

Detección de cambios en la cobertura vegetal mediante interpretación de imágenes Landsat por redes neuronales artificiales (RNA). Caso de estudio: Región Amazónica Ecuatoriana

Jaramillo, L.V.*, Antunes, A. F.

¹ *Universidad Federal de Paraná – UFPR, Sector de Ciencias de la Tierra – Departamento de Geomática - Programa de Posgrado en Ciencias Geodésicas - Curitiba, Paraná, Brasil.*

Resumen: La interpretación de clases y detección de cambios en la cobertura vegetal de áreas extensas son actividades que se viabilizan mediante el uso de tecnologías y métodos asociados a la Percepción Remota. Imágenes satelitales de media y alta resolución espacial y espectral constituyen herramientas fundamentales para la ejecución de proyectos que tienen como objetivo principal la clasificación de la cobertura vegetal y la detección de sus variaciones temporales. Para explotar de mejor forma el uso de la información del territorio recuperada por las imágenes satelitales, y con el fin de optimizar los recursos invertidos en las tareas de clasificación e interpretación, es requerimiento disponer de herramientas y métodos que permitan la automatización de los procesos involucrados. Las Redes Neuronales Artificiales (RNAs) demuestran ser un mecanismo adecuado para la ejecución de estos procesos. El presente trabajo, tiene como principal objetivo validar una metodología para la identificación de cambios en la cobertura vegetal de un área localizada en la Amazonía ecuatoriana. La metodología aplicada busca principalmente la detección de cambios en la cobertura de bosques nativos predominantes en la región de estudio.

Palabras clave: Redes Neuronales Artificiales, detección de cambios, imágenes satelitales.

Change detection in vegetation cover through interpretation of Landsat images by artificial neural networks (ANN). Case study: Ecuadorian Amazon Region

Abstract: The interpretation of classes and change detection in the vegetation cover of large areas are activities that are made possible by the use of technologies and methods associated to Remote Sensing. Satellite images of medium and high spatial and spectral resolution are fundamental tools for the execution of projects with objectives of classification of vegetal cover and detection of its temporal variations. To exploit the use of digital information of territory recovered by the satellite images, and in order to optimize the resources invested in the tasks of classification and interpretation, it is necessary to have tools and methods that allow the automation of the processes involved and prove to be the Artificial Neural Networks (ANNs) an adequate mechanism for the execution of these processes. The main objective of this work is to validate a methodology for the identification of changes in the vegetation cover of an area located in the Ecuadorian Amazon. The applied methodology seeks the change detection in the coverage of native forests prevailing in the study region.

Key words: Artificial Neural Network, change detection, satellite images.

To cite this article: Jaramillo, L.V., Antunes, A.F. 2018. Change detection in vegetation cover through interpretation of Landsat images by artificial neural networks (ANN). Case study: Ecuadorian Amazon Region. *Revista de Teledetección*, 51, 33-46. <https://doi.org/10.4995/raet.2018.8995>

* *Corresponding author: jagadananda1@hotmail.com*

1. Introducción

Los bosques abarcan aproximadamente el 30% del área continental y constituyen uno de los elementos clave en el funcionamiento y equilibrio de los ecosistemas, dando albergue a una amplia gama de especies vegetales y animales. Actúan también como transmisores y receptores de carbono, siendo el ciclo natural de este elemento químico uno de los procesos fundamentales para el desarrollo de la flora y la fauna en el planeta. Los sistemas boscosos también proporcionan un conjunto de elementos clave (e.g. madera, leña, carbón) para el desarrollo de actividades humanas vinculadas al desarrollo industrial y agrícola.

El crecimiento exponencial de la población a escala global, el acelerado desarrollo industrial y tecnológico registrado en las últimas décadas, junto con la consecuente expansión agrícola y urbana, han generado una creciente demanda de insumos provenientes de los bosques. Este fenómeno ha desencadenado en la explotación no sostenible de los recursos forestales, lo cual representa una amenaza para el equilibrio de los ecosistemas naturales.

Según Achard (2002), la cobertura de bosques en el planeta ha sufrido rápidos cambios desde los años 80; es así que para el año 1990 se registraba un total aproximado de 4128 millones de hectáreas de bosque distribuidas en el planeta, mientras que para el año 2015 la cobertura boscosa global se estimaba en 3999 millones de hectáreas. De acuerdo con Keenan *et al.* (2015), las mayores pérdidas de cobertura vegetal han ocurrido en los trópicos, particularmente en Centroamérica, Sudamérica y África, no obstante para el período 2010-2015 el área forestal se expandió en Europa, América del Norte, el Caribe, Asia Oriental y Asia Central Occidental.

En las últimas décadas la atención dada a los métodos y técnicas orientadas a la detección de cambios en la cobertura vegetal ha crecido gradualmente, debido principalmente a que la deforestación de vastas zonas de territorio tiene relación directa con problemas relacionados con el cambio climático global, degradación de suelos y fuentes de agua, protección de la biodiversidad, seguridad alimentaria, entre otros (Angelsen y Kaimowitz, 1999).

Debido a los aspectos antes mencionados, es de fundamental importancia el desarrollo de estudios vinculados al funcionamiento de los ecosistemas forestales y las implicaciones que las distintas acciones antrópicas tienen sobre su equilibrio. La información fiable y actualizada permite tomar decisiones y ejecutar acciones adecuadas y oportunas para el manejo sostenible de los recursos forestales.

Ecuador contiene un territorio con gran biodiversidad atribuida principalmente a la variedad de climas, tipos de suelo y pisos altitudinales. Actualmente, el país considera entre sus políticas de gestión del territorio la conservación y manejo sostenible de sus recursos naturales. Históricamente los bosques nativos de Ecuador han sido afectados por procesos extractivistas que han generado su degradación y surgimiento de focos de deforestación, estos procesos están relacionados con factores tales como la expansión agrícola y urbana, crianza de ganado, extracción maderera, procesos industriales, entre otras acciones ya mencionadas anteriormente que persiguen fundamentalmente la consecución de beneficios económicos y satisfacer la creciente demanda de insumos y servicios ambientales derivados de los bosques.

En este trabajo se desarrolla una metodología para la detección oportuna de alteraciones en la cobertura boscosa de una región localizada en la amazonia ecuatoriana. El área de estudio fue seleccionada por abarcar predominantemente cobertura de bosque nativo (aproximadamente 52% del área total) y también en función de la disponibilidad de imágenes satelitales. Debido a la heterogeneidad de coberturas presentes en el área de estudio, el análisis no es realizado únicamente para las regiones que contienen bosques nativos; sin embargo, el objeto principal del estudio corresponde a la detección de cambios en la cobertura boscosa. Para estos fines, Redes Neuronales Artificiales (RNAs) multicapa son sometidas a procesos de aprendizaje para que adquieran la capacidad de clasificar de forma automática imágenes satelitales ópticas de resolución media. El aprendizaje de las RNAs es realizado en función de ejemplos o muestras, estos ejemplos de entrenamiento deben provenir de observaciones de la cobertura vegetal *in situ*, no obstante, en el presente trabajo por no estar disponibles muestras de campo, los ejemplos de

entrenamiento fueron generados mediante interpretación visual sobre las imágenes satelitales con el auxilio de cálculo de índice de vegetación normalizado (NDVI). La metodología empleada en la presente investigación es replicable para otras áreas de estudio y considerando otros tipos de coberturas, también el uso de imágenes satelitales provenientes de otros sensores puede ser evaluado en futuros estudios.

2. Detección de cambios con imágenes satelitales

La detección de cambios es el proceso de identificar diferencias en el estado de un objeto o fenómeno mediante observación en tiempos diferentes (Singh, 1989)

Esta discriminación de diferencias en el tiempo puede ser realizada mediante la interpretación de imágenes satelitales de acuerdo a dos enfoques básicos, basada en píxeles y basada en objetos. La detección de cambios por objetos, en general obedece a métodos actuales y mayormente sofisticados que han sido desarrollados a partir del uso de imágenes con mayor resolución espacial. İlsever y Ünsalan (2012).

De acuerdo a lo señalado por Singh (1989), entre los principales métodos para la detección de cambios mediante el uso de imágenes satelitales se tiene: diferencia de imágenes, regresión de imágenes, relación de imágenes, diferencias de índices de vegetación, Análisis de Componentes Principales (ACP), comparación pos-clasificación y análisis de vectores de cambios. Algunos de los métodos más actuales para la detección de cambios son enumerados en el trabajo de Lu *et al.* (2004) entre estos: análisis de combinación espectral, modelo de dosel de *Li-Strahler*, transformación de Chi-cuadrado, métodos *fuzzy* y Redes Neuronales Artificiales (RNAs). En el presente estudio la detección de cambios fue realizada mediante el uso de RNAs, detalles del método se encuentran en la siguiente sección.

Aspectos relacionados a las condiciones particulares del instante y lugar de la adquisición de la imagen deben ser considerados para que la detección de cambios no genere resultados erróneos y de esta forma los cambios detectados en el análisis multitemporal correspondan a alteraciones reales acontecidas en la cobertura de la región estudiada.

Entre estos aspectos se deben considerar condiciones atmosféricas, ángulo de incidencia solar, humedad del suelo y época de adquisición de las imágenes. Adicionalmente, el correcto registro geométrico y corrección radiométrica de las imágenes son procedimientos que obligatoriamente deben ser ejecutados antes de aplicar el método orientado a la detección de cambios (Ambrosio *et al.*, 2009).

2.1. Redes Neuronales Artificiales

Las RNAs forman parte del conjunto de técnicas relacionadas con la inteligencia artificial (IA) y se basan en la capacidad de aprendizaje de los sistemas biológicos (Isasi y Galván, 2004).

Según Haykin (2001), cada interconexión entre las unidades del sistema (neuronas) (Figura 1) actúa como un canal de comunicación por medio del cual circulan señales de una neurona hacia otra, esas señales son evaluadas por una estructura de pesos sinápticos (parámetros libres) asociados a cada una de las conexiones y que son iterativamente modificados durante la fase de aprendizaje hasta que la red asimile la información recibida durante el entrenamiento y adquiera la capacidad de generalización.

La siguiente expresión vectorial (Ecuación 1) representa el funcionamiento básico de una RNA (Isasi y Galván, 2004):

$$\vec{Y} = f_2(f_1(\vec{X} \cdot \vec{\omega}_1) \vec{\omega}_2) \quad (1)$$

donde:

\vec{X} = Vector de entrada a la red neuronal (conjunto de entradas)

\vec{Y} = Vector de salida de la red neuronal

f_1 = Función de transferencia de la capa oculta

$\vec{\omega}_1$ = Vector de pesos sinápticos de la capa oculta

f_2 = Función de transferencia de la capa de salida

$\vec{\omega}_2$ = Vector de pesos sinápticos de la capa de salida

Existen diversos algoritmos usados para el entrenamiento de las RNAs, la selección del algoritmo depende fundamentalmente del tipo de problema que la red deberá resolver (Isasi y Galvan, (2004)

Según Haykin (2001), los algoritmos utilizados para el entrenamiento de las RNAs se basan en

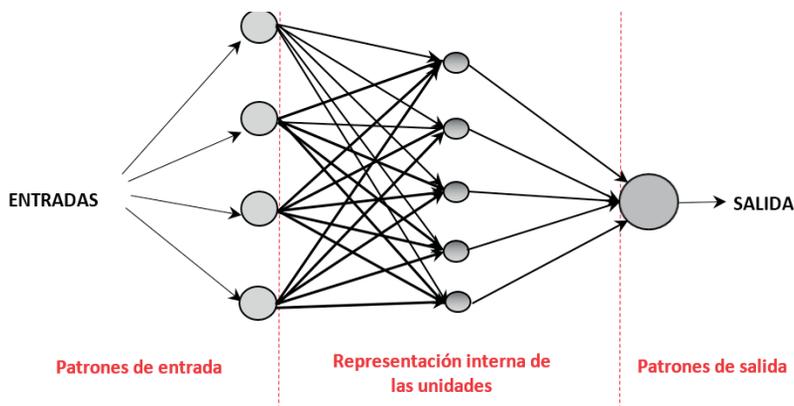


Figura 1. Esquema de una Red Neuronal Artificial (RNA) de tres capas interconectadas. *Fuente:* Adaptado de Isasi y Galván (2004).

procedimientos de minimización de funciones de error a través de resolución de problemas de mínimos cuadrados no lineales, entre los principales tenemos: el método de *Newton*, el método de *Gauss-Newton* y el método de *Levenberg-Marquardt*, siendo éste último el utilizado para entrenar las RNAs multicapa.

La detección de alteraciones basada en RNAs implica la utilización de muestras bien establecidas (entradas de entrenamiento) para el aprendizaje de la red, la cantidad y calidad de los datos disponibles son factores de extrema importancia relacionados directamente con la capacidad de generalización que alcanza la RNA (Moya, 2012). Según Basogain (2008), el entrenamiento de la RNA requiere la definición de tres subconjuntos de datos: entrenamiento propiamente dicho, validación y test.

2.2. Área de estudio

La Región Amazónica Ecuatoriana (RAE) contiene aproximadamente el 70% de los bosques nativos del país, la cobertura vegetal natural no registró mayores cambios hasta la segunda mitad del siglo XX. El rápido avance de la frontera agrícola y las actividades relacionadas con la exploración de petróleo produjeron hasta el año 1999 la degradación de aproximadamente el 12% de la vegetación natural presente en esta región (Valencia *et al.*, 1999). Registros recientes de deforestación en los bosques nativos de la RAE han sido estimados y reportados por el Ministerio de Ambiente del Ecuador (MAE), siendo que para el periodo

1990-2000 la tasa de deforestación registrada en la RAE es de 32655 ha/año, y para el periodo 2000-2008 de 37991 ha/año (MAE, 2012a).

Para aplicar la metodología propuesta en el presente trabajo, un área de aproximadamente 734 km² fue seleccionada en función del tipo de cobertura vegetal contenido y de la disponibilidad de imágenes satelitales. La región contiene los principales tipos de cobertura vegetal que caracterizan a la RAE y está localizada en la provincia de Orellana, presentando alturas sobre el nivel medio del mar que varían desde 200 hasta 500 m. La tabla 1 contiene las coordenadas extremas de la región de estudio.

Tabla 1. Coordenadas del área de estudio. *Fuente:* Los autores (2015).

Norte	-0,270829°	Sur	-0,586886°
Este	-76,914154°	Oeste	-77,102848°

La Figura 2 muestra la localización del área seleccionada para la realización del estudio.

2.3. Imágenes satelitales

Las imágenes utilizadas para el desarrollo del presente estudio corresponden a adquisiciones realizadas por las misiones LANDSAT 5 y LANDSAT 8. La detección de cambios en el área de estudio (Figura 2) fue realizada para dos periodos: 1990-1999 y 1999-2013. Las tres imágenes, previamente sometidas a correcciones de nivel L1T (*Standar Terrain Correction*), USGS (2014), fueron seleccionadas bajo el criterio de minimizar la cobertura de nubes y se obtuvieron del servicio

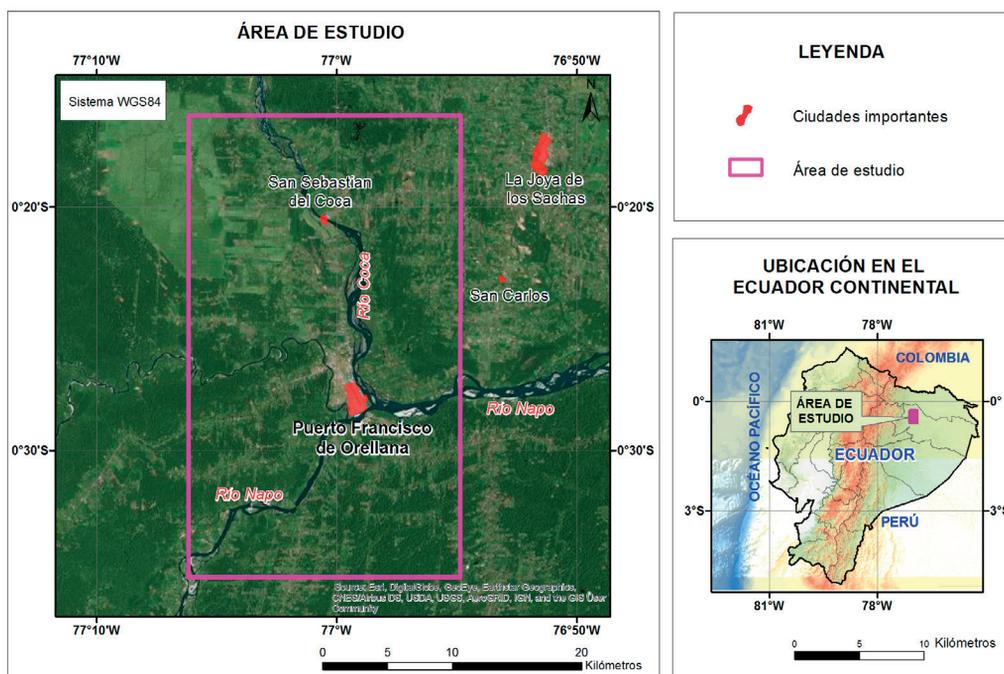


Figura 2. Área de estudio. Fuente: SIGTIERRAS (Ministerio de Agricultura, Ganadería y Pesca - Ecuador), DigitalGlobe, GeoEye and the GIS Users Community. Elaboración: Los autores (2015).

web <http://glovis.usgs.gov/del> U.S. Geological Survey de los Estados Unidos (USGS). Detalles de las imágenes se muestran en la Tabla 2.

Con el fin de minimizar las distorsiones de las imágenes debido a la dispersión atmosférica de la señal y a errores geométricos presentes en el nivel de corrección L1T, es necesario realizar correcciones adicionales.

Considerando el hecho de que la detección de cambios en el presente trabajo prioriza la cuantificación de las variaciones en la cobertura boscosa, son utilizadas las bandas cuya información presenta mayor correspondencia con la respuesta espectral de la vegetación. De esta forma, se

emplearon en el análisis las bandas correspondientes al rojo (R) y al infrarrojo cercano (NIR) de cada imagen para los períodos considerados (1990-1999) (1999-2013).

2.3.1. Corrección de las imágenes

Según lo propone Crosta (1999), el registro de las imágenes fue realizado con el fin de evitar falsas alteraciones en la detección de cambios. La corrección atmosférica, por su parte, es ejecutada con las herramientas informáticas del paquete LEDAPS (*Landsat Ecosystem Disturbance Adaptive Processing System*) generadas y distribuidas gratuitamente por la NASA y por la

Tabla 2. Características de las imágenes satelitales utilizadas.

Datos de la imagen	1990	1999	2013
ID de Imagen	LT50090601990038CPE04	LT50090601999319CPE00	LC80090602013357LGN00
Fecha de adquisición	07/02/1990	15/11/1999	23/12/2013
Tipo de Sensor	L5 - TM	L5 - TM	OLI-TIRS
Nivel de procesamiento	L1T	L1T	L1T
Azmut del sol (°)	112.98255620	124.45396311	134.29229543
Elevación del sol (°)	47.57863726	55.95529097	55.30526372
Tiempo Central (GTM)	14:41:52	14:55:47	15:21:34

Universidad de Maryland. Este software fue desarrollado originalmente para generar valores de reflectancia en el tope de la atmósfera en base a productos LANDSAT (*Landsat Thematic Mapper and Enhanced Thematic Mapper Plus Level 1*) y para aplicar correcciones atmosféricas con el objetivo de generar valores de reflectancia en superficie. Estas correcciones atmosféricas se basan en la Segunda Simulación de la Señal de Satélite en el Espectro Solar (6S) del modelo de transferencia de radiación, (Vermote *et al.*, 1997; Kotchenova *et al.*, 2006).

La corrección atmosférica mediante LEDAPS considera fuentes de datos auxiliares sobre presión y temperatura del aire, concentración de ozono; adicionalmente utiliza el modelo de Densidad de Vegetación Oscura (Kaufman *et al.*, 1997) para la recuperación de la concentración de aerosoles (Schmidt *et al.*, 2013). La corrección radiométrica de las imágenes fue realizada según la metodología propuesta por Chander y Markham (2003).

2.3.2. Segmentación de las imágenes

La detección de cambios se realizó a nivel de píxel y a nivel de objetos, en este segundo caso es requerimiento la discriminación de píxeles con características espectrales similares, siendo agrupados mediante segmentos.

Para la segmentación de las imágenes se utilizó el método de crecimiento de regiones por agregación de píxeles, disponible en el paquete de

herramientas *Open Foris* (OPEN-FORIS-FAO, 2009). La segmentación multifecha se realizó considerando los siguientes parámetros: 50 píxeles para el tamaño mínimo de segmento y el valor de cero (0) para la distancia espectral mínima, distancia espectral máxima y peso.

En la figura 3 se puede apreciar la segmentación multifecha obtenida para los dos periodos analizados contrastada con una combinación de imagen RGB-432 para mejor visualización. Para la segmentación multifecha se emplearon las bandas roja e infrarroja de los años 1990 y 1999 para el periodo 1 y años 1999 y 2013 para el periodo 2.

Una vez generada la segmentación multifecha, se calcula el valor medio por segmento para los valores digitales correspondientes a las bandas utilizadas. Así se organiza la información espectral proveniente de las imágenes para que el análisis multitemporal (periodo 1 y periodo 2) de los objetos identificados en la imagen pueda realizarse.

2.4. Clasificación de la cobertura

Los tipos de cobertura establecidos para la detección de cambios se basan en la leyenda del Panel Intergubernamental sobre Cambios Climáticos (IPCC por sus siglas en inglés), la cual fue adaptada por el Ministerio del Ambiente del Ecuador (MAE, 2012b) en el contexto del desarrollo del proyecto Mapa de Deforestación Histórico del Ecuador (MAE, 2012).

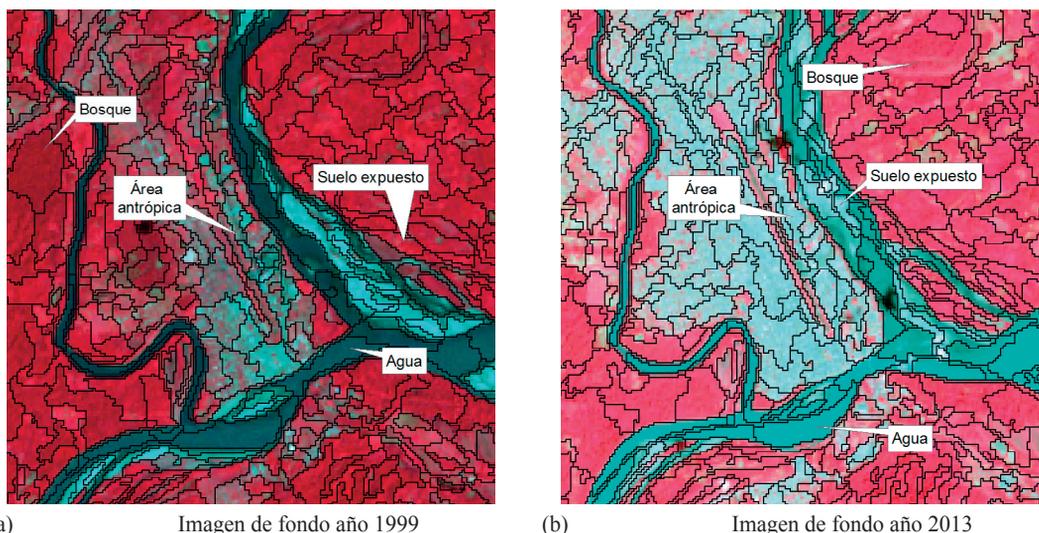


Figura 3. Segmentación multifecha, (a) 1990-1999, (b) 1999-2013.

Tabla 3. Clases consideradas para la detección de cambios.

Clases (*TCl)	Clases (**TCF)		Áreas		
	Bosque	agropecuarias	Vegetación arbustiva y herbácea	Cuerpos de agua	Áreas antrópicas
Bosque	s/c	c	n/o	n/o	n/o
Áreas agropecuarias	n/o	s/c	n/o	c	c
Vegetación arbustiva y herbácea	n/o	n/o	s/c	n/o	n/o
Cuerpos de agua	n/o	c	n/o	s/c	n/o
Áreas antrópicas	n/o	c	n/o	n/o	s/c

(*Tipo de Cobertura Inicial **Tipo de cobertura final).

Dentro de la región de estudio se definieron cinco clases de cobertura de las cuales se realizará la detección de alteraciones: bosque, áreas agropecuarias, vegetación arbustiva y herbácea, cuerpos de agua y áreas antrópicas. Los cambios en la cobertura se determinaron de acuerdo a las clases establecidas en la tabla 3. En ella se aprecian los eventos que serán detectados mediante el entrenamiento de la RNA, las clases ‘c’ y ‘s/c’ corresponden con los eventos cambio y no cambio respectivamente. La clase ‘n/o’ se atribuye a aquellos eventos que no tienen ocurrencia dentro del área de estudio.

Los eventos de cambio y no cambio detallados en la tabla 3, se relacionan con las clases correspondientes que deberán ser interpretadas por la RNA (Tabla 5).

2.5. Entrenamiento de las RNAs

Para la detección de cambios en la cobertura del área de estudio se realizó el entrenamiento de 4 RNAs, considerando un análisis a nivel de píxel y a nivel de segmentos.

Las muestras utilizadas para el entrenamiento de las RNAs fueron obtenidas mediante interpretación visual de las imágenes, esta interpretación se realizó con el auxilio de valores de NDVI asociados a las escenas LANDSAT. En total se emplearon 4 conjuntos de muestras para el entrenamiento de las RNAs, según se observa en la tabla 4.

Los conjuntos de entrenamiento se generaron de forma independiente considerando los dos períodos de estudio (Periodo 1: imágenes de los años 1990 y 1999; Periodo 2: imágenes de los años 1999 y 2013) y en función del tipo de análisis realizado (e.g. por píxel o por objetos).

Para realizar el entrenamiento de las RNAs, es necesario que cada una de las muestras pertenecientes a los conjuntos de entrenamiento (Tabla 4), esté asociada con un valor relacionado a los tipos de cambios/no cambios (salidas de la RNA) (Tabla 5) y con la información espectral proveniente de los valores en las bandas del rojo e infrarrojo cercano de las imágenes (entradas de la RNA). Los valores digitales oriundos de las imágenes de satélite constituyen las entradas de la RNA (Figura 4), en tanto que los atributos relacionados con las clases cambio/no cambio son obtenidos mediante interpretación visual de las imágenes (con ayuda del NDVI) y corresponden a la salida de la red.

La salida esperada de la red (*targets*) corresponde a las clases consideradas para la detección de cambios (Tabla 5), asociadas a un atributo numérico que permite realizar los cálculos inherentes al proceso iterativo de aprendizaje de la RNA. Estos valores numéricos fueron definidos en relación proporcional a los intervalos del NDVI asociado con cada tipo de cobertura. Así por ejemplo, si en el periodo 1 la clase corresponde a agua y en el segundo periodo corresponde a

Tabla 4. Número de muestras por conjunto de entrenamiento.

Conjunto	Número de muestras			
	Entrenamiento	Validación	Test	Total/conjunto
Nivel píxel: 1990-1999	302	100	100	502
Nivel píxel: 1999-2013	180	60	60	300
Nivel segmento: 1990-1999	110	33	22	165
Nivel segmento: 1999-2013	100	30	20	150
TOTAL				1117

Tabla 5. Clases atribuidas para el entrenamiento de las RNAs.

Clase Periodo 1	Clase Periodo 2	Salida de la RNA
Agua	Agua	1
Agua	Área agropecuaria	2
Áreas antrópicas	Áreas antrópicas	3
Áreas antrópicas	Agropecuaria	4
Vegetación arbustiva y herbácea	Vegetación arbustiva y herbácea	5
Bosque	Bosque	6
Bosque	Área agropecuaria	7
Área agropecuaria	Agua	8
Área agropecuaria	Áreas antrópicas	9
Área agropecuaria	Área agropecuaria	10

área agropecuaria, el valor para la salida corresponde al número 2 (Tabla 5). Se utilizó una red multicapa con una neurona de salida; los valores obtenidos en la capa de salida corresponden a valores continuos cercanos a los establecidos en la tabla 5 para salida de la red, por lo tanto en la clasificación final se asignó el valor discreto más cercano al resultado.

En el caso de la detección de cambios realizada a nivel de objeto, los valores utilizados como entrada y salida de la RNA corresponden a valores medios calculados a nivel de segmento.

Los datos de los subconjuntos de entrenamiento, validación y *test* se normalizaron considerando un valor de media igual a cero y una desviación estándar de uno. La normalización se realizó con el objetivo de homogeneizar la magnitud de las variables involucradas y se hizo tanto para los

valores a nivel de píxel como para los valores medios atribuidos a los segmentos.

Las redes utilizadas en este trabajo son del tipo *feedforward* (propagación hacia adelante), con tres capas interconectadas. La capa oculta tiene diez neuronas y la capa de salida una neurona, por lo cual se reflejarán valores continuos cercanos a los asignados de 1-10 dependiendo del cambio detectado (Figura 4). La arquitectura de la red fue determinada mediante el proceso de prueba y error.

El algoritmo de aprendizaje utilizado para el entrenamiento de las RNAs es el de *Levenberg-Marquardt*. La función de transferencia utilizada en la capa oculta es la tangente sigmoide, mientras que en la capa de salida es de tipo lineal. La función de error a ser minimizada es el Error Cuadrático Medio (ECM).

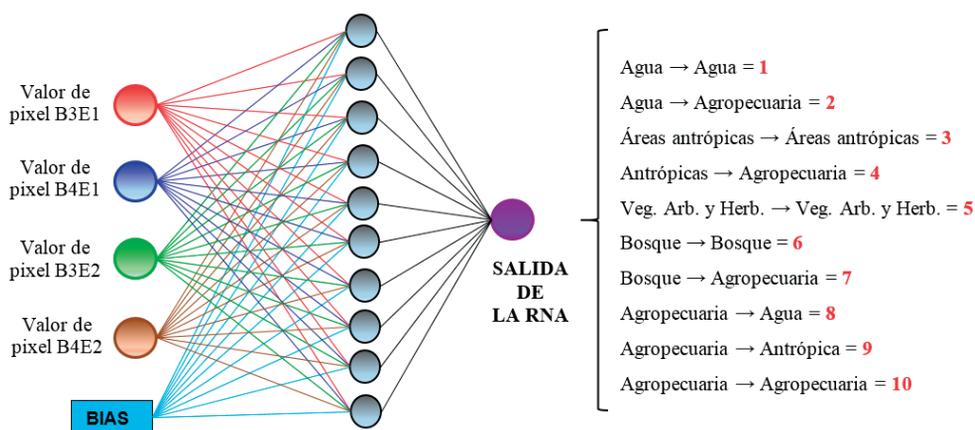


Figura 4. Arquitectura de las RNAs entrenadas.

Tabla 6. ECM, valor máximo y valor mínimo obtenidos en el entrenamiento de los conjuntos de entrenamiento, validación y *test* en los periodos 1 y 2.

Periodo	Nivel de información	Datos estadísticos	Conjunto de Entrenamiento	Conjunto de Validación	Conjunto de Test
1	Segmentos	ECM	0,05886172	0,11215975	0,14680737
		Valor máximo	0,9696075	0,77224904	1,51998056
		Valor mínimo	-0,99966399	-1,57480836	-1,49517014
	Píxeles	ECM	7,33E-11	1,27E-05	1,96E-06
		Valor máximo	0,00015153	0,00015153	0,00350044
		Valor mínimo	-0,00015596	-0,00015596	-0,03309537
2	Segmentos	ECM	0,10293546	0,22215228	0,21713743
		Valor máximo	3,52925739	4,70229917	4,4465672
		Valor mínimo	-2,69492483	-1,4513218	-2,42164622
	Píxeles	ECM	1,03E-13	9,15E-10	3,33E-06
		Valor máximo	5,47E-06	0,00066857	0,00891056
		Valor mínimo	-5,29E-06	-1,31E-06	-0,03866069

2.6. Análisis de la RNA

La tabla 6 presenta el Error Cuadrático Medio (ECM), valor máximo y valor mínimo resultantes del entrenamiento para los datos de los conjuntos

de entrenamiento, validación y *test* utilizando la información proveniente de la segmentación y píxeles para los dos periodos analizados. En general, se observa un mejor desempeño de la RNA cuando el análisis se realiza a nivel de píxel. La

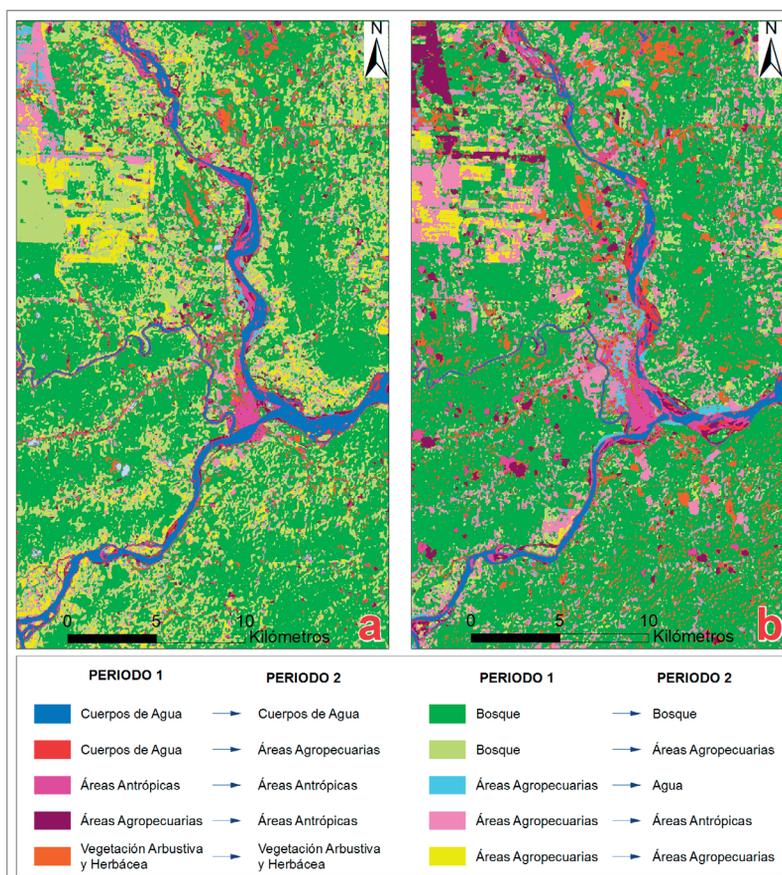


Figura 5. Detección de cambios en los periodos (a) 1990-1999 y (b) 1999-2013.

capacidad de generalización alcanzada por las RNAs mediante la minimización de los errores (proceso de aprendizaje), puede ser estimada según los valores estadísticos para las discrepancias entre las salidas esperadas (*targets*) y las salidas generadas por la red para los registros de *test*.

2.7. Detección de cambios con RNAs

Una vez realizado el entrenamiento de las RNAs, la configuración de los parámetros generados para cada RNA se almacenan para su uso posterior, las RNAs entrenadas son capaces de predecir salidas para ejemplos no considerados en el entrenamiento (generalización). Debido a que la detección de cambios por RNAs a nivel de píxel funciona mejor (Tabla 6), la discriminación de alteraciones para el área de estudio mediante las RNAs entrenadas se realizó también a nivel de píxel.

En base a la RNA entrenada, se realizó una predicción de cambios en la cobertura para los periodos de referencia considerados. La figura 5 presenta los resultados obtenidos para la detección de cambios.

Los valores presentados en la tabla 7 muestran los resultados obtenidos para la detección de cambios. Las alteraciones detectadas son presentadas en km² (área) y porcentaje. Se observa que las áreas de bosque aumentaron en el segundo período, se puede atribuir este hecho a la reforestación efectuada en la zona lo cual es coherente con la disminución de áreas agropecuarias para el mismo período. Sin embargo, el aumento de áreas antrópicas es evidente, debido principalmente al crecimiento de las áreas urbanas, así como también el cambio de áreas agropecuarias para suelo expuesto y de áreas agropecuarias para áreas urbanas. Las áreas

denominadas indeterminadas corresponden a resultados analizados en el primer período y son atribuidas a las nubes presentes en la imagen del año 1999. La cobertura de nubes representa menos el 1% del área total.

3. Análisis de resultados

Una forma de obtener una estimación de la fiabilidad de las RNAs entrenadas para la detección de cambios a nivel de píxel es mediante la construcción de una matriz de confusión (Tablas 8 y 9) y el cálculo del índice *kappa* (Tabla 10). La determinación de cambios en la cobertura para el área de estudio permite inferir la clasificación de la cobertura de la tierra para cada una de las épocas consideradas en el estudio multitemporal (1990, 1999 y 2013). La construcción de las matrices de confusión se realiza en función de la clasificación de la cobertura obtenida para cada año estudiado en contraste con la información del mapa de cobertura y uso de la tierra (CUT) de los años 1990, 2000 y 2014 (SUIA, 1990); en donde las filas corresponden a la clase de la clasificación obtenida para cada año (RNAs) y las columnas a la clase obtenida del mapa de CUT. El índice *kappa* representa una medida de concordancia entre la clasificación realizada por RNAs y las categorías reales (observadas *in situ* o, en el caso del presente estudio, interpretadas visualmente). En la tabla 8 (matriz de confusión) se presentan el número y el porcentaje de coincidencias (diagonal principal) y no coincidencias encontradas en las clasificaciones realizadas con las RNAs para los tres años (1990-1999-2013).

El porcentaje de coincidencias en todos los casos es mayor que el 70%, se verifica que para los años 1990 y 2013 la menor fiabilidad de las RNAs

Tabla 7. Áreas y porcentajes de cambios para los períodos I y II.

Clase	Período 1		Período 2	
	(km ²)	%	(km ²)	%
Bosque → Bosque	334,64	45,59	387,55	52,81
Áreas agropecuarias → Áreas agropecuarias	67,43	9,19	23,33	3,18
V. arbustiva y herbácea → V. arbustiva y herbácea	35,39	4,82	76,94	10,48
Agua → Agua	26,40	3,60	18,83	2,57
Áreas antrópicas → Áreas antrópicas	21,00	2,86	22,85	3,11
Bosque → Áreas agropecuarias	165,02	22,48	57,72	7,86
Agua → Áreas agropecuarias	3,45	0,48	4,66	0,64
Áreas antrópicas → Áreas agropecuarias	14,87	2,03	27,16	3,70
Áreas agropecuarias → Agua	15,72	2,14	12,21	1,66
Áreas agropecuarias → Áreas antrópicas	45,91	6,25	102,70	13,99
Indeterminado	4,11	0,56	-	-

Tabla 8. Matrices de confusión para las clasificaciones por RNA entrenadas a nivel de píxel (número de píxeles y porcentajes).

Año 1990						
Clase	Bosque	Áreas Agrop.	V. Arb. y Herb.	Cuerpos de agua	Áreas antrópicas	Total
Bosque	990 (97,35%)	15 (1,47%)	11 (1,08%)	0 (0,0%)	1 (0,10%)	1017 (100%)
Áreas Agropecuarias	40 (6,97%)	529 (92,16%)	1 (0,17%)	1 (0,17%)	3 (0,52%)	574 (100%)
V. Arbustiva y Herbácea	26 (7,51%)	0 (0,0%)	320 (92,49%)	0 (0,0%)	0 (0,0%)	346 (100%)
Cuerpos de agua	11 (1,84%)	0 (0,0%)	15 (2,51%)	551 (92,29%)	20 (3,35%)	597 (100%)
Áreas antrópicas	10 (1,39%)	10 (1,39%)	24 (3,33%)	47 (6,53%)	629 (87,36%)	720 (100%)
			Total			3254
Año 1999						
Clase	Bosque	Áreas Agrop.	V. Arb. y Herb.	Cuerpos de agua	Áreas antrópicas	Total
Bosque	713 (88,13%)	11 (1,36%)	85 (10,51%)	0 (0,0%)	0 (0,0%)	809 (100%)
Áreas Agropecuarias	106 (13,55%)	671 (85,81%)	4 (0,51%)	0 (0,0%)	1 (0,13%)	782 (100%)
V. Arbustiva y Herbácea	55 (15,90%)	0 (0,0%)	291 (84,10%)	0 (0,0%)	0 (0,0%)	346 (100%)
Cuerpos de agua	0 (0,0%)	0 (0,0%)	14 (2,35%)	568 (95,14%)	15 (2,51%)	597 (100%)
Áreas antrópicas	8 (1,12%)	15 (2,10%)	35 (4,91%)	50 (7,01%)	605 (84,85%)	713 (100%)
Total						2848
Año 2013						
Clase	Bosque	Áreas Agrop.	V. Arb. y Herb.	Cuerpos de agua	Áreas antrópicas	Total
Bosque	718 (88,75%)	8 (0,99%)	81 (10,01%)	0 (0,0%)	2 (0,25%)	809 (100%)
Áreas Agropecuarias	62 (7,93%)	637 (81,46%)	5 (0,64%)	6 (0,77%)	72 (9,21%)	782 (100%)
V. Arbustiva y Herbácea	52 (15,03%)	0 (0,0%)	294 (84,97%)	0 (0,0%)	0 (0,0%)	346 (100%)
Cuerpos de agua	0 (0,0%)	23 (3,85%)	14 (2,35%)	545 (91,29%)	15 (2,51%)	597 (100%)
Áreas antrópicas	8 (1,12%)	31 (4,35%)	115 (16,13%)	32 (4,49%)	527 (73,91%)	713 (100%)
Total						3247

resulta en el reconocimiento de patrones espectrales asociados con áreas antrópicas (87,36% y 73,91%, respectivamente). En el caso de la clasificación realizada para el año 1999, la peor fiabilidad de la RNA se registra para la cobertura de áreas antrópicas (84,85%).

El porcentaje de coincidencias en todos los casos es mayor que el 70%, al igual que con la clasificación por cada año de estudio. En la detección de cambios para el periodo 1 la menor fiabilidad de la

RNA se aprecia en la cobertura de cuerpos de agua (84,76%), mientras que en el periodo 2, la menor se da en la cobertura de bosque (79,91%).

Con los valores presentados en las matrices de confusión, se realizó el cálculo del coeficiente *kappa* (Tabla 10) de las clasificaciones y la detección de cambios con RNAs y con el método de Máxima Verosimilitud (MV). Este coeficiente proporciona una estimación global de la fiabilidad del método utilizado en términos de correspondencia de los

Tabla 9. Matrices de confusión para la detección de cambios con uso de la RNAs entrenadas a nivel de píxel (número de píxeles y porcentajes)

Periodo 1 (1990-1999)						
Clase	Bosque	Áreas Agrop.	V. Arb. y Herb.	Cuerpos de agua	Áreas antrópicas	Total
Bosque	779 (96,29%)	8 (0,99%)	22 (2,72%)	0 (0,0%)	0 (0,0%)	809 (100%)
Áreas Agropecuarias	98 (2,10%)	674 (86,19%)	10 (1,28%)	0 (0,0%)	0 (0,0%)	782 (100%)
V. Arbustiva y Herbácea	35 (7,77%)	6 (1,73%)	305 (88,15%)	0 (0,0%)	0 (0,0%)	346 (100%)
Cuerpos de agua	2 (0,0%)	7 (1,17%)	10 (1,68%)	506 (84,76%)	72 (12,06%)	597 (100%)
Áreas antrópicas	0 (0,0%)	18 (2,52%)	0 (0,0%)	0 (0,0%)	685 (97,48%)	713 (100%)
Total						2959
Periodo 2 (1999-2013)						
Clase	Bosque	Áreas Agrop.	V. Arb. y Herb.	Cuerpos de agua	Áreas antrópicas	Total
Bosque	1822 (79,91%)	279 (12,24%)	177 (7,76%)	2 (0,09%)	0 (0,0%)	2280 (100%)
Áreas Agropecuarias	27 (2,10%)	1182 (91,77%)	44 (3,42%)	1 (0,08%)	34 (2,64%)	1288 (100%)
V. Arbustiva y Herbácea	80 (7,77%)	27 (2,62%)	913 (88,73%)	4 (0,39%)	5 (0,49%)	1029 (100%)
Cuerpos de agua	0 (0,0%)	0 (0,0%)	0 (0,0%)	860 (100,0%)	0 (0,0%)	860 (100%)
Áreas antrópicas	0 (0,0%)	64 (6,65%)	6 (0,62%)	36 (3,74%)	857 (88,99%)	963 (100%)
Total						6420

valores generados por las RNAs y MV con los valores reales (esperados). Adicionalmente se calcula la exactitud global alcanzada por cada RNA, estos valores son obtenidos de la suma de la diagonal principal de la matriz de confusión dividida por el total de los píxeles de las muestras.

Al comparar ambos métodos se verifica que el método basado en el entrenamiento de la RNA presenta una fiabilidad global ligeramente superior (Tabla 10). Sin embargo, para la clasificación del año 2013 el método de MV funcionó mejor que el de RNA.

Los valores *kappa* (Cohen, 1960), obtenidos corresponden a una concordancia entre buena y muy buena, de acuerdo con la Tabla 11.

Tabla 11. Interpretación de los valores *kappa*.

Valor de kappa	Concordancia
< 0,20	Pobre
0,21 - 0,40	Débil
0,41 - 0,60	Moderada
0,61 - 0,80	Buena
0,81 - 1,00	Muy buena

Fuente: Centeno (2003).

Tabla 10. Índices *kappa* y fiabilidad global calculados para los años de referencia.

Año/periodos de referencia	Índice kappa		Exactitud Global	
	RNA	MV	RNA	MV
Clasificación 1990	0,91	0,84	0,93	0,88
Clasificación 1999	0,84	0,82	0,88	0,87
Clasificación 2013	0,80	0,84	0,84	0,87
Detección de cambios Periodo 1	0,89	0,87	0,91	0,90
Detección de cambios Periodo 2	0,84	0,77	0,88	0,82

4. Conclusiones

Las RNAs, muestran ser una opción válida para la clasificación de imágenes satelitales para detectar cambios en la cobertura del territorio; la fiabilidad global y el coeficiente $kappa$ calculados para la clasificación y posterior detección de cambios mediante el uso de imágenes satelitales demuestran que el uso de la técnica de RNAs, presenta resultados de buena calidad, con una mejor fiabilidad que el método tradicional de máxima verosimilitud.

La utilización de la técnica de RNAs puede generar resultados satisfactorios en la detección de cambios de cobertura; sin embargo, es necesario que las muestras utilizadas para el entrenamiento de la red se establezcan correctamente para que se puedan extraer patrones reales de alteración en el paisaje.

Las discrepancias resultantes entre el uso de valores a nivel de píxel y a nivel de segmento son significativas, observando mejores resultados con la información a nivel de píxel; esto se explica por el uso de imágenes de mediana resolución (LANDSAT) donde solamente se utilizan características espectrales.

No existe una técnica universalmente óptima o única para la detección de cambios. La selección del método depende del problema presentado, imágenes disponibles y la escala de trabajo.

Referencias

Achard, F. 2002. Determination of Deforestation Rates of the World's Humid Tropical Forests. *Science*, 297(5583), 999-1002. <https://doi.org/10.1126/science.1070656>

Ambrosio, G., González, J., Arévalo, V. 2009. Comparación de imágenes de satélite para la Detección de Cambios Temporales. Málaga, España. Dpto. Ingeniería de Sistemas y Automática. Universidad de Málaga, p. 1-6. Último acceso: 7 julio 2014, de <http://mapir.isa.uma.es/varevalo/drafts/ambrosio2003cis.pdf>

Angelsen, A., Kaimowitz, D. 1999. Rethinking the causes of deforestation: lessons from economic models. *The World Bank Research Observer*, 14(1), 73-98. <https://doi.org/10.1093/wbro/14.1.73>

Basogain, X. 2008. *Redes neuronales artificiales y sus aplicaciones*. Departamento de Ingeniería de Sistemas y Automática, Escuela Superior de Ingeniería Bilbao. Open Course Ware. País Vasco. Último acceso: 28 de octubre 2014, de https://ocw.ehu.eus/pluginfile.php/9047/mod_resource/content/1/redes_neuro/contenidos/pdf/libro-del-curso.pdf

Centeno, J. A. S. 2003. *Sensoriamento remoto e processamento de imagens digitais*. Curitiba: UFPR.

Chander, G., Markham, B. 2003. Revised Landsat-5 TM Radiometric Calibration Procedures and Postcalibration Dynamic Ranges. *IEEE Transactions on Geoscience and Remote Sensing*, 41(11) Part II, 2674-2677. <https://doi.org/10.1109/TGRS.2003.818464>

Cohen, J. 1960. A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement*, 20(1), 37-46. <https://doi.org/10.1177/001316446002000104>

Crosta, A. P. 1999. *Processamento digital de imagens de sensoriamento remoto*. Campinas: UNICAMP/ Instituto de Geociências.

Haykin, S. 2001. *Redes neurais: princípios e prática*. Bookman, 900.

İlseven, M., Ünsalan, C. 2012. Pixel-Based Change Detection Methods. Two-Dimensional Change Detection Methods. *Springer*. 7-22. https://doi.org/10.1007/978-1-4471-4255-3_2

Isasi, P., Galván, I. 2004. *Redes de neuronas artificiales. Un enfoque práctico*. Madrid: Prentice Hall.

Kaufman, Y. J., Wald, A. E., Remer, L. A., Gao, B.-C., Li, R.-R., Flynn, L. 1997. The MODIS 2.1um channel-correlation with visible reflectance for use in remote sensing of aerosol. *IEEE Transactions on Geoscience and Remote Sensing*, 35(5), 1286-1298. <https://doi.org/10.1109/36.628795>

Keenan, R. J., Reams, G. A., Achard, F., De Freitas, J. V., Grainger, A., Lindquist, E. 2015. Dynamics of global forest area: results from the FAO Global Forest Resources Assessment 2015. *Forest Ecology and Management*, 352, 9-20. <https://doi.org/10.1016/j.foreco.2015.06.014>

Kotchenova, S. Y., Vermote, E. F., Matarrese, R., Frank J., Klemm, J. 2006. Validation of a vector version of the 6S radiative transfer code for atmospheric correction of satellite data. Part I: Path radiance. *Applied Optics*, 45(26), 6762-6774, set. Disponible en: Último acceso: 22 mayo 2015, de <http://ao.osa.org/abstract.cfm?URI=ao-45-26-6762>

- Lu, D., Mausel, P., Brondizio, E., Moran, E. 2004. Change detection techniques. *International Journal of Remote Sensing*, 25(12), 2365-2401. <https://doi.org/10.1080/0143116031000139863>
- MAE. (2012a). Metodología para la Representación Cartográfica de los Ecosistemas del Ecuador Continental. *Ministerio del Ambiente del Ecuador*. Último acceso: 29 de Agosto de 2014, de http://www.ambiente.gob.ec/wp-content/uploads/downloads/2012/09/Documento_Metodolog+ja_28_05_2012_v2_1.pdf
- MAE (2012b). Línea Base de deforestación del Ecuador Continental. *Ministerio del Ambiente de Ecuador*. Último acceso en: 28 de octubre de 2014, de <http://sociobosque.ambiente.gob.ec/files/Folleto%20mapa-partel.pdf>
- Moya, A. 2012. Detección automática de nuevas construcciones a partir de ortofotos. *Universitat de Valencia*. Último acceso: 28 de agosto de 2014, de <http://personales.upv.es/almofue/curso02/26092012Tesina.pdf>
- OpenForis 2009. Open Foris Geospatial Tools. Food and Agriculture Organization of United Nations (FAO). Último acceso: 25 de febrero de 2017, de <http://www.fao.org/forestry/fima/openforis/en/>
- Schmidt, G., Jenkerson, C., Masek, J., Vermote, E., Gao, F. 2013. Landsat Ecosystem Disturbance Adaptive Processing System (LEDAPS) Algorithm Description Open-file Report 2013-1057. *U.S. Geological Survey Home Page*. Último acceso: 16/ agosto/2017, de <http://pubs.usgs.gov/of/2013/1057/>
- Singh, A. 1989. Review Article Digital change detection techniques using remotely-sensed data. *International Journal of Remote Sensing*, 10(6), 989-1003. <https://doi.org/10.1080/01431168908903939>
- SUIA 1990. Sistema Único de Información Ambiental - Ministerio del Ambiente del Ecuador. *Mapa Interactivo Ambiental*. Último acceso en: 30 de junio de 2015, de <http://mapainteractivo.ambiente.gob.ec/>
- USGS. Landsat Surface Reflectance Higher-Level Data Products. *U.S. Geological Survey Home Page*. Último acceso: 28 de mayo de 2015, de <https://landsat.usgs.gov/landsat-surface-reflectance-high-level-data-products>
- Valencia, R., Cerón, C., Palacios, W., Sierra, R. (1999). Las formaciones naturales de la Amazonía del Ecuador. Sierra, R. (ed) Propuesta preliminar de un sistema de clasificación de vegetación para el Ecuador continental. *Proyecto INEFAN/GEF-BIRF y EcoCiencia*, Quito, 109-119.
- Vermote, E. F., Tanré, D., Deuzé, J. L., Herman, M., Morcrette, J.J. 1997. Second simulation of the satellite signal in the solar spectrum, 6s: an overview. *IEEE Transactions on Geoscience and Remote Sensing*, 35(3), 675-686. <https://doi.org/10.1109/36.581987>