

Memorias



Sociedad Latinoamericana en
Percepción Remota y Sistemas
de Información Espacial
Capítulo Colombia

30
AÑOS

Medellín, Colombia
29 de Septiembre al 3 de Octubre de 2014



Análisis Comparativo de dos Modelos de Deforestación: Redes Neuronales Artificiales y Regresión Logística

Comparative Analysis of two Models of Deforestation: Artificial Neural Networks and Logistic Regression

Luisa Fernanda Gómez Ossa. Correo electrónico: lfgomezos@unal.edu.co.

Verónica Botero Fernández. Correo electrónico: vbotero@unal.edu.co.

Resumen: métodos estadísticos como la regresión logística han sido ampliamente utilizados para modelar la deforestación en la región tropical. Además de estos métodos, existen modelos de simulación dinámica como las redes neuronales artificiales que tienen la capacidad de realizar predicciones ante la presencia de relaciones no lineales. En la investigación se estimó un modelo de regresión logística y un modelo con redes neuronales artificiales para las regiones del Bajo Cauca y Nordeste del departamento de Antioquia, en función de variables biofísicas y de variables que representan accesibilidad a mercados. El conjunto de variables que generó mejores predicciones con el modelo de regresión logística se utilizó para la construcción y entrenamiento de redes neuronales artificiales. La capacidad predictiva de los modelos se evaluó con el área bajo la curva ROC (AUC). El modelo de regresión presentó un AUC de 0.77 y las redes neuronales un AUC de 0,80 a 0,82. La superficie estimada por el modelo de red neuronal indica que los bosques más susceptibles a la deforestación se encuentran cerca de los centros poblados y siguen la localización de las principales vías, por lo tanto los resultados y métodos de la investigación podrían ser útiles para orientar las medidas de conservación.

Palabras claves: Curva ROC, Entrenamiento, Perceptron Multicapa, Predicción.

Abstract: statistical methods such as logistic regression have been widely used for modeling tropical deforestation. Besides these methods, there are dynamic simulation models like neural networks that have the capacity to make predictions in the presence of non-linear relationships. In this research, a logistic regression model and a model using artificial neural networks for the Bajo Cauca region and the Northeast region of the department of Antioquia were estimated, based on biophysical variables and variables representing access to markets. The set of variables from the logistic regression model that generated better predictions, were used for the construction and training of artificial neural networks. The predictive ability of the models was assessed with the area under the ROC curve (AUC). The logistic regression model presented an AUC of 0.77 and neural networks an AUC of 0.80 to 0.82. The surface estimated by the neural network model indicates that the forests most susceptible to deforestation are located near population centers and follows the location of the main roads, so the methods and results of the research could be useful to guide conservation measures.

Key words: ROC curve, Training, Multilayer Perceptron, Prediction.

INTRODUCCIÓN

Por sus condiciones geográficas Colombia posee una gran biodiversidad pero desafortunadamente se encuentra entre los 10 primeros países que ha presentado pérdidas significativas de hábitat boscoso con una tasa de destrucción del 0.5% anual (Savage et al. 2010), y se proyecta que para el año 2050 casi el 80% de extinción de especies sea resultado de la deforestación (Eraso et al. 2013) , por lo tanto, es importante desarrollar modelos espaciales para evaluar el riesgo de conversión de los bosques a nivel nacional o regional.

En Colombia se han realizado trabajos sobre determinantes de la deforestación, (Armenteras et al. 2006; Etter et al. 2006a; Etter et al. 2006b) con aproximaciones de modelación propias de la ecología del paisaje. En el departamento de Antioquia recientemente se realizó un estudio de deforestación (Orrego 2009) en el cual se usó teoría de la renta y un modelo logístico para identificar los principales determinantes de la deforestación.

Los métodos estadísticos como la regresión logística, se han aplicado a una amplia gama de decisiones en muchas disciplinas (Butine & Weigend 1991). Estos modelos son atractivos para los tomadores de decisiones, debido a su estabilidad metodológica y la larga historia de aplicación, sin embargo presentan limitaciones en la predicción cuando la relación entre variables es muy compleja. Además de estos métodos, existen modelos de simulación dinámica como las redes neuronales artificiales (RNAs) que tienen la capacidad de realizar predicciones ante la presencia de relaciones no lineales, por lo tanto son útiles para modelar

fenómenos naturales, cuando la relación entre variables no es bien conocida (Mas et al. 2004).

Varios investigadores han comparado los modelos de redes neuronales con modelos logit utilizando diferentes conjuntos de datos, encontrando un rendimiento superior para las redes neuronales (Comrie 1997;Yilmaz 2009), sin embargo la evidencia empírica es limitada con respecto a la superioridad de las RNAs en la predicción de la deforestación. En la presente investigación se estimó un modelo de regresión logística y un modelo de RNAs para las regiones del bajo Cauca y Nordeste del departamento de Antioquia para el periodo 1980-2000, en función de variables biofísicas y de variables que representan accesibilidad a mercados. El modelo de regresión logística se desarrolló para identificar la importancia relativa de las variables explicadoras y las RNAs para lograr mayor precisión en la predicción de la deforestación, la cual se evaluó para ambos modelos con el área bajo la curva ROC (AUC).

Metodología

Área de estudio

El área de estudio comprende las subregiones del Bajo Cauca y Nordeste del departamento de Antioquia (figura 1) las cuales tienen 6 y 10 municipios, con un área total de 8.585 km² y 8.645km² respectivamente. Estas subregiones están dedicadas principalmente a la ganadería y a la minería, con producción agrícola marginal (Gobernación de Antioquia et al. 2007) y aún conservan grandes áreas en bosque con gran diversidad de recursos naturales, sin embargo su ubicación geográfica ha conducido a la planeación de nuevos proyectos de infraestructura vial que buscan mejorar la conectividad del departamento con el norte del país, por lo tanto es una área interesante para desarrollar modelos espaciales de

deforestación que sirvan de base para mitigar los impactos causados por la construcción de nuevas vías.

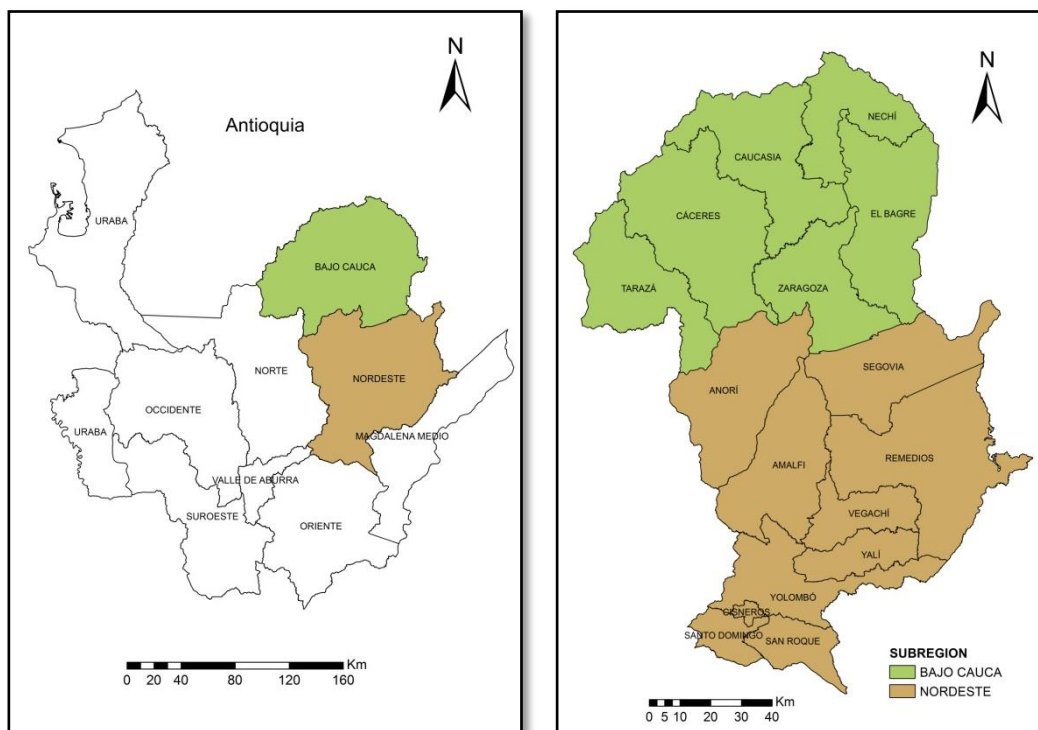


Figura 1. Localización del área de estudio correspondiente a las subregiones del Nordeste y Bajo Cauca del departamento de Antioquia.

Datos y variables

Información de coberturas terrestres de 1980 y 2000, a escala 1:25.000, se usó en la modelación de la deforestación.

La información de coberturas terrestres para el año 1980 se obtuvo luego de digitalizar más de 500 planchas temáticas (Orrego 2009) en formato análogo, proporcionadas por la Secretaría de Agricultura de Antioquia.

La información de coberturas terrestres para el año 2000 fue el resultado de un Convenio Interadministrativo entre la Secretaría de Agricultura, el Departamento Administrativo de Planeación y el Instituto Geográfico Agustín Codazzi. Ambos mapas de coberturas terrestres se convirtieron a formato raster y a partir de estos se identificó la trayectoria de bosque a no bosque.

Variables

Distancia euclidiana a ríos: Con la red de drenaje a escala 1:25.000 proporcionada por la Secretaria de Agricultura de Antioquia se generó un archivo en formato raster con la distancia euclidiana a los principales ríos, es decir ríos navegables que facilitan el transporte de productos agrícolas y la conectividad entre los municipios del área de estudio.

Distancia euclidiana a vías: Con la información de la red vial primaria, secundaria y terciaria, a escala 1:25.000 proporcionada por la Secretaria de Infraestructura de Antioquia se genero un archivo en formato raster con la distancia euclidiana a las vías.

Distancia al borde del bosque: Se utilizo la información en formato vector de la cobertura boscosa (bosque denso y bosque mixto) y no boscosa para el año 1980 y se calculo la distancia euclidiana desde la cobertura en bosque hacia la cobertura sin bosque.

La experiencia ha mostrado como la deforestación comienza desde el borde del bosque o cerca de sitios previamente deforestados, por lo tanto se considera una variable importante para modelar los patrones de deforestación (Thies et al. 2012).

Distancia de menor costo a las cabeceras municipales: La accesibilidad a mercados podría medirse más objetivamente con los tiempos de viaje que con las distancias lineales. Sin embargo, la información de tiempos de viaje por lo general no está disponible. Por esto los estudios de deforestación tropical usan distancias ponderadas por la impedancia. La

impedancia o costo, representa la dificultad de moverse planimétricamente a través de cada celda o pixel.

En la presente investigación se asignaron valores de impedancia a las coberturas, vías, ríos, áreas protegidas y pendiente, teniendo en cuenta las estimaciones del costo de transporte de productos agrícolas realizadas en el estudio de Nelson et al. (1999) .

- **Valor de impedancia por tipo de cobertura:** A las áreas forestales, que incluyen todos los tipos de bosques y aquellas cubiertas con vegetación arbórea de porte bajo, se les asignó un valor de impedancia 5. A las áreas con uso agropecuario, plantaciones forestales y áreas urbanas, se les asignó un valor de impedancia 3. Para la asignación de valores de impedancia se asume que las áreas con bosques presentan mayores dificultades para el transporte de productos agrícolas, por tanto, estas áreas no se podrían cruzar relativamente fácil si se comparan con áreas que tienen otro tipo de cobertura como pastos o zonas urbanas.
- **Asignación del Valor de impedancia por tipo de vía:** Un valor de impedancia 1 se asignó a las vías pavimentadas las cuales constituyen nodos importantes en la red de transporte terrestre de la región. Un valor de impedancia 3 a las vías sin pavimentar, un valor de impedancia 4 a caminos de herradura que solo permiten el tránsito de bestias de carga, y un valor de impedancia 5 a sitios sin vías para representar la mayor dificultad en el transporte de productos agropecuarios.
- **Asignación del valor de impedancia a los ríos:** los ríos podrían tener un valor de impedancia similar al de una vía (Nelson et al. 1999), ya que representan una importante fuente de transporte y proporcionan fácil acceso a los principales centros

urbanos, por tanto a los ríos se les asigno un valor de impedancia 1 y al resto del área un valor de 5.

- **Asignación de impedancia a las áreas protegidas:** aunque es posible trasportar productos agrícolas a través de un área protegida, este tipo de áreas representan una barrera natural para el transporte por encontrarse bajo protección legal, por lo tanto al área protegida presente en la zona de estudio la cual corresponde a la Reserva de Recursos Naturales Bajo Cauca-Nechí se le asigno un valor de impedancia de 5 y al resto del área un valor de 1.
- Finalmente los valores de impedancia asignados se sumaron y luego se multiplicaron por una función de la pendiente sugerida por Nelson et al.(1999)

$$\left(1 + \frac{p_e^2}{50}\right) * (Cc + Cv + Cr + Ca) \quad (1)$$

Donde Cc corresponde al costo por tipo de cobertura, Cv al costo por tipo de via, Cr al costo asignado a los ríos y Ca al costo asignado al área protegida. Aunque la fórmula es un tanto arbitraria, captura la relación positiva entre el aumento en la pendiente y el mayor costo de accesibilidad a mercados.

El cálculo equivale a la identificación sobre una superficie de la ruta de menor costo desde un pixel a cada uno de los mercados, caracterizados espacialmente por las cabeceras municipales existentes en 1980.

Pendiente: Se genero un mapa en formato raster de la pendiente en grados, a partir del modelo de elevación digital ASTER (METI & NASA, 2009) con una resolución espacial de 30 m. Se considera que tierras planas son más aptas para el uso agropecuario que aquellas

ubicadas en topografías montañosas, por poseer suelos más fértiles y facilitar el uso de maquinaria agrícola.

Aptitud agrícola: Con el mapa digital de suelos de la Secretaría de Agricultura de Antioquia del año 1979, a escala 1:25.000, se creó una variable *dummy* en formato raster con la información de clases agrológicas. Se asignó un valor de 1 para los píxeles en las clases II y III, es decir para aquellas zonas apropiadas para un uso agrícola moderadamente intensivo y 0 para las otras clases (IV, V, VI, VII, VIII). Se asume que áreas con mayor aptitud agrícola son más susceptibles a deforestación.

Aunque la deforestación puede ser explicada por una gran cantidad de variables, las causas subyacentes de la deforestación son más difíciles de identificar que las causas próximas debido a la disponibilidad de datos (datos socioeconómicos, tenencia de la tierra, influencia de políticas nacionales) por lo tanto se utilizaron variables biofísicas y de accesibilidad que permiten una mejor representación espacial. Mas et al.(2004) y Sanabria (2009) también reportaron esta limitación y utilizaron solo variables biofísicas para modelar la deforestación con RNas y a partir de métodos estadísticos como la regresión logística.

La construcción de las variables se realizó en el software ArcGis 10.1(ESRI 2009), con un tamaño de píxel de 30 m ya que de acuerdo con Orrego (2009) es el más adecuado para la representación en formato raster de la variable de deforestación y de aquellas que explican su ocurrencia.

Modelo de regresión logística

Dado que la multicolinealidad podría estar presente en modelos estadísticos de deforestación tropical se estimó una matriz de correlación para identificar las variables a incluir en el modelo. Una correlación de por lo menos 0,6 se consideró como un valor indicativo de alta correlación entre pares de variables.

Para estimar el modelo se seleccionó una muestra aleatoria de 700.000 puntos, correspondientes al 10% de los datos. Las variables explicadoras se incorporaron al modelo como variables independientes y la deforestación observada durante el periodo 1980-2000, como variable dependiente de tipo binaria o dicotómica.

Este método estadístico es el más utilizado en las ciencias ambientales y se expresa como se indica en la ecuación 2.

$$Y = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n \quad (2)$$

Donde Y es la variable dependiente y representa la presencia (1) o ausencia (0) de deforestación, b_0 el intercepto del modelo, $b_1 \dots b_n$ los coeficientes de regresión y $x_1 \dots x_n$ las variables explicadoras.

La probabilidad de deforestación, se calculó a partir de la ecuación 3.

$$P_i = \frac{1}{1 + \exp(-b_0 - b_1x_{1i} - b_2x_{2i} - \dots - b_nx_{ni})} \quad (3)$$

Donde x representa el conjunto de variables explicadoras y P_i la función de distribución acumulada de una variable que se distribuye acorde a una función logística. Los cálculos se realizaron en el software RStudio (R Development Core Team 2008).

Modelo de Red Neuronal

El entrenamiento de la red neuronal se llevó a cabo en el software R Studio (R Development Core Team 2008) usando el paquete AMORE, el cual hace uso del algoritmo de retropropagación del error (Haykin 1999).

La red neuronal propuesta para iniciar la fase de entrenamiento presenta una estructura de perceptron multicapa unidireccional (figura 2). Cada variable explicadora está asociada a una neurona en la capa de entrada, y se asigno una neurona a la capa de salida que corresponde a la variable dependiente, para esta ultima capa se uso una función de activación logística por tratarse de una variable categórica que toma valores de cero y uno, y se utilizo el método de aprendizaje en línea por su capacidad de trabajar con grandes conjuntos de datos (Plagianakos et al. 2001; Wilson & Martinez 2003).

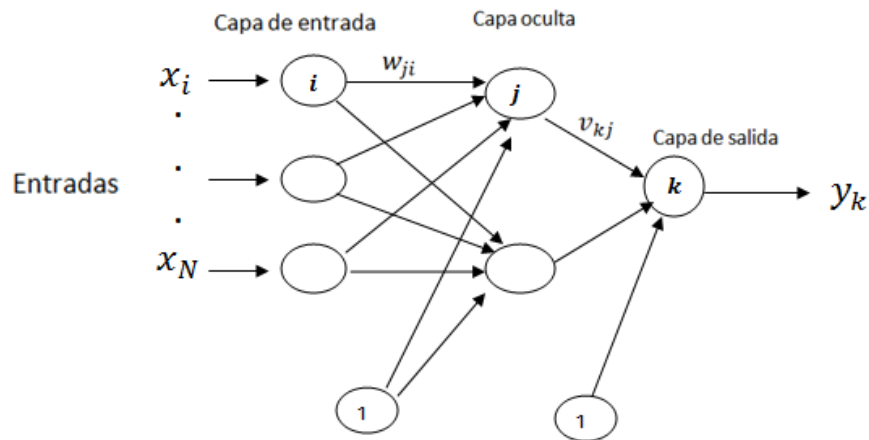


Figura 2. Esquema de un perceptron multicapa. En este ejemplo $X_i \dots X_N$ corresponden a las variables explicadoras, K a la variable dependiente y w_{ji} y v_{kj} a los pesos de cada una de las conexiones.

El entrenamiento inicialmente se realizo con el mismo tamaño de muestra empleado para el modelo de regresión logística (700.000 puntos), sin embargo con esta muestra el entrenamiento fue muy lento, por lo tanto se seleccionó una muestra de 250.000 puntos correspondientes al 3% de los datos. De esta muestra el 50% de los datos corresponde a puntos deforestados y el otro 50% a puntos que no se deforestaron. Esto se realizo con el fin de mejorar el rendimiento de la red y lograr una mejor generalización ya que para una muestra desbalanceada el aprendizaje de la red tiende a estar sesgado hacia la clase que presenta mayoría en el grupo de entrenamiento (Nguyen et al. 2009; Haibo He & Garcia 2009).

De acuerdo con lo sugerido por Gong (1996) los datos de entrada se estandarizaron con el fin de acelerar el entrenamiento de la red neuronal. La estandarización se realizo mediante el uso de los valores máximos y mínimos en la escala del conjunto de datos original. Al escalar cada variable la RNA asigna igual importancia a los datos, por lo tanto se evita el problema de variables con diferente relevancia debido a su rango de valores. La transformación se realizo a partir de la ecuación 4.

$$x'_i = (x_i - \text{minimo}) / (\text{maximo} - \text{minimo}) \quad (4)$$

Esta misma estandarización se utilizo para estimar el modelo de regresión logística.

Se entrenaron redes cambiando el valor de los parámetros, según las recomendaciones de Moreira & Fiesler (1995) los valores considerados para la tasa de entrenamiento fueron: 0.01, 0.05, 0.1, y para el momentum: 0.9 y 0.5. Estos valores permiten la evaluación de diferencias en el comportamiento de la red, lo que hace que el entrenamiento sea más robusto. Igualmente se vario la cantidad de neuronas en la capa oculta y se tomó como base

lo sugerido por Bishop (1995) quien afirma que el uso de $2n + 1$ neuronas ocultas (con n como el número de neuronas de entrada) puede garantizar el perfecto ajuste de cualquier función continua. En total se entrenaron 24 redes con un ciclo de entrenamiento de 5000 iteraciones, usando la función de activación logística tanto para la capa oculta como para la capa de salida.

Para evaluar la capacidad predictiva de los modelos, es decir su comportamiento frente a la entrada de nuevos datos, se evaluó el criterio de información de Akaike (CIA) para la regresión logística y el área bajo la curva ROC (Receiver Operating Characteristic en inglés) para ambos modelos. Con el valor de estos criterios se identificó el modelo de regresión logística que presentó mejor predicción y algunas tendencias en el entrenamiento de la red frente a diferentes conjuntos de parámetros, así como la red neuronal más adecuada para predecir la deforestación.

Las curvas ROC son índices de la exactitud diagnóstica de una prueba, por lo tanto proporcionan un criterio unificador en el proceso de evaluación de un modelo (Fawcett 2006). En la presente investigación el gráfico de la curva ROC se obtiene al definir varios valores umbrales para considerar un píxel como deforestado y graficar la proporción de verdaderos positivos o sensibilidad (deforestación correctamente predicha) en función de falsos positivos o especificidad (deforestación incorrectamente predicha).

Resultados

Modelo de regresión logística y validación

El análisis de correlación arrojó un valor de 0,61 en un par de variables: distancia a vías y distancia de menor costo a las cabeceras municipales. Por lo tanto, se estimaron dos

modelos, uno con todas las variables explicadoras y otro excluyendo la variable distancia de menor costo. El modelo que presento menor CIA y mejor rendimiento, es decir un AUC mayor, fue el modelo 1 estimado con todas las variables explicadoras, el modelo 2 presento predicciones similares (tabla 1), por lo tanto la exclusión o inclusión de la variable distancia de menor costo no generó cambios significativos en la predicción.

Tabla 1. Resultados del modelo de regresión logística.

| Variables explicadoras | Coeficientes de Regresión | |
|--|---------------------------|------------------------|
| | M1 | M2 |
| Intercepto | 0,0965 ^{***} | 0,0092 ^{***} |
| Distancia a ríos | -0,2561 ^{***} | -0,0738 ^{***} |
| Distancia a vías | -3,6448 ^{***} | -4,5801 ^{***} |
| Distancia de menor costo a las cabeceras municipales | -1,3139 ^{***} | — |
| Distancia al borde del bosque | -6,8115 ^{***} | -7,0798 ^{***} |
| Aptitud agrícola | 0,7274 ^{***} | 0,9734 ^{***} |
| Pendiente | -1,4224 ^{***} | -1,3060 ^{***} |
| CIA | 518.160 | 520.243 |
| AUC | 0,7760 | 0,7743 |

Valores de significancia: $p < .001$ ***.

Modelo de Red Neuronal y Validación

Las redes con una menor tasa de entrenamiento y mayor cantidad de neuronas en la capa oculta presentaron altos valores de AUC, (figura 3). Del conjunto de redes entrenadas, la red que presento mayor AUC fue la estimada con un momentum de 0.5, una tasa de entrenamiento de 0.05 y 30 neuronas en la capa oculta.

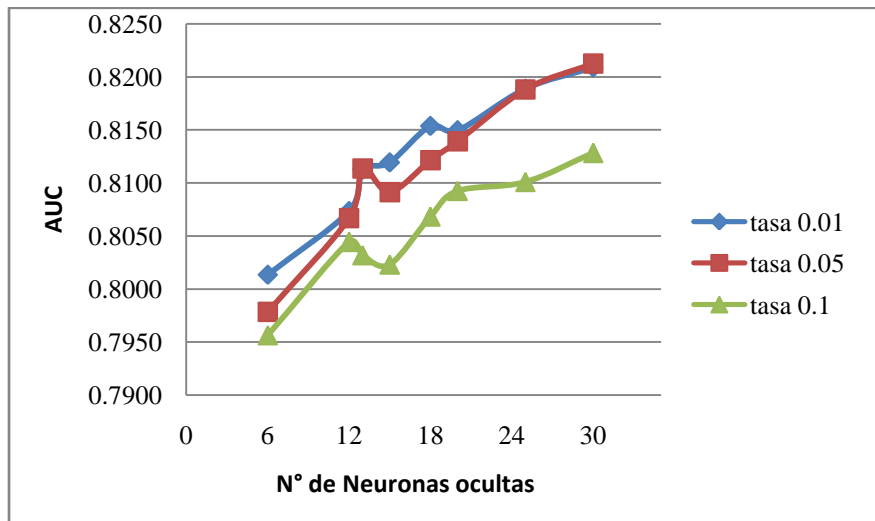


Figura 3. Curva ROC (AUC), con respecto a las tasas de entrenamiento y al número de neuronas ocultas para un ciclo de 5000 iteraciones.

Comparación entre la regresión logística y RNas (AUC/ROC)

El área bajo la curva ROC indica que las redes neuronales tienen mejor capacidad predictiva con respecto a los modelos de regresión logística. El gráfico 4 muestra la diferencia entre la curva ROC obtenida del modelo 1, estimado a partir de la regresión logística (línea morada) y la curva ROC de la red que presentó mejor predicción (línea azul). Con esta red se generó una superficie continua de probabilidad de deforestación para el área cubierta por bosques en 1980 (Figura 5).

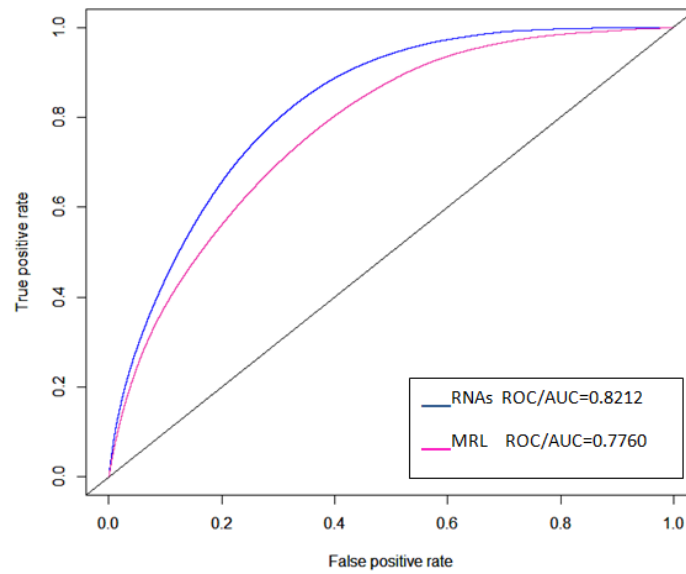


Figura 4. Evaluación de la capacidad predictiva entre el modelo de RNAs y la regresión logística (AUC/ROC).

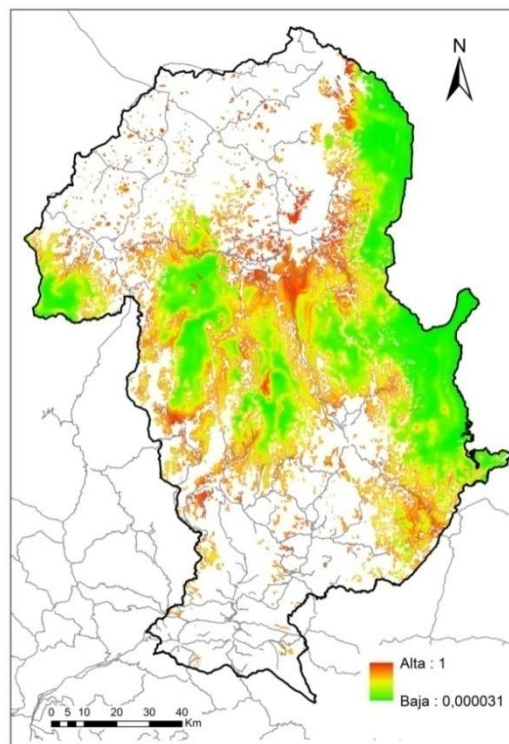


Figura 5. Superficie de probabilidad de deforestación generada del modelo de red neuronal. Tamaño de pixel: 30m. Las líneas en el mapa representan la red vial existente al inicio del periodo de análisis.

El modelo de RNas predice bajas probabilidades de deforestación (color verde) en la parte oriental de la región de estudio. Estas constituyen áreas remotas, con altas pendientes, baja densidad vial, donde se observó la menor conversión de bosques naturales entre 1980 y 2000. Las altas probabilidades de deforestación (en color rojo) se presentan a lo largo del borde del bosque y en la parte central cerca a la cabecera municipal de Zaragoza donde hay mayor densidad vial.

Discusión

Los signos de los parámetros de las variables coinciden con los signos esperados de manera anticipada. Una mayor distancia a vías, ríos y a las cabeceras municipales, así como una mayor pendiente conllevan a una menor deforestación. Por el contrario la aptitud agrícola refleja un efecto positivo sobre la deforestación (Tabla 1). Es decir, aquellas áreas más aptas para la agricultura exhiben mayores tasas de conversión de bosques, lo que es consistente con los resultados de un estudio de deforestación en Santa Cruz, Bolivia (Mertens et al. 2004)

Con respecto a los coeficientes de regresión, las variables distancia a vías y distancia al borde del bosque fueron las más importantes sobre la deforestación. Estudios realizados a nivel regional en Antioquia también concluyeron que la distancia a las vías fue un determinante de la deforestación. Estas variables han sido importantes impulsores del cambio de la cobertura boscosa en el sur de Camerún (Mertens & Lambin 1997), en las tierras bajas de Sumatra, Indonesia (Linkie et al. 2004) y factores importantes del cambio de los bosques en el sureste de México (Mas et al. 2004).

Los Modelos generados en la fase de entrenamiento tienen unas precisiones relativamente similares, con valores de AUC entre 0.80 y 0.82, Müller & Mburu (2009) también encontraron resultados similares con diferentes arquitecturas de red neuronal y Okwuashi et al. (2012) quienes simularon cambios en el uso del suelo en lagos Nigeria obtuvieron valores de AUC entre 0.7574 y 0.7850.

Aunque las redes con bajas tasas de entrenamiento presentaron mejores predicciones, el entrenamiento fue más lento comparado con las demás tasas. Por lo tanto el valor de la tasa de aprendizaje debe ser lo suficientemente grande como para permitir un proceso de aprendizaje rápido pero lo suficientemente pequeño como para garantizar su efectividad, para la presente investigación la tasa que presento buen rendimiento en cuanto a tiempos de entrenamiento y capacidad de generalización fue de 0.05.

El AUC permitió realizar una comparación general de los modelos estimados a partir de la regresión logística y RNAs, las cuales mostraron una capacidad predictiva superior de 0.8212, con respecto al modelo de regresión que presento un AUC de 0.7760, lo que puede ser resultado de la presencia de relaciones no lineales, las cuales no pueden ser detectadas por el modelo de regresión logística. Sanabria (2009) en su estudio realizado en Bolivia también encontró una diferencia significativa en la predicción de la deforestación con un AUC de 0.92 para las RNAs frente a 0,84 para la regresión logística.

Mientras el modelo de RNAs genero mejores predicciones, la regresión logística fue útil para entender la importancia relativa de las variables explicadoras sobre la deforestación, sin embargo se debe tener presente las limitaciones de la regresión para modelar fenómenos ambientales en presencia de autocorrelación espacial y en los cuales las variables

explicadoras están altamente correlacionadas (Thies et al. 2012; Mas et al. 2004), Por lo tanto se podrían realizar otros métodos estadísticos para identificar los determinantes de la deforestación, como modelos de rezago espacial que tiene en cuenta la presencia de autocorrelación a partir de un análisis de vecindad de las variables consideradas en el modelo (Overmars et al. 2003).

Conclusiones

Aunque no existen modelos ideales debido a que el proceso de deforestación depende de factores muy diversos que varían con el tiempo, la investigación presenta una herramienta metodológica diferente a la regresión logística, que puede ser generalizable a otros lugares y que ofrece la posibilidad de producir diferentes escenarios que permitan evaluar las estrategias de gestión del uso del suelo.

Las redes neuronales no deben ser consideradas un modelo de caja negra, si bien el análisis del funcionamiento interno de la red es una tarea compleja, varias investigaciones han interpretado la contribución de las variables de entrada (Intrator & Intrator 2001; Dai et al. 2005), y han proporcionado diferentes enfoques metodológicos para la interpretación de las variables (Gevrey et al. 2003), por lo tanto, más que ser un modelo predictivo puede ser usado como un modelo explicativo.

En el pasado, ha sido difícil investigar las particularidades geográficas y ambientales del territorio a partir de métodos computacionales, por la dificultad en el análisis espacial de datos. Sin embargo, los nuevos desarrollos en el software de información geográfica, la rápida disminución de los costos en la capacidad computacional y el desarrollo de nuevas

técnicas analíticas han facilitado la investigación y aplicación de las redes neuronales en el desarrollo de modelos cuantitativos.

La superación de los problemas de la estructura y tamaño de la red sería un gran paso hacia un mayor entendimiento de las redes neuronales artificiales. Hay una necesidad de investigación para mejorar el diseño y el análisis a través de métodos formales que no se basen en ensayos de prueba y error, y que permitan un uso más productivo y eficaz de las redes en la ecología y ciencias ambientales.

Bibliografía.

- Armenteras, D., Rudas, G. & Rodríguez, N. (2006). Patterns and causes of deforestation in the Colombian Amazon. *Ecological Indicators*, 6(2), pp.353–368.
- Bishop, C.M. (1995). *Neural Networks for Pattern Recognition*, Oxford: Oxford University Press.
- Butine, W.L. & Weigend, A.S. (1991). Bayesian Back-Propagation. *Complex Systems*, 5, pp.603–643.
- Comrie, A.C. (1997). Comparing Neural Networks and Regression Models for Ozone Forecasting. *Journal of the Air & Waste Management Association*, 47(6), pp.653–663.
- Dai, E., Wu, S., Shi, W., Cheung, C. & Shaker, A. (2005). Modeling Change-Pattern-Value Dynamics on Land Use: An Integrated GIS and Artificial Neural Networks Approach. *Environmental Management*, 36(4), pp.576–591.
- Eraso, N.R., Armenteras, D. & Alumbrosos, J.R. (2013). Land use and land cover change in the Colombian Andes: dynamics and future scenarios. *Journal of Land Use Science*, 8(2), pp.154–174.
- Esri. (2009). ArcGIS (Versión 10.1) Software de procesamiento digital de imágenes satelitales. En Los Ángeles, Estados Unidos: Environmental Systems Research Institute, Inc.

- Etter, A., McAlpine C., Pullar D. & Possingham H. (2006a). Characterizing a tropical deforestation wave: a dynamic spatial analysis of a deforestation hotspot in the Colombian Amazon. *Global Change Biology*, 12(8), pp.1409–1420.
- Etter, A., McAlpine, C., Pullar, D. & Possingham H. (2006b). Modelling the conversion of Colombian lowland ecosystems since 1940: Drivers, patterns and rates. *Journal of Environmental Management*, 79(1), pp.74–87.
- Fawcett, T. (2006). An introduction to ROC analysis. *ROC Analysis in Pattern Recognition*, 27(8), pp.861–874.
- Gevrey, M., Dimopoulos, I. & Lek, S. (2003). Review and comparison of methods to study the contribution of variables in artificial neural network models. *Modelling the structure of aquatic communities: concepts, methods and problems.*, 160(3), pp.249–264.
- Gobernación de Antioquia, IDEA & IGAC. (2007). *Antioquia características geográficas*, Bogotá, Colombia: Imprenta Nacional de Colombia.
- Gong, P. (1996). Integrated analysis of spatial data from multiple sources : Using evidential reasoning and artificial neural network techniques for geological mapping. *Photogrammetric Engineering & Remote Sensing*, 62(5), pp.513–523.
- Haibo He & Garcia, E. (2009). Learning from Imbalanced Data. *IEEE Transactions on Knowledge and Data Engineering*, 21(9), pp.1263–1284.
- Haykin, S. (1999). *Neural Networks, A Comprehensive Foundation* 2^a ed., Hamilton, Canada: Prentice- Hall International, Inc.
- Intrator, O. & Intrator, N. (2001). Interpreting neural-network results: a simulation study. *Computational Statistics & Data Analysis*, 37(3), pp.373–393.
- Linkie, M., Smith, R. & Leader-Williams, N. (2004). Mapping and predicting deforestation patterns in the lowlands of Sumatra. *Biodiversity & Conservation*, 13(10), pp.1809–1818.
- Mas, J.F., Puig, H., Palacio, J.L., Sosa, A. (2004). Modelling deforestation using GIS and artificial neural networks. *Environmental Modelling & Software*, 19(5), pp.461 – 471.
- Mertens, B., Kaimowitz, D., Puntodewo, A., Vanclay, J., Mendez, P. (2004). Modelling Deforestation at Distinct Geographic Scales and Time Periods in Santa Cruz, Bolivia. *International Regional Science*, 27(3), pp.271–296.
- Mertens, B. & Lambin, E. (1997). Spatial modelling of deforestation in southern Cameroon. *Applied Geography*, 17(3), pp.143–162.

- METI & NASA. (2009). ASTER Global Digital Elevation Map. Obtenido de <http://asterweb.jpl.nasa.gov/gdem.asp>.
- Moreira, M. & Fiesler, E. (1995). Neural Networks with Adaptive Learning Rate and Momentum Terms. IDIAP Technical Report.
- Müller, D. & Mburu, J. (2009). Forecasting hotspots of forest clearing in Kakamega Forest, Western Kenya. *Forest Ecology and Management*, 257(3), pp.968–977.
- Nelson, G., Harris, V. & Stone, S. (1999). *Spatial Econometric Analysis and Project Evaluation: Modeling Land Use Change in the Darién*, Washington, D.C.
- Nguyen, G.H., Bouzerdoun, A. & Phung, S. (2009). Learning pattern classification tasks with imbalanced data sets. En *Pattern recognition*. Vukovar, Croatia: Intech, pp. 193–208.
- Okwuashi, O., Isong, M., Eyo, E., Eyoh, A., Nwaneke, O., Olayinka, D., Udoudo, Daniel. & Ofem, B. (2012). GIS Cellular Automata Using Artificial Neural Network for Land Use Change Simulation of Lagos, Nigeria. *Journal of Geography and Geology*, 4(2), pp.94–101.
- Orrego, S. (2009). Economic modeling of tropical deforestation in Antioquia (Colombia), 1980-2000: an analysis at a semi-fine scale with spatially explicit data. Ph D Dissertation. Oregon State University.
- Overmars, K., de Koning, G. & Veldkamp, A. (2003). Spatial autocorrelation in multi-scale land use models. *Ecological Modelling*, 164(2), pp.257–270.
- Plagianakos, V.P., Magoulas, G.D. & Vrahatis, M.N. (2001). Learning Rate Adaptation in Stochastic Gradient Descent. En N. Hadjisavvas & P. Pardalos, eds. *Advances in Convex Analysis and Global Optimization. Nonconvex Optimization and Its Applications*. Springer US, pp. 433–444. disponible en: http://dx.doi.org/10.1007/978-1-4613-0279-7_27.
- R Development Core Team. (2008). *R: A language and environment for statistical computing*. En Vienna: R Foundation for Statistical Computing.
- Sanabria, N.J. (2009). *Spatial Modelling and Prediction of Tropical Forest Conversion in the Isiboro Sécure National Park and Indigenous Territory (TIPNIS), Bolivia*. MSc. The Netherlands: International Institute For Geo-Information Science and Earth Observation.
- Savage, A., Guillen R., Lamilla, I. & Soto L. (2010). Developing an effective community conservation program for cotton-top tamarins (*Saguinus oedipus*) in Colombia. *American Journal Of Primatology*, 72(5), pp.379–390.

- Thies, B., Meyer, H., Nauss, T. & Bendix, J. (2012). Projecting land-use and land-cover changes in a tropical mountain forest of Southern Ecuador. *Journal of Land Use Science*, 9(1), pp.1–33.
- Wilson, D.R. & Martinez, T.R. (2003). The general inefficiency of batch training for gradient descent learning. *Neural Networks*, 16(10), pp.1429–1451.
- Yilmaz, I. (2009). Landslide susceptibility mapping using frequency ratio, logistic regression, artificial neural networks and their comparison: A case study from Kat landslides (Tokat—Turkey). *Computers & Geosciences*, 35(6), pp.1125–1138.