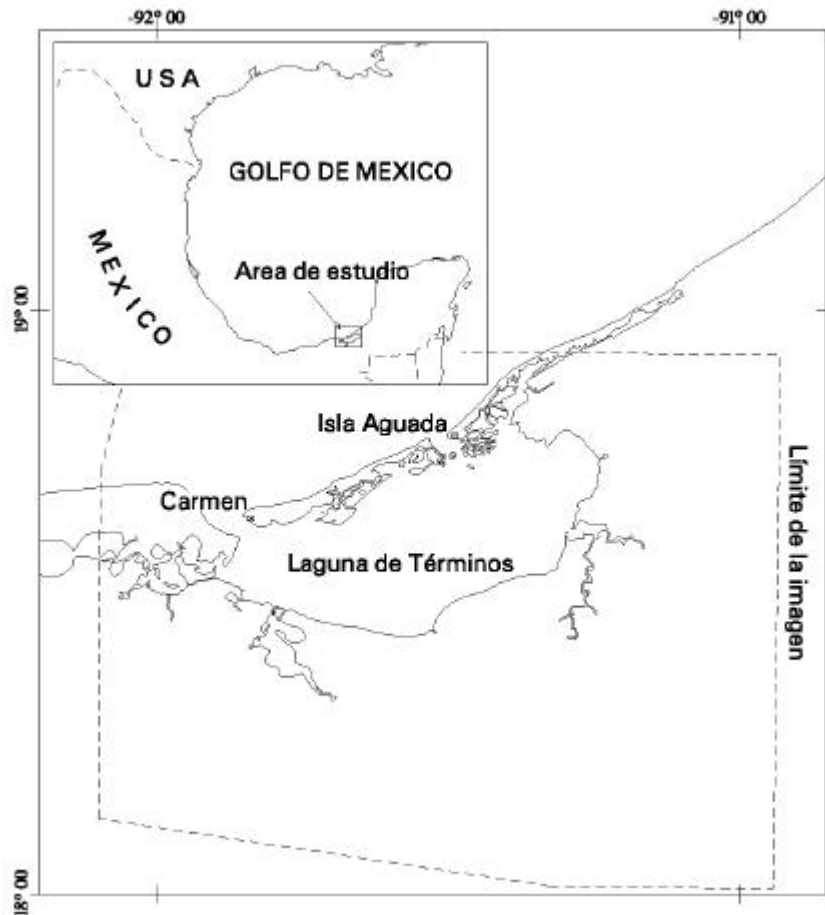
La deforestación es un tema que ha recibido una importante atención durante los últimos años por las consecuencias negativas que tiene sobre el clima, el ciclo hidrológico, la conservación de los suelos y la biodiversidad (Puig, 2000). En México, se estimaron las tasas de deforestación durante las tres últimas décadas en 0.25 y 0.76 % por año para los bosques templados y tropicales respectivamente (Mas et al., 2002; Velázquez et al., 2002). Sin embargo, se conocen mal las causas y los mecanismos de la deforestación. El desarrollo de modelos de deforestación espacialmente explícitos contribuye a entender mejor como ciertas variables interactúan y controlan la deforestación y permite la predicción de las tasas de cambio y la localización de las áreas deforestadas (Lambin, 1994; Geoghegan et al., 2001).

Las redes neuronales (RN) son un nuevo paradigma de procesamiento de datos que se basa en la estructura del cerebro. No hacen en hipótesis sobre la distribución de los datos, son capaces de modelar relaciones muy complejas entre las variables de entrada y de salida. Una vez entrenadas, es posible utilizar las RN para calcular las variables de salidas a partir de datos de entrada nuevos (Lek y Guégan, 1999). Se ha comprobado el potencial de las RN como alternativa ante los clasificadores estadísticos tradicionales (Civco, 1993; Paola y Schowengerdt, 1995; Chiuderi, 1997; Paruelo y Tomasel, 1999).

El objetivo de este estudio es de desarrollar un modelo espacial que pueda predecir la localización de áreas deforestadas en una región tropical.

## 2. Área de estudio

El área de estudio está localizada en el sureste de México y tiene una superficie de 12 400 km<sup>2</sup> (**Figura 1**). Los principales tipos de vegetación son sabanas, manglares y selva tropical. Grandes áreas fueron convertidas en pastizales y en arrozales durante las últimas décadas (Isaac-Márquez, 1993; Mas y Puig, 2001). Los suelos están dominados por el tipo gleysol, se encuentran también suelos solonchak y rendzina. La principal ciudad, Ciudad del Carmen (84 000 habitantes), es el centro de una importante actividad petrolera y pesquera.



**Figura 1 – Localización del área de estudio**

## 3. Materiales y métodos

Se elaboró una base de datos espacial sobre los cambios en la cobertura forestal. Para ello, se utilizaron 3 imágenes Landsat, de fecha 15/2/1974, 15/1/1986 y 3/4/1991 que fueron corregidas geoméricamente. En un estudio anterior, se aplicaron diferentes métodos de detección de cambios a estas imágenes para el monitoreo de los cambios de cobertura. Es la comparación de imágenes clasificadas de forma independiente que arrojó los mejores resultados (Mas, 1999). Las imágenes fueron clasificadas y simplificadas para generar imágenes binarias con 2 clases (*forestal* y *no forestal*). En un paso siguiente, estas imágenes se cruzaron para generar imágenes de cambio que indican las combinaciones *forestal / forestal* (persistencia del bosque) y *forestal / no forestal* (deforestación).

Se buscó establecer la relación entre la deforestación y variables consideradas *a priori* como variables que podían controlar los patrones espaciales de la deforestación como la distancia a las vías de comunicación y a los asentamientos humanos, la elevación, la pendiente, los suelos y el grado de fragmentación de la cobertura forestal. Se digitalizaron los mapas de suelos, de las vías de comunicación y de los asentamientos humanos del Instituto Nacional de Estadística, Geografía e Informática (INEGI), escala 1:250 000. Se generó un modelo digital de elevación por interpolación de curvas de nivel del mapa topográfico, escala 1:50 000. Se generaron las variables espaciales que se indican a continuación :

- Distancia a las carreteras,
- Distancia a los asentamientos humanos,
- Distancia al área forestal más cercana,
- Porcentaje de cubierta forestal en ventanas de 3 x 3, 9 x 9 y 15 x 15 píxeles,
- Índice de Matheron. Este índice de fragmentación se calculó en una ventana de 3 x 3 píxeles, siguiendo la ecuación a continuación (Matheron, 1970):


$$M = \frac{N_{F-NF}}{\sqrt{N_F} \cdot \sqrt{N}}$$

Donde  $N_{F-NF}$  es el número de contactos entre píxeles clasificados como *forestal* y *no forestal*,  $N_F$  es el número de píxeles *forestales* y  $N$  es el número total de píxeles dentro de la ventana.

Para desarrollar el modelo, se buscó una función que relacione la deforestación y las variables explicativas con base en el mapa de deforestación del primer periodo (1974-86). Esta función se utilizó para estimar el riesgo de deforestación para cada píxel que represente una área forestal en 1986. Para evaluar el desempeño del modelo para la predicción espacial de la deforestación, se comparó los valores de riesgo de deforestación y la distribución real de las áreas deforestadas durante el periodo siguiente (1986-91).

Para establecer la relación entre la deforestación y las variables explicativas, se cruzó cada una de estas variables con el mapa de deforestación para generar una tabla que indique el tipo de cambio (persistencia del bosque o deforestación) y los valores de las variables explicativas (Mas y Puig, 2001). Un análisis de separabilidad, basado en el cálculo de la distancia de Bhattacharyya (Mausel et al., 1990) permitió seleccionar las variables que separaban mejor los áreas deforestadas y las no-deforestadas.

Se utilizó el perceptrón multicapa que es la estructura de RN más comúnmente utilizada (Bishop, 1995; Aktinkon y Tatnall, 1997; Lek y Guégan, 1999). La estructura de la RN está compuesta por unidades de procesamiento (neuronas), distribuidas en capas, con entradas, elementos intermedios (capa o capas ocultas) y salidas que simulan una red neuronal viva, en la que cada neurona está conectada con la capa siguiente (**Figura 2**). La conexión de neuronas entre capas produce un flujo de información unidireccional que se activa al recibir información de la capa anterior, ponderarla y llegar a un umbral o valor de activación. Este valor de activación es calculado por la misma neurona. El valor de activación se incorpora a una función de activación que produce las salidas de la neurona. En este estudio, el valor de activación de salida, que representa el grado de pertenencia a la categoría *deforestación* se interpreta como una propensión o un riesgo de deforestación.



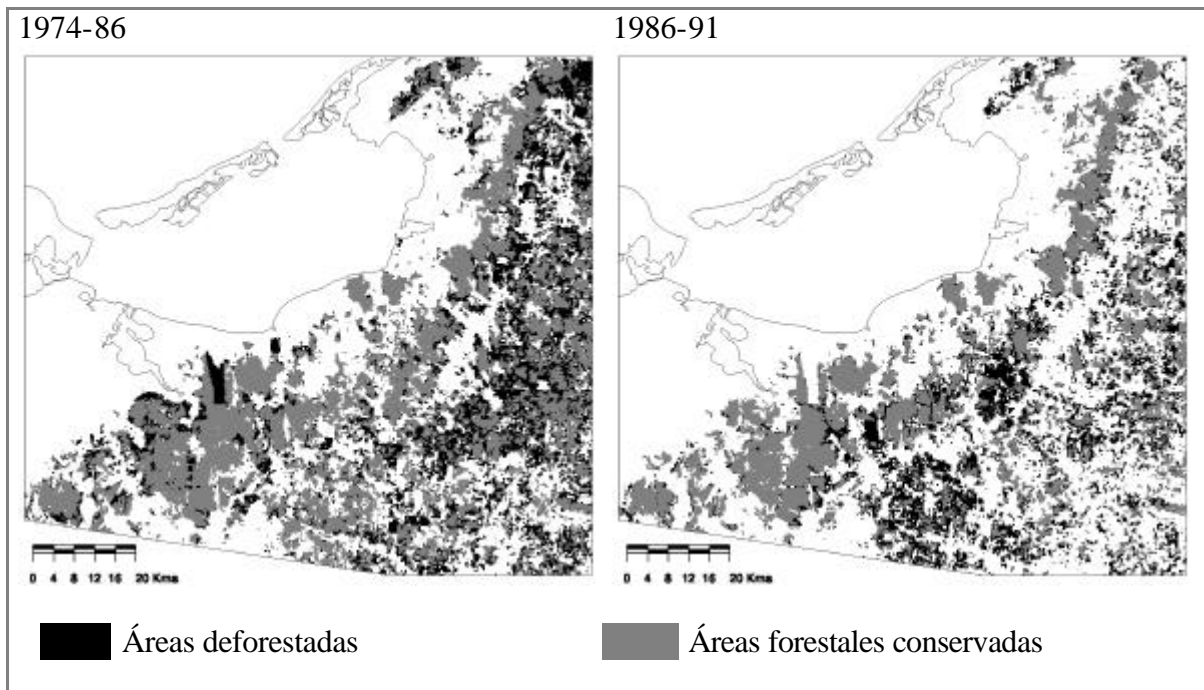
**Figura 2 – Estructura de un perceptrón multicapa**

Para evitar el sobreentrenamiento de la RN, se dividieron los datos de entrenamiento en tres: 1) los datos de entrenamiento en el sentido estricto que se utilizan para ajustar los valores de activación de cada elemento de la RN, 2) los datos que no son directamente utilizados en el entrenamiento y se usan para detectar el sobreentrenamiento y parar el proceso de iteraciones y, 3) los datos independiente del proceso de entrenamiento que se usan para medir el desempeño de la RN. Se utilizó el algoritmo de entrenamiento de Levenberg-Marquadt (Bishop, 1995) que es más rápido que el algoritmo de retropropagación.

El desempeño del modelo se evaluó con el coeficiente de Kappa (Pontius et al., 2001) y el coeficiente de predicción (de Brujin, 1991; Mas et al., 1996).

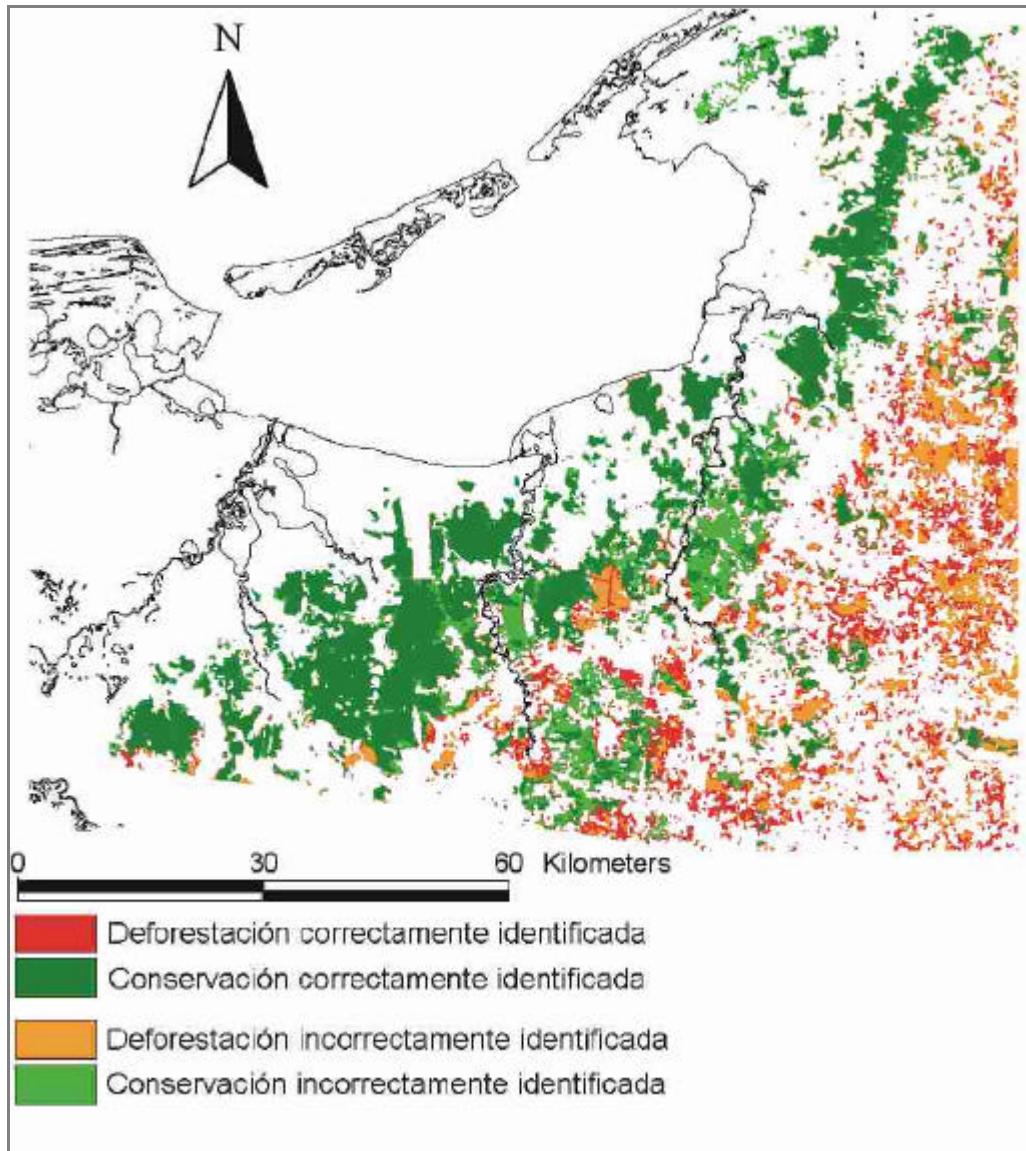
#### 4. Resultados

Se clasificaron las tres imágenes y se generaron dos mapas de deforestación para los periodo 1974-86 y 1986-91 (**Figura 3**). La confiabilidad de las imágenes varía entre 81 y 95 %.



**Figure 3 – Mapas de deforestación**

Con base en la distancia de Bhattacharyya, se determinó que el porcentaje de cubierta forestal en ventana de 3 x 3 píxeles, la elevación y la distancia a los asentamientos humanas eran las tres variables que separaban mejor las áreas deforestadas de las no-deforestadas. Con base en los datos 1974-1986, se estableció una función entre la deforestación y estas variables que fue utilizada para calcular el riesgo de deforestación para las regiones forestales de 1986. El mapa de riesgo de deforestación se comparó con el mapa real de deforestación para el periodo 1986-1991 con el fin de calcular los índices de desempeño del modelo (**Figura 4**). El modelo clasificó correctamente cerca de 69 % de los píxeles en 2 categorías *deforestación / no deforestación* con un coeficiente de Kappa de 0.34 y un coeficiente de predicción de 0.49. Como elementos de comparación, los coeficiente de predicción de modelos de crecimientos urbanos obtenidos por de Brujin (1991) presentaron valores del coeficiente de predicción entre 0.25 y 0.59, un modelo de deforestación en México alcanzó un coeficiente de predicción de 0.4 (Mas et al., 1996) mientras que Pontius et al. (2001) reportan un coeficiente de Kappa entre 0.31 y 0.53 para modelos de deforestación desarrollados en Costa Rica.



**Figura 4 – Comparación del mapa de riesgo de deforestación y la deforestación real**

## 5. Conclusión

Los factores que propician y controlan los patrones espaciales del proceso de deforestación interactúan entre ellos de manera muy compleja. En este sentido, el enfoque neuronal, que permite modelar funciones no-lineares muy complejas, puede ser una muy buena opción para desarrollar tales modelos. Sin embargo, los modelos complejos pierden poder de generalización y, por lo tanto, de predicción (Bishop, 1995; Rosin y Fierens 1995, Foody y Arora, 1997, Kavzoglu y Mather, 2000). En otras palabras, si el modelo se apega demasiado a los datos del periodo de entrenamiento y no es capaz de caracterizar de manera general las relaciones entre las variables explicativas y la deforestación. Se debe entonces buscar un modelo más sencillo aunque no parezca tan eficiente con los datos de entrenamiento.

Independientemente del método de modelización empleado, este tipo de ejercicio se enfrenta a varias limitaciones. Se basa en la hipótesis que las relaciones entre las variables explicativas y los patrones de deforestación siguen iguales en el tiempo (periodo de calibración y periodo de predicción). Es imposible integrar todas las variables que pueden tener una influencia sobre el proceso de deforestación y existe sin duda una componente aleatoria que impide una predicción precisa. Otra limitante es tal vez la escala, es probable que un modelo más burdo espacialmente permita identificar regiones propensas a la deforestación de manera más eficiente que un modelo que pretende localizar los parches forestales en riesgo de ser deforestados.

No obstante estas limitaciones, el modelo identifica las áreas forestales que están más en riesgo de ser desmontadas. Por lo tanto, se puede aplicar, por ejemplo, a la identificación de áreas de alto valor ecológico en riesgo o a la modelización del impacto de un proyecto de carretera.

## 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, England, 1995.
- Chiuderi, A. Multisource and Multitemporal data in land cover classification tasks the advantage offered by neural networks, *IEEE*, p. 1663-1665, 1997.
- Civco, D. L. Artificial neural networks for land-cover classification and mapping. *International Journal of Geographical Information Systems*, v. 7, n. 2, p. 173-186, 1993.
- De Brujin, A.C. Spatial factors in urban growth: towards GIS models for cities in developing countries. *ITC Journal*, n. 1991-4, p. 221-231, 1991.
- Foody, G. M.; Arora, M. K. An evaluation of some factors affecting the accuracy of classification by an artificial neural network, *International Journal of Remote Sensing*, v. 18, n. 4, p. 799–810, 1997.
- Geoghegan, J.; Villar, S.C.; Klepeis, P.; Mendoza, P.M; Ogneva-Himmelberger, Y.; Chowdhury, R.R.; Turner, B.L.; Vance, C. Modeling tropical deforestation in the southern Yucatan peninsular region: comparing survey and satellite data. *Agriculture, Ecosystems and Environment*, n. 85, p. 25-46, 2001.
- Isaac-Márquez, R. *Evaluación del cultivo de arroz como fuente de contaminación e impacto ambiental para la Laguna de Términos, Campeche, México*. Tesis profesional, Escuela de Biología, Universidad Autónoma de Guadalajara, México, 1993.
- Kavzoglu T.; Mather, P.M. Using Feature Selection Techniques to produce Smaller Neural Networks with Better Generalization Capabilities, *IEEE*, p. 3069 –3071, 2000.

- Lambin, E.F. *Modelling Deforestation processes, a review*, Joint Research Centre, Institute for Remote Sensing Applications; European Space Agency, Luxembourg, Office for Official Publications of the European Community, EUR 15744 EN, TREES series B: Research Report nº1, 128 p, 1994.
- Lek, S.; Guégan, J.F. Artificial neural networks as a tool in ecológical modelling, an introduction. *Ecológical Modelling*, n. 120, p. 65-73, 1999.
- 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. Monitoring Land-cover Changes : A Comparison of Change Detection Techniques. *International Journal of Remote Sensing*, v. 20, n. 1, p. 139-152, 1999.
- Mas, J.F.; Sorani, V.; Alvarez, R. Elaboración de un modelo de simulación del proceso de deforestación. *Investigaciones Geográficas*, n. 5, p. 43-57, 1996.
- Mas, J.F.; Velázquez, A.; Díaz, J.R.; Mayorga, R.; Alcántara, C.; Castro, R.; Fernández, T. Assessing Land Use / Cover Changes in Mexico, 29th International Symposium on Remote Sensing of the Environment, Buenos Aires, Argentina, *Proceedings* (CD), 2002.
- Matheron, G. La théorie des variables généralisées et ses applications. *Les Cahiers du Centre de Morphologie Mathématique de Fontainebleau*, Fascicule 5, 1970.
- Mausel, P.W.; Kramber, W.J.; Lee, J.K. Optimum band selection for supervised classification of multispectral data. *Photogrammetric Engineering and Remote Sensing*, v. 56, n. 1, p. 55-60, 1990.
- Paola, J. D.; Showengerdt, R. A. A detailed comparison of backpropagation neural network and maximum-likelihood classifiers for urban land use classification. *IEEE Transactions on Geoscience and Remote Sensing*, v. 33, n. 4, p. 981-996, 1995.
- Paruelo, J. M.; Tomasel, F. Prediction of functional characteristics of ecosystems: a comparison of artificial neural networks and regression models. *Ecological Modelling*, n. 98, p. 173-186, 1999.
- Pontius, R.G.; Cornell, J.D.; Hall, C.A.S. Modeling the spatial pattern of land-use change with GEOMOD2: application and validation in Costa Rica. *Agriculture, Ecosystems and Environment*, n. 85, p. 191-203, 2001.
- Puig, H. Diversité spécifique et déforestation : l'exemple des forêts tropicales humides du Mexique. *Bois et Forêts des tropiques*, n. 268, p. 41-55, 2001.
- Rosin, P. L.; Fierens, F. Improving Neural Network Generalisation, IEEE, pp. 1255-1257, 1995.
- Velázquez, A.; Mas, J.F.; Díaz, J.R.; Mayorga-Saucedo, R.; Alcántara, P.C.; Castro, R.; Fernández, T.; Bocco, G.; Ezcurra, E.; Palacio, J.L. Patrones y tasas de cambio de uso del suelo en México, *Gaceta ecológica*, INE-SEMARNAT, n. 62, p. 21-37, 2002. Disponible em: <http://www.ine.gob.mx/ueajei/publicaciones>