



**UNIVERSIDAD DE CUENCA**  
**Facultad de Ciencias Químicas**  
**Escuela de Ingeniería Ambiental**

**“Análisis multitemporal del cambio de uso de suelo en la microcuenca del río Tabacay para el periodo 2005-2017”**

Trabajo de titulación previo  
a la obtención del título de  
Ingeniero Ambiental

**Autor:**

Carlos Alejandro Bowen Quiroz  
CI: 1312953811

**Director:**

Biol. Julio Danilo Mejía Coronel  
CI: 0103638581

Cuenca - Ecuador  
2018



## RESUMEN

La microcuenca del río Tabacay es de vital importancia para las 27 comunas que en ella habitan, de la cual extraen recursos, desarrollan actividades económicas y su vida en general. Esta microcuenca también es significativa para la ciudad de Azogues, que toma de sus quebradas el agua para abastecer a su población. Este estudio analiza la dinámica del uso de suelo y el estado de la vegetación en términos de calidad en la microcuenca durante el periodo 2005 - 2017, empleando imágenes satelitales Landsat en conjunto con sistemas de información geográfica, con el fin de determinar áreas críticas para el manejo y conservación de la microcuenca. Se determinaron cuatro clases de uso de suelo: agropecuario, forestal, urbano y páramo. El análisis determinó que las clases de uso de suelo agropecuario y urbano han incrementado en términos de superficie, al mismo tiempo que las clases de uso de suelo forestal y de páramo disminuyeron su ocupación. El uso de suelo correspondiente a páramo ha sido el más afectado por la dinámica del uso del suelo; en términos de superficie, este perdió 6 ha/año durante el periodo de análisis, lo que equivale al 54% de su superficie inicial en 2005. El análisis también demostró que la zona más afectada por la fragmentación y la pérdida de superficie de los usos del suelo forestal y de páramo fue la parte alta de la microcuenca, teniendo como principal causa de estos problemas a la expansión de la frontera agrícola y a la urbanización.

**Palabras clave:** SISTEMAS DE INFORMACIÓN GEOGRÁFICA, LANDSAT, USO DE SUELO, MICROCUENCA, TABACAY, ANÁLISIS MULTITEMPORAL, PERCEPCIÓN REMOTA.



## ABSTRACT

Tabacay micro-basin is very important for 27 communes that lives in it, from which they extract resources, develop economic activities and life overall. This micro-basin is also important for Azogues city, which takes water from its rivers for supply the population. This study analyzes land use dynamics and vegetation's quality during 2005-2017 period, using Landsat satellite images along with geographic information systems, for determining critical areas for management and conservation of Tabacay micro-basin. Four land use classes were determined: agricultural, forestry, urban and moor. Analysis results show that agricultural and urban land use has grown in surface terms, as well as forestry and moor surface has decreased. Moor land use has been the most affected by land use dynamics. In terms of surface, this land use shows a 6 ha/year loss during analysis period, which is equivalent to 54% of its initial surface. Analysis also shows that most affected zone by forest and moor fragmentation and surface loss is micro-basin's high part, having as main cause of the problem the agricultural frontier expansion and urbanization.

**Keywords:** GEOGRAPHIC INFORMATION SYSTEMS, LANDSAT, LAND USE, TABACAY, MICRO-BASIN, MULTITEMPORAL ANALYSIS, REMOTE SENSING.



## ÍNDICE DE CONTENIDOS

RESUMEN .....	2
ABSTRACT .....	3
ÍNDICE DE CONTENIDOS .....	4
ÍNDICE DE ILUSTRACIONES .....	6
ÍNDICE DE TABLAS .....	7
CLÁUSULAS .....	8
DEDICATORIA.....	10
1. INTRODUCCIÓN .....	11
1.1. Objetivos.....	12
1.1.1. Objetivo general .....	12
1.1.2. Objetivos específicos.....	12
CAPÍTULO I .....	13
2. PERCEPCIÓN REMOTA .....	13
2.1. Generalidades .....	13
2.1.1. Energía electromagnética.....	13
2.1.1.1. Espectro electromagnético.....	14
2.1.2. Sensores remotos .....	16
2.1.2.1. Programa Landsat .....	17
2.2. Aplicación de la Percepción Remota.....	19
2.2.1. Preprocesamiento de imágenes satelitales .....	19
2.2.1.1. Corrección atmosférica .....	19
2.2.1.2. Corrección topográfica .....	20
2.2.2. Índices de vegetación.....	21
2.2.2.1. índice de Vegetación Diferencial Normalizado .....	22
2.2.2.2. índice de Agua Diferencial Normalizado .....	22
2.2.3. Clasificación digital de imágenes satelitales .....	22
2.2.3.1 Cobertura y uso del suelo .....	23
2.2.4. Análisis multitemporales.....	24
CAPÍTULO II .....	25
3. METODOLOGÍA.....	25
3.1. Área de estudio.....	25
3.2. Determinación de clases de uso del suelo .....	25
3.3. Preprocesamiento.....	27



---

3.3.1. Corrección de bandeo (Gap-filling) .....	27
3.3.2. Correcciones .....	28
3.3.2.1. Corrección atmosférica .....	28
3.3.2.2. Corrección topográfica .....	29
3.4. Análisis de la vegetación.....	30
3.4.1. NDVI .....	30
3.4.2. NDWI .....	30
3.5. Selección de áreas de entrenamiento y de prueba .....	31
3.6. Clasificación supervisada.....	32
3.6.1. Verificación.....	32
3.7. Análisis multitemporal y estadístico .....	32
3.7.1. Tasa de Cambio Anual (TCA).....	33
3.7.2. Correlación.....	33
CAPÍTULO III .....	34
4. RESULTADOS Y DISCUSIÓN .....	34
4.1. Análisis de la vegetación.....	34
4.1.1. NDVI .....	34
4.1.2. NDWI .....	36
4.2. Clasificación supervisada.....	39
4.3. Análisis multitemporal y estadístico .....	40
4.3.1. Evolución del uso del suelo y TCA .....	40
4.3.2. Matriz de transición .....	43
4.3.3. Correlación.....	46
CAPÍTULO IV.....	47
5. CONCLUSIONES.....	47
6. RECOMENDACIONES .....	48
7. REFERENCIAS.....	49
8. ANEXOS .....	56
Anexo 1: Mapas individuales de NDVI por año analizado .....	56
Anexo 2: Mapas individuales de NDWI por año analizado .....	59
Anexo 3: Matrices de confusión .....	62
Anexo 4: Mapas individuales de uso del suelo por año analizado.....	63

## ÍNDICE DE ILUSTRACIONES

<b>Ilustración 1.</b> El espectro electromagnético.....	14
<b>Ilustración 2.</b> Efectos de la pendiente y la incidencia solar en la distorsión de las reflectancias durante la captura de una imagen satelital. ....	21
<b>Ilustración 3.</b> Mapa base del área de estudio.....	25
<b>Ilustración 4.</b> Porcentaje de ocupación de las clases de calidad vegetal con respecto al total de la superficie de la microcuenca. ....	35
<b>Ilustración 5.</b> Mapa comparativo de la variación espacial y temporal de las clases de calidad de vegetación.....	36
<b>Ilustración 6.</b> Porcentaje de ocupación de las clases de contenido de humedad vegetal con respecto al total de la superficie de la microcuenca.....	37
<b>Ilustración 7.</b> Mapa comparativo de la variación espacial y temporal del contenido de humedad vegetal.....	38
<b>Ilustración 8.</b> Comparación gráfica entre el resultado de la clasificación supervisada por el método de máxima probabilidad (izquierda) y redes neuronales (derecha) para la imagen satelital del año 2017. Representación de los colores: rojo: uso de suelo urbano; verde claro: uso de suelo agropecuario; verde oscuro: uso de suelo forestal; marrón: uso de suelo de páramo.....	40
<b>Ilustración 9.</b> Porcentaje representativo de cada clase de uso del suelo. ....	41
<b>Ilustración 10.</b> Mapa comparativo de la variación espacial y temporal de las clases de uso del suelo. ....	42
<b>Ilustración 11.</b> Áreas de pérdida de uso forestal y de páramo frente a la expansión de uso agropecuario y urbano durante el periodo de estudio. ....	45



## ÍNDICE DE TABLAS

<b>Tabla 1.</b> Especificaciones técnicas de los sensores ETM+ y OLI*.....	18
<b>Tabla 2.</b> Descripción de las clases de uso de suelo.....	27
<b>Tabla 3.</b> Detalle de las imágenes satelitales utilizadas.....	27
<b>Tabla 4.</b> Clases de calidad vegetal empleadas. ....	30
<b>Tabla 5.</b> Clases de contenido de humedad vegetal empleadas.....	31
<b>Tabla 6.</b> Evolución de la calidad vegetal en superficie y porcentaje para 2005, 2013 y 2017.....	34
<b>Tabla 7.</b> Evolución del contenido de humedad vegetal en superficie y porcentaje para 2005, 2013 y 2017.....	37
<b>Tabla 8.</b> Precisión global y coeficiente de Kappa por método de clasificación y año analizado.....	39
<b>Tabla 9.</b> Evolución de las clases de uso del suelo en superficie y porcentaje para 2005, 2013 y 2017.....	41
<b>Tabla 10.</b> Matriz de transición de clases de uso del suelo para el periodo de estudio (2005-2017).....	44
<b>Tabla 11.</b> Coeficiente de correlación de Pearson y coeficiente de determinación entre pares de clases. ....	46



Cláusula de licencia y autorización para publicación en el Repositorio  
Institucional

---

Yo, Carlos Alejandro Bowen Quiroz, en calidad de autor y titular de los derechos morales y patrimoniales del trabajo de titulación "ANÁLISIS MULTITEMPORAL DEL CAMBIO DE USO DE SUELO EN LA MICROCUENCA DEL RÍO TABACAY PARA EL PERIODO 2005-2017", de conformidad con el Art. 114 del CÓDIGO ORGÁNICO DE LA ECONOMÍA SOCIAL DE LOS CONOCIMIENTOS, CREATIVIDAD E INNOVACIÓN reconozco a favor de la Universidad de Cuenca una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos.

Asimismo, autorizo a la Universidad de Cuenca para que realice la publicación de este trabajo de titulación en el repositorio institucional, de conformidad a lo dispuesto en el Art. 144 de la Ley Orgánica de Educación Superior.

Cuenca, 19 de septiembre de 2018.

---

Carlos Alejandro Bowen Quiroz

C.I: 1312953811





Cláusula de Propiedad Intelectual

---

Yo, Carlos Alejandro Bowen Quiroz, autor del trabajo de titulación "ANÁLISIS MULTITEMPORAL DEL CAMBIO DE USO DE SUELO EN LA MICROCUENCA DEL RÍO TABACAY PARA EL PERIODO 2005-2017", certifico que todas las ideas, opiniones y contenidos expuestos en la presente investigación son de exclusiva responsabilidad de su autor.

Cuenca, 19 de septiembre de 2018.

A handwritten signature in blue ink, appearing to read 'Carlos Bowen Quiroz', written over a horizontal line.

Carlos Alejandro Bowen Quiroz

C.I: 1312953811



## DEDICATORIA

A mi gran familia, en especial a mis padres, cuyo amor infinito y apoyo incondicional hicieron esto posible. Son la luz que guía mi camino.

A mis amigos, a quienes nunca les falta una palabra de aliento, una mano extendida y un abrazo.

A Dani, quien siempre supo cómo aclarar hasta la más oscura situación.

## 1. INTRODUCCIÓN

La microcuenca del río Tabacay es de vital importancia para Saguin, Mirapamba, Monjas y otras 24 comunas que en ella habitan, de la cual extraen recursos y desarrollan actividades económicas. Esta microcuenca también es significativa para la ciudad de Azogues, que toma agua de sus quebradas para abastecer a su población. A pesar de su importancia, existen varios problemas de índole social y ambiental, que afectan especialmente a la zona de interés hídrico (parte media y alta) de la microcuenca.

Dos de estos problemas son la erosión y el deslizamiento de tierras que, en conjunto, están destruyendo potenciales zonas agrícolas, aumentando así la cantidad de sedimento que se acumula en los lechos de las principales quebradas. La degradación del suelo es causada, en su mayoría, por la deforestación de bosques y vegetación nativa, e inadecuadas prácticas agrícolas por parte de los pobladores de las partes altas de la microcuenca (EMAPAL EP, COPOE, & PROMAS, 2005). Otro problema que afecta a la microcuenca es la expansión urbana hacia zonas altas, siendo esto consecuencia de la construcción no planificada y antitécnica de una extensa red vial sin planes de mitigación (EMAPAL EP et al., 2005).

La ausencia de información con respecto a la evolución a través del tiempo de la cobertura y el uso del suelo dentro de la microcuenca es un limitante para la gestión de este territorio. Los estudios sobre estas variables permiten entender las causas y consecuencias de los procesos de deforestación, degradación, desertificación y pérdida de biodiversidad de una región determinada (Mas, Velázquez, & Couturier, 2009). Los análisis de la dinámica del uso del suelo son indispensables para la planificación del desarrollo rural y el monitoreo de la seguridad alimentaria de una región (Sahle, Marohn, & Cadisch, 2015).

El desarrollo de análisis multitemporales puede generar información útil para la toma de decisiones en cuanto al manejo de cuencas hidrográficas (Sahle et al., 2015). De esta manera, los Sistemas de Información Geográfica (SIG) y la Percepción Remota (PR) se perfilan como herramientas idóneas para analizar la dinámica del paisaje de la microcuenca del río Tabacay.

El presente trabajo de investigación pretende brindar información cartográfica y estadística representativa acerca de la dinámica del paisaje de la microcuenca del río



Tabacay, para que las autoridades competentes de su manejo puedan dirigir esfuerzos en la gestión de este territorio con un enfoque ecosistémico y de conservación. Puesto que, para Malarvizhi et al. (2016), para tener el adecuado control de un territorio, las entidades reguladoras necesitan información sobre el uso del suelo actual y cómo este cambió y cambiará con el tiempo.

## **1.1. Objetivos**

### **1.1.1. Objetivo general**

Analizar el cambio de uso del suelo de la microcuenca del río Tabacay en el periodo 2005-2017 mediante técnicas de percepción remota para el análisis de imágenes satelitales.

### **1.1.2. Objetivos específicos**

- Definir las clases de uso de suelo a analizar mediante información secundaria.
- Clasificar los usos de suelo a partir de un método de clasificación supervisada.
- Realizar un análisis multitemporal para determinar las tasas de cambio de uso de suelo.
- Analizar estadísticamente la correlación entre variables relacionadas al cambio de uso de suelo.

---

## CAPÍTULO I

### 2. PERCEPCIÓN REMOTA

#### 2.1. Generalidades

La percepción remota es el conjunto de técnicas cuya función es obtener información sobre un objeto, área o fenómeno a través del análisis de datos adquiridos por un dispositivo que no se encuentra en contacto físico con el objeto, área o fenómeno en cuestión (Lillesand, Kiefer, & Chipman, 2014). Para que la información del objeto sea percibida por el dispositivo, es preciso que entre ellos exista alguna interacción (Chuvienco, 2008). El conjunto que forman el objeto observado (superficie terrestre), el dispositivo (sensor remoto) y la interacción entre ellos (flujo energético) se denomina sistema de percepción remota (Chuvienco, 2008).

El flujo energético entre la superficie terrestre y el sensor remoto puede darse de tres formas: reflexión, emisión y emisión-reflexión. La primera de ellas es la más importante, ya que se deriva directamente de la energía solar (Chuvienco, 2008). La reflexión se da cuando el sol ilumina la superficie terrestre; esta refleja una fracción de la energía recibida en función del tipo de cubierta, que luego será captada por el sensor (Lillesand et al., 2014).

De igual forma, la percepción remota puede basarse en la energía emitida por las propias cubiertas (emisión), o en la que se puede enviar desde un sensor que fuese capaz, tanto de generar su propio flujo energético, como de recoger posteriormente su reflexión sobre la superficie terrestre (emisión-reflexión) (Chuvienco, 2008). En cualquiera de estos casos, el flujo energético entre la cubierta terrestre y el sensor constituye una forma de energía electromagnética (Chuvienco, 2008).

##### 2.1.1. Energía electromagnética

La energía se transfiere de un lugar a otro por tres procesos: convección, conducción y radiación (Young & Freedman, 2009). De estos, la radiación constituye la base de los sistemas de percepción remota, pues es la forma de flujo energético que los sensores remotos pueden percibir (Chuvienco, 2008).

Históricamente, la radiación se ha explicado por dos teorías aparentemente contrapuestas: aquella que la concibe como un haz ondulatorio (ondas electromagnéticas) y aquella que la considera como una sucesión de unidades discretas de energía con masa igual a cero (fotones) (Young & Freedman, 2009).

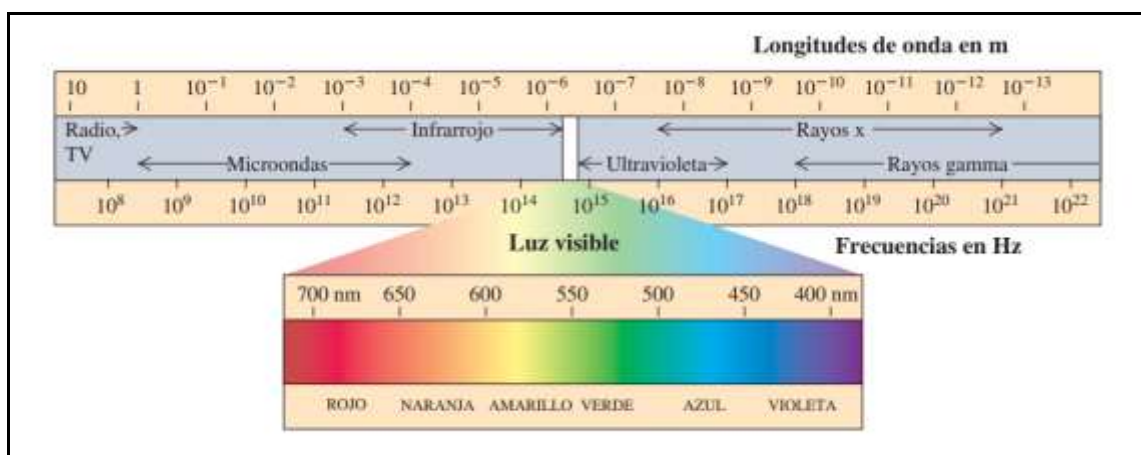
Ambas teorías pueden compaginar, pues se ha demostrado que la energía electromagnética o radiación presenta comportamientos que pueden explicarse mediante ambos planteamientos (Young & Freedman, 2009).

En resumen, la energía electromagnética puede describirse por dos variables: longitud de onda y frecuencia. La primera hace referencia a la distancia entre dos picos sucesivos de una onda, mientras que la frecuencia designa el número de ciclos pasando por un punto fijo en una unidad de tiempo (Young & Freedman, 2009). Ambas variables están relacionadas mediante la velocidad de la luz, que es una constante (Young & Freedman, 2009).

Gracias a la teoría cuántica es posible determinar la energía transportada por un fotón, siempre y cuando se conozca su frecuencia, puesto que, a mayor longitud de onda (o menor frecuencia) menor será el contenido energético y viceversa (Chuvieco, 2008). Por lo tanto, la energía electromagnética en longitudes de onda largas es más difícil de detectar que aquella proveniente de longitudes de onda cortas (Lillesand et al., 2014).

#### 2.1.1.1. Espectro electromagnético

De lo explicado previamente, se deduce que es posible definir cualquier tipo de energía electromagnética en función de su longitud de onda o de su frecuencia (Lillesand et al., 2014). Aunque la sucesión de valores de longitud de onda es continua, históricamente se ha establecido una serie de rangos (bandas espectrales) en donde la energía electromagnética manifiesta un comportamiento similar, denominados en su conjunto “espectro electromagnético” (Young & Freedman, 2009), como se muestra en la siguiente ilustración:



**Ilustración 1.** El espectro electromagnético.  
Fuente: Young & Freedman (2009).

Este comprende desde longitudes de onda más cortas (rayos  $\gamma$ , rayos X), hasta longitudes de onda empleadas en telecomunicaciones (ondas largas) (Chuvieco,

2008). Las unidades de medida más comunes dependen de la longitud de onda: para las más cortas se utilizan nanómetros (nm) o micrómetros ( $\mu\text{m}$ ), mientras que para las más largas se utilizan centímetros (cm) o metros (m) (Lillesand et al., 2014).

Desde el punto de vista de la percepción remota, es preciso destacar una serie de bandas espectrales de alta importancia por su amplia utilización; su denominación y la amplitud del espectro que abarcan varía según distintos autores (Bolstad, 2012; Chuvieco, 2008; Gomarasca, 2004; Lillesand et al., 2014; Young & Freedman, 2009), no obstante, la terminología más común es la siguiente:

- Espectro visible (de 0.4 a 0.7  $\mu\text{m}$ ). Se denomina así por tratarse de la única región del espectro electromagnético que el ojo humano puede percibir, coincidiendo con las longitudes de onda en donde es máxima la radiación solar (Chuvieco, 2008). Dentro de este rango suelen distinguirse tres bandas elementales, que se denominan Azul (Blue, B: 0.4 – 0.5  $\mu\text{m}$ ), Verde (Green, G: 0.5 – 0.6  $\mu\text{m}$ ), y Rojo (Red, R: 0.6 – 0.7  $\mu\text{m}$ ), en razón de los colores primarios que el ojo humano percibe a esas longitudes de onda (Young & Freedman, 2009).
- Infrarrojo cercano (Near Infrared, NIR: de 0.7 a 1.3  $\mu\text{m}$ ). También denominado infrarrojo próximo, resulta de especial importancia por su capacidad para discriminar masas vegetales y concentraciones de humedad (Pettorelli et al., 2011).
- Infrarrojo medio (1.3 a 8  $\mu\text{m}$ ): En esta región se entremezclan los procesos de reflexión de la luz solar y de emisión de la superficie terrestre (Chuvieco, 2008). En el primer caso se habla del infrarrojo de onda corta (Short Wave Infrared, SWIR1), que se sitúa entre 1,3 y 3  $\mu\text{m}$  y resulta una banda idónea para estimar el contenido de humedad en la vegetación o en el suelo (Gao, 1996). La segunda banda de interés está comprendida entre 3 y 8  $\mu\text{m}$ , y suele denominarse más propiamente como infrarrojo medio (SWIR2), siendo determinante para la detección de focos de alta temperatura (incendios o volcanes activos) (Gao, 1996).
- Infrarrojo lejano o térmico (Thermal Infrared, TIR: 8 a 14  $\mu\text{m}$ ). Este incluye la porción emisiva del espectro terrestre, en donde se detecta el calor proveniente de la mayor parte de las cubiertas terrestres (Lillesand et al., 2014).
- Micro-ondas (M, por encima de 1 mm). Son de gran interés por ser un tipo de energía bastante transparente a la cubierta nubosa (Chuvieco, 2008).

---

### 2.1.2. Sensores remotos

Un sensor remoto es un instrumento capaz de percibir la energía electromagnética reflejada o emitida por la superficie terrestre (Bolstad, 2012). El sensor percibe la energía a través de un conjunto de detectores. Estos apuntan hacia la superficie terrestre y registran individualmente o en conjunto la energía reflejada de un área pequeña (celda o píxel) mediante un escaneo de barrido de la superficie total que se desea capturar (Bolstad, 2012).

En su conjunto, el sensor construye una matriz compuesta por celdas o píxeles con un valor asignado representativo de la energía percibida por los detectores; el valor correspondiente a cada píxel se denomina Nivel Digital (ND) (Chuvienco, 2008). El tamaño de los píxeles se denomina resolución espacial, que se mide en metros o centímetros (Gomarasca, 2004). En total, existirán tantas matrices como bandas espectrales pueda detectar el sensor; el número de bandas y el rango detectable de cada una de estas se denomina resolución espectral (Gomarasca, 2004). El conjunto de todas las bandas se denomina imagen multiespectral o más coloquialmente, imagen satelital (Bolstad, 2012). Al encontrarse por encima de los 700 Km, la perspectiva de los sensores reduce significativamente la distorsión de la imagen con respecto al terreno (Lillesand et al., 2014).

Un sensor remoto puede generar varias imágenes al día de diferentes regiones de la superficie terrestre (Chuvienco, 2008). El tiempo que existe entre la captura de dos imágenes de un mismo punto se denomina resolución temporal (Gomarasca, 2004). La mayoría de las plataformas tienen una órbita heliosincrónica, es decir, los parámetros de movimiento del satélite están diseñados de tal forma que su posición relativa con respecto al sol se mantenga constante (Bolstad, 2012). Esto permite que las imágenes de un mismo punto se adquieran aproximadamente a la misma hora y en condiciones similares de observación, lo que facilita notablemente los análisis multitemporales (Viedma & Chuvienco, 1993).

Los sistemas de percepción remota se componen de varios subsistemas, además del subsistema de detección descrito previamente: subsistema de energía, conformado por paneles solares y baterías para alimentar el sistema en órbita; subsistema de almacenamiento de información y comunicación, para transmitir los datos adquiridos a la tierra; subsistema de posicionamiento y navegación, imprescindible para mantener la precisión altitudinal y el control orbital (Bolstad, 2012).

Adjunto a cada imagen satelital se puede encontrar un conjunto de datos de alta importancia. Este conjunto es denominado “metadato” y en él se pueden encontrar





datos de gran utilidad para el usuario, tales como fecha y hora de captura, ángulos de la posición del sol con respecto a la superficie capturada, coeficientes de calibración, entre otros.

Numerosos sistemas de percepción remota se han desarrollado desde principios de la década de los 70's; el detalle, la frecuencia y la calidad de las imágenes satelitales han mejorado constantemente desde entonces (Gomarasca, 2004). Actualmente existen varios sistemas en operación, cada uno diseñado para distintas aplicaciones, pero conservando el principio básico de la percepción remota (Bolstad, 2012).

La observación que realizan los satélites de percepción remota ha demostrado ser muy valiosa para el monitoreo ambiental, así como el estudio y prevención de desastres naturales como sequías, erupciones volcánicas o inundaciones (Viedma & Chuvieco, 1993). Su aplicación es tal que es posible incluso monitorear y cartografiar hábitats costeros como arrecifes (Abualhin, 2016).

Las imágenes multiespectrales empleadas en esta investigación provienen del Programa Landsat.

#### **2.1.2.1. Programa Landsat**

El Programa Landsat (Land Remote Sensing Satellite) es una colaboración entre la Administración Nacional de la Aeronáutica y el Espacio (National Aeronautics and Space Administration, NASA) y el Servicio Geológico de los Estados Unidos (U.S. Geological Survey, USGS) para mantener la adquisición, el almacenamiento y la distribución de imagerie multiespectral y proporcionar una cobertura global, sinóptica y repetitiva de la superficie terrestre en una escala donde los cambios naturales y antropogénicos puedan ser detectados, diferenciados, caracterizados y monitoreados a través del tiempo (Servicio Geológico de los Estados Unidos, 2012). El programa inició el 23 de julio de 1972 con la puesta en órbita del satélite Landsat 1. El éxito de este lideró el desarrollo de otros 6 satélites, permitiendo que la misión opere continuamente desde su lanzamiento hasta la actualidad (Bolstad, 2012).

Este programa ha empleado cuatro sensores diferentes hasta la fecha, siendo el Escáner Multiespectral (*Multispectral Scanner*, MSS), el pionero. Este sensor detectaba cuatro bandas espectrales (R, G, NIR y SWIR1) a 80 m de resolución espacial (Chuvieco, 1995). Satélites lanzados posteriormente mejoraron los sensores a bordo, y para el año 1999 se tenía en órbita al Landsat 7, cuyo sensor, el Cartógrafo Temático Mejorado (Enhanced Thematic Mapper Plus, ETM+), incluía mejoras como el aumento a seis bandas espectrales (R, G, B, NIR, SWIR1 y SWIR2) de 30 m de resolución espacial, la inclusión de una banda térmica (TIR) de 60 m de resolución

espacial y una banda pancromática que cubría el espectro visible (R, G, B) y una porción del infrarrojo cercano (NIR) de 15 m de resolución espacial (Goward, Masek, Williams, Irons, & Thompson, 2001).

El Landsat 8, puesto en órbita en 2013 y actualmente en funcionamiento, cuenta con dos sensores: el Generador Operacional de Imágenes (Operational Land Imager, OLI) y el Sensor Infrarrojo Térmico (Thermal Infrared Sensor, TIRS) (Irons, Dwyer, & Barsi, 2012). El primero incluye mejoras con respecto a su antecesor, el ETM+, tales como la inclusión de dos nuevas bandas exclusivas para estudios de aerosoles en zonas costeras y nubes cirrus; el segundo, como su nombre lo indica, se encarga de adquirir datos exclusivamente en ese espectro, generando dos bandas en lugar de una, a diferencia de sus predecesores (Irons et al., 2012).

El Programa Landsat ha generado una biblioteca de imágenes de más de 40 años de longevidad, y la mayoría están disponibles de manera gratuita para cualquier usuario con acceso a internet (Bolstad, 2012). La información proporcionada por la misión es crítica para caracterizar, entender y predecir cambios en la cobertura y el uso del suelo a nivel global (Irons et al., 2012).

Las ínfimas diferencias entre la resolución espectral de los sensores ETM+ y OLI (Tabla 1), además de la compatibilidad en términos de resolución espacial, tamaño de la imagen y cobertura geográfica permiten utilizar información proveniente de ambos sensores conjuntamente, de manera que es posible detectar cambios de coberturas y uso del suelo, así como otros tipos de análisis a grandes escalas temporales (Czapla-Myers et al., 2015; Irons et al., 2012).

**Tabla 1.** Especificaciones técnicas de los sensores ETM+ y OLI\*.

ETM+ (Landsat 7)			OLI (Landsat 8)		
Nombre	Rango espectral ( $\mu\text{m}$ )	Longitud de onda central ( $\mu\text{m}$ )	Nombre	Rango espectral ( $\mu\text{m}$ )	Longitud de onda central ( $\mu\text{m}$ )
B	0,452-0,514	0,483	B	0,450-0,515	0,483
G	0,519-0,601	0,560	G	0,525-0,600	0,561
R	0,631-0,692	0,662	R	0,630-0,680	0,655
NIR	0,772-0,898	0,835	NIR	0,845-0,885	0,865
SWIR1	1,547-1,748	1,648	SWIR1	1,560-1,660	1,609

\*Sólo se describen las bandas empleadas en esta investigación.

Fuente: Chander, Markham, & Helder (2009); Czapla-Myers et al. (2015).

---

## 2.2. Aplicación de la Percepción Remota

### 2.2.1. Preprocesamiento de imágenes satelitales

Previo a cualquier análisis, las imágenes generadas por un sensor deben ser sometidas a un proceso que corrija los errores que se presentan normalmente durante la adquisición y transmisión de la imagen (Chuvienco, 2008; Gomasasca, 2004).

Estos errores están relacionados a varios factores: 1) el movimiento del satélite durante la adquisición, que distorsiona geoméricamente la imagen; 2) problemas mecánicos en el sensor, que generan píxeles vacíos o con ND incorrectos; 3) la capa de atmósfera entre el sensor y la cubierta terrestre, que afecta la respuesta espectral de la cobertura al absorber y distorsionar la energía y 4) las características topográficas del terreno y la posición del sol, que generan sombras y alteraciones en los valores reales de los ND (Gomasasca, 2004).

En el caso del Programa Landsat, las imágenes disponibles al usuario ya cuentan con georreferenciación, corrección al primer y segundo factor de error (corrección geométrica y corrección radiométrica) (Servicio Geológico de los Estados Unidos, 2012). La corrección del tercer y cuarto factor de error (corrección atmosférica y corrección topográfica) se delega a las habilidades y conveniencias del usuario.

#### 2.2.1.1. Corrección atmosférica

Las condiciones atmosféricas pueden variar significativamente espacial y temporalmente (Lillesand et al., 2014). Esta variación repercute negativamente en las imágenes satelitales, ya que la atmósfera puede absorber y distorsionar la energía electromagnética reflejada por la superficie terrestre (Gomasasca, 2004). Estos efectos dependen de las condiciones de la atmósfera en un tiempo y espacio determinado, por lo que su corrección se hace imprescindible en análisis multi-imagen, multitemporales, multi-sensor e incluso análisis mediante índices de vegetación (Chavez, 1996; Gomasasca, 2004; Lu, Mausel, Brondizio, & Moran, 2010).

No existe un único modelo para corregir atmosféricamente una imagen, por el contrario, se han desarrollado numerosas alternativas para problemas específicos y diferentes niveles de precisión (Gomasasca, 2004). Se distinguen dos grupos: métodos basados en la física de la transferencia radiativa y métodos basados en la información de las imágenes (Gomasasca, 2004).

Los primeros son los más precisos y a la vez los más complejos. Por ejemplo, para describir correctamente la propagación de la radiación mediante el método 5S/6S (Tanré et al., 1990) se requieren mediciones *in situ* de ciertos parámetros como

condiciones geométricas (ángulo azimutal y cenital solar), composición atmosférica, perfiles de presión y temperatura, concentración de aerosoles, entre otros. En la mayoría de los casos no se dispone de esta información, y la aplicación de este tipo de métodos se ve bastante limitada, sobre todo en análisis que requieren series históricas de imágenes satelitales (Lu et al., 2010).

Los segundos son más numerosos. El más simple de estos es el modelo de la reflectancia aparente, propuesto por Markham y Barker (1986); este convierte la reflectancia aparente (reflectancia en el techo de la atmósfera, luego de la distorsión) a reflectancia de la superficie (reflectancia original, sin efectos atmosféricos) corrigiendo la ganancia, el sesgo, la irradiancia solar y el ángulo cenital, pero ignora la distorsión atmosférica.

El modelo basado en la sustracción del objeto oscuro (Dark Object Sustraction, DOS), propuesto por Chavez (1988, 1996) considera la trayectoria de la energía en el modelo de reflectancia aparente, pero generaliza otros aspectos, como que el efecto multiplicativo de la atmósfera es constante, que la superficie de la escena es plana, que la trayectoria de la energía es uniforme, que ciertos píxeles en la imagen están en completa oscuridad y que la energía captada por el sensor en estos píxeles se debe a la distorsión atmosférica. No obstante, es una alternativa simple y eficiente para corregir los efectos atmosféricos cuando no se requiere una precisión extrema (Lu et al., 2010).


### **2.2.1.2. Corrección topográfica**

La configuración geométrica del sistema sol-superficie-sensor durante la adquisición de la imagen afecta la respuesta espectral de la superficie en términos cuantitativos, modificando la intensidad de la energía que se detecta (Gomasasca, 2004). Para corregir este efecto se consideran dos variables principales: el ángulo solar y la pendiente del terreno.

Para corregir la iluminación se toma en cuenta la posición del sol, medida a través del ángulo cenital y azimutal durante la adquisición de la imagen, mientras que para corregir la topografía se toma en cuenta la orientación relativa de las superficies con respecto a la dirección de donde viene la luz (Hantson & Chuvieco, 2011). Como se ejemplifica en la ilustración 2, La reflectancia es mayor cuando la incidencia es ortogonal a la superficie y, por ende, es menor cuando la superficie está en penumbra (Riano, Chuvieco, Salas, & Aguado, 2003). En estudios de carácter multitemporal, la normalización con respecto al ángulo solar es imprescindible (Hantson & Chuvieco, 2011).

Al igual que con los efectos atmosféricos, los efectos topográficos también pueden ser corregidos por numerosos métodos. El más simple es el método del Coseno (Teillet, Guindon, & Goodenough, 1982), no obstante, se ha demostrado que sobre corrige áreas con poca iluminación (Füreder, 2010; Meyer, Itten, Kellenberger, Sandmeier, & Sandmeier, 1993; Twele & Erasmi, 2005).

En respuesta a esto, Civco (1989) desarrolló a partir del método del Coseno un algoritmo mejorado que suaviza la corrección en áreas poco iluminadas y, en general, ofrece mejores resultados (Hantson & Chuvieco, 2011).



**Ilustración 2.** Efectos de la pendiente y la incidencia solar en la distorsión de las reflectancias durante la captura de una imagen satelital.  
Fuente: Riano et al., (2003).

### **2.2.2. Índices de vegetación**

Las coberturas vegetales, como cualquier objeto, emiten energía detectable por un sensor remoto. Esta energía es diferente según las características y la situación de las coberturas (Sancha, 2010). Por lo tanto, los índices de vegetación son instrumentos que permiten conocer la situación de los elementos vegetales situados sobre la superficie terrestre a través de la energía que emiten y/o reflejan (Sancha, 2010). Con estas herramientas no sólo es posible conocer el estado de una cubierta vegetal, sino características más complejas como la actuación de los diferentes pigmentos de la hoja, su estructura, su forma, y el grado de humedad o estrés hídrico que posea (Ke, Im, Lee, Gong, & Ryu, 2015).

La energía reflejada por la vegetación es realmente significativa en el rango de longitud de onda entre 0,4 y 2,8  $\mu\text{m}$ , correspondiente al espectro visible, el infrarrojo cercano y una estrecha franja de longitud de onda del infrarrojo medio (Sancha, 2010). La energía que recibe el sensor en cada banda lleva consigo información específica sobre las características fisiológicas de la planta: en el espectro visible es posible

obtener datos sobre la pigmentación de la hoja (clorofila, xantofila y caroteno), en el infrarrojo cercano sobre su estructura interna y en el infrarrojo medio sobre el contenido de agua en esta (Sancha, 2010).

A lo largo de la implementación de los sensores remotos se han desarrollado numerosos índices que relacionan las bandas antes mencionadas para obtener una valoración cuantitativa de las cubiertas vegetales (Sancha, 2010). A continuación, se detallan dos índices ampliamente utilizados.

### **2.2.2.1. Índice de Vegetación Diferencial Normalizado**

El Índice de Vegetación Diferencial Normalizado (Normalized Difference Vegetation Index, NDVI), es un índice que permite determinar la calidad de la vegetación (Pettorelli et al., 2011). Propuesto por Jordan (1969), actualmente es el índice de vegetación más utilizado (Ke et al., 2015).

La vegetación sana absorbe intensamente la radiación solar, debido a la presencia de clorofila foliar, no así en la región espectral del infrarrojo cercano, en donde exhibe una alta reflexión debido a la estructura interna de las hojas sanas (Sancha, 2010). De esta manera, mientras más sano se encuentra un vegetal, más alta es la diferencia de reflexión entre la luz roja y el infrarrojo cercano (Pettorelli et al., 2011). Este índice se expresa adimensional, en valores entre -1 y 1, siendo más cercano a 1 para vegetación sana y cercano a 0 para vegetación enferma. Otras superficies como agua o nubes pueden presentar valores negativos descartables (Córdova & García, 2013).

### **2.2.2.2. Índice de Agua Diferencial Normalizado**

El Índice de Agua Diferencial Normalizado (Normalized Difference Water Index, NDWI) es un índice que permite evaluar el contenido de agua en la vegetación (Córdova & García, 2013). Fue propuesto por Gao (1996) como un índice sensible a los cambios en el contenido de agua presente en la vegetación y a su vez poco interferido por los efectos de dispersión atmosférica. Este índice no debe ser considerado como sustituto del NDVI, sino como un índice independiente y complementario a este (Chen, Zhao, Li, & Yin, 2006). Al igual que el NDVI, este índice se expresa en valores entre -1 y 1, siendo más cercano a 1 para vegetación con alto contenido de humedad y cercano a 0 para vegetación seca (Córdova & García, 2013).

### **2.2.3. Clasificación digital de imágenes satelitales**

La clasificación digital supone, en la mayoría de los casos, la culminación del tratamiento de imágenes satelitales (Chuvieco, 2008). Clasificar una imagen implica categorizarla en términos estadísticos, es decir, reducir la escala de medida de una variable continua (ND), a una escala nominal o categórica (clases temáticas)

(Mendoza, 2010). La imagen multiespectral es transformada en otra imagen en donde los ND que definen a cada píxel dejan de tener relación con la energía detectada, y pasan a ser una etiqueta que identifica las categorías o clases temáticas que supongan un mejor conocimiento del territorio (Mendoza, 2010).

La clasificación digital no busca una definición absoluta de cada clase temática, que pudiera ser aplicable a cualquier imagen, sino más bien una caracterización particular, válida para una determinada imagen y un territorio concreto (Gomarasca, 2004). Como fruto de la clasificación digital, la información multiespectral se condensa, en definitiva, en información cartográfica y estadística que definen la localización y ofrecen un inventario superficial de las clases temáticas de interés (Chuvieco, 2008).

Si bien la clasificación digital supone muchas ventajas, sus resultados distan de ser totalmente precisos (Malarvizhi, Vasantha, & Porchelvan, 2016). La confiabilidad de un mapa temático es el grado de correspondencia entre los fenómenos geográficos *in situ* y sus representaciones en él (Mas et al., 2009). Esta depende de la metodología adoptada y de la calidad de los datos sobre los que se aplica (Gomarasca, 2004). Las fuentes de error de una clasificación digital se pueden agrupar según Chuvieco (2008) en: i) estructura del territorio; ii) nivel de desagregación; iii) adquisición de la imagen y; iv) condiciones medioambientales.

La estimación de la confiabilidad de un mapa temático puede realizarse por diversos criterios, como comparar la clasificación con la obtenida por diferentes fuentes, siempre y cuando tengan un mayor nivel de detalle (Mas et al., 2009) o, el más utilizado, seleccionando áreas de verificación para las que se cuenta con la cubierta realmente presente en el suelo (Chuvieco, 2008). Este último se conoce como matriz de confusión, y es llamada así puesto que recoge en una matriz bidimensional los conflictos que se presentan entre categorías. Las filas se ocupan por las clases de referencia, y las columnas por las categorías deducidas de la clasificación. La diagonal de esta matriz expresa el número de puntos de verificación en donde se produce acuerdo entre el mapa y la realidad, mientras que los marginales representan errores de asignación. La relación entre el número de píxeles correctamente asignados y el total expresa la fiabilidad global del mapa (Chuvieco, 2008).

### **2.2.3.1 Cobertura y uso del suelo**

Las categorías más comunes de clasificación de una imagen satelital son las relacionadas a la cobertura y el uso del suelo (Chuvieco, 2008). Si bien estos términos



están estrechamente relacionados, no son lo mismo. Gomarasca (2004) explica la diferencia entre cobertura y uso del suelo:

- **Cobertura** se refiere a la superficie física sobre la tierra, incluyendo varias combinaciones de vegetación natural y cultivada e infraestructuras hechas por el humano. Superficies como agua, glaciares, rocas y suelo desnudo no necesariamente son una forma de cobertura, no obstante, se las considera así por cuestiones prácticas.
- **Uso**, por otra parte, incluye tanto la manera en cómo los atributos biofísicos son modificados y las razones de su alteración. El uso del suelo se ve afectado por acciones humanas, especialmente aquellas basadas en el manejo y control del suelo. La dinámica del uso del suelo también es indicadora de los cambios de coberturas (Gomarasca, 2004).

La utilidad de los mapas de cobertura y uso del suelo se intensifica cuando se utiliza la información para detectar cambios en estas a través de análisis multitemporales. La representación cartográfica de la información resulta de especial relevancia, puesto que, sin ella se torna difícil entender la relación entre los procesos de cambio (causas, efectos, escenarios probables) y fenómenos relacionados como fragmentación de hábitats, emisión de carbono, ciclos hidrológicos, pérdida de servicios ambientales, entre otros (Mas et al., 2009).

#### ***2.2.4. Análisis multitemporales***

Un análisis multitemporal mediante imágenes satelitales permite detectar cambios espaciales en clases temáticas (comúnmente cobertura y uso del suelo) entre dos fechas de referencia, deduciendo la evolución del medio natural o las repercusiones de la acción humana sobre dichas clases (Mendoza, 2010). En los últimos años, las coberturas y el uso del suelo están cambiando a un ritmo acelerado debido al crecimiento poblacional y a los avances en la tecnología (Irons et al., 2012; Mas et al., 2009).

Estos cambios tienen profundas consecuencias para la sociedad con respecto a la producción de comida, manejo del agua, servicios ecosistémicos, calidad del aire y del agua, salud y cambio climático (Irons et al., 2012). De esta manera, la detección de cambios a partir de una secuencia multitemporal de imágenes satelitales se vuelve una de las aplicaciones más importantes en percepción remota, debido a la facilidad que presenta analizar estos cambios, incluso a grandes escalas temporales (Mendoza, 2010).

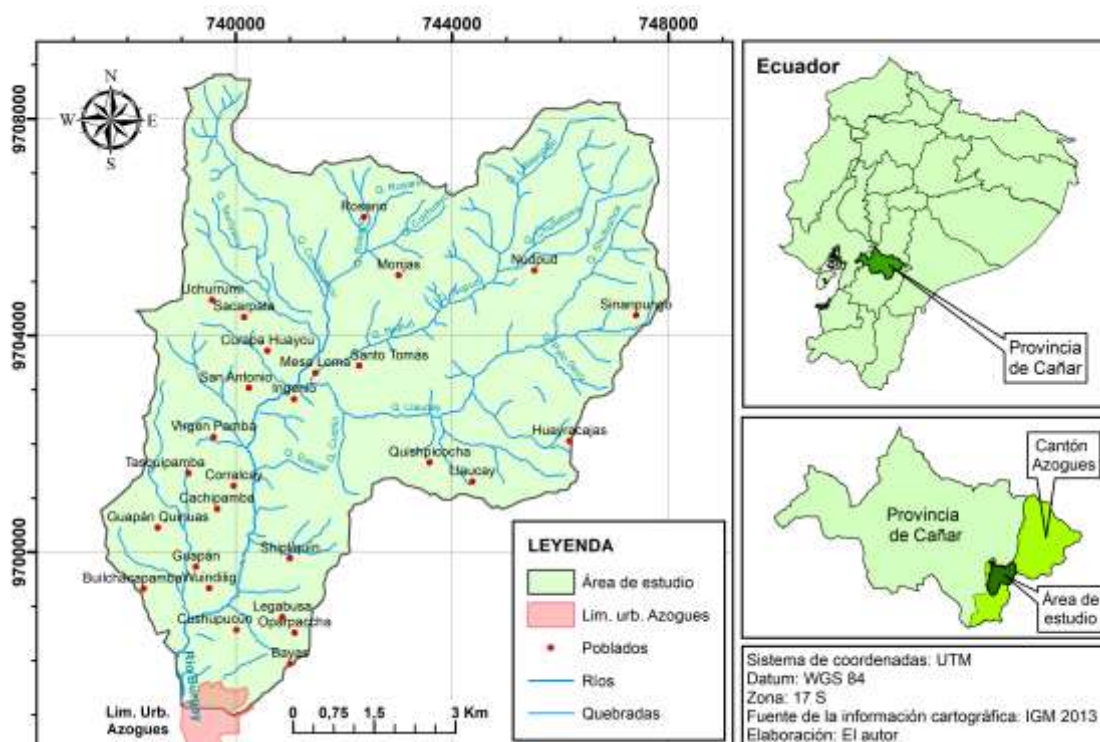


## CAPÍTULO II

### 3. METODOLOGÍA

#### 3.1. Área de estudio

El área de estudio corresponde administrativamente al cantón Azogues, provincia de Cañar, e hidrológicamente a la microcuenca del río Tabacay, subcuenca del río Burgay, Cuenca del río Paute (Ilustración 3). Los principales afluentes de esta microcuenca son las quebradas Llaucay, Nudpud, Cóndor Yacu, Rosario, Mapayacu y Rubís. Su superficie abarca 68.3 Km<sup>2</sup>, su gradiente altitudinal va desde 2490 hasta 3730 m.s.n.m.; la temperatura promedio de esta zona es de 14° C, la humedad relativa promedio es de 76.1 % y la precipitación anual promedio es de 894.6 mm (EMAPAL EP et al., 2005).



**Ilustración 3.** Mapa base del área de estudio.  
Fuente de la información cartográfica: IGM (2013).  
Elaboración: El autor.

#### 3.2. Determinación de clases de uso del suelo

Las clases temáticas empleadas en esta investigación se determinaron de dos formas: mediante la extracción de clases predefinidas a partir de documentación referente a la microcuenca estudiada y mediante visitas de campo, a fin de comprobar la existencia de las clases documentadas.



Únicamente dos documentos oficiales contienen información sobre la cobertura y el uso del suelo en la microcuenca del río Tabacay. A continuación, se detallan las clases de uso de suelo descritas en cada documento revisado:

- *Plan de desarrollo y ordenamiento territorial de la provincia de Cañar (PDOTC)*

Dentro del PDOTC (GAD provincial de Cañar, 2015) se divide al territorio en tres zonas de planificación de acuerdo a los cantones de esta provincia, de los cuales el cantón Azogues, al cual pertenece la microcuenca estudiada, forma parte de la zona 1. Para esta zona, se describen las siguientes clases de cobertura y uso del suelo:

- Cultivo de ciclo corto
- Cultivo perenne
- Pastos cultivados
- Pastos naturales
- Bosque y vegetación arbustiva
- Páramo

- *Plan de Manejo de la microcuenca del río Tabacay (PMT)*





En el PMT (EMAPAL EP et al., 2005) se establecieron tres tipos de tierras, correspondientes a las partes alta, media y baja de la microcuenca, dentro de los cuales se describen los siguientes usos de suelo:

- Urbano
- Cultivos perennes
- Cultivos de ciclo corto
- Bosque
- Pastizal
- Páramo

- *Visita de campo*

Durante esta visita se comprobó la existencia de las clases de uso del suelo descritas en los documentos revisados. A partir de esta comprobación se seleccionaron las clases definitivas. En la tabla 2 se describen las clases seleccionadas.

**Tabla 2.** Descripción de las clases de uso de suelo.

Clase de uso de suelo	Descripción	Referencia fotográfica
Urbano	Incluye mayoritariamente infraestructura, carreteras y caminos vecinales. También incluye suelo desnudo producto de excavaciones y deforestación.	
Agropecuario	Incluye cultivos de ciclo corto (maíz, hortalizas, papas, etc.) y perennes (manzana, capulí, etc.). Incluye pastos naturales como el kikuyo y pastos cultivados para ganadería (ray grass, etc.).	
Forestal	Incluye chaparral, bosques de pino, bosques de eucalipto y bosques mixtos (pino, eucalipto y vegetación nativa).	
Páramo	Incluye vegetación arbustiva, bosque natural y humedal por encima de 3300 m.s.n.m.	

Fuente de la descripción: EMAPAL EP et al. (2005).

Fuente de la referencia fotográfica: El autor.

### 3.3. Preprocesamiento

Se utilizaron tres imágenes satelitales, provenientes del Programa Landsat, descargadas del portal web del USGS (Servicio Geológico de los Estados Unidos, 2018c). Información relevante de cada imagen satelital se detalla en la siguiente tabla:

**Tabla 3.** Detalle de las imágenes satelitales utilizadas.

Fecha de captura	Satélite	Sensor	Resolución espacial
29 de diciembre de 2004	Landsat 7	ETM+	30 m
28 de noviembre de 2013	Landsat 8	OLI	30 m
20 de noviembre de 2016	Landsat 8	OLI	30 m

Fuente: (Servicio Geológico de los Estados Unidos, 2018c).

#### 3.3.1. Corrección de bandeado (Gap-filling)

Desde 2003, el sensor ETM+ del satélite Landsat 7 sufre un desperfecto en su sistema SLC (Scan Line Corrector), el cual compensa el movimiento del satélite durante la

adquisición de la imagen. Sin el SLC, el área escaneada genera un patrón de zigzag provocando un bandeo o “*gap-effect*” en la escena.

Para solucionar este defecto y rellenar el bandeo en la imagen del año 2005 se aplicó el método propuesto por el USGS (2018a), en el cual se interpolan los píxeles de los bordes hacia el centro del vacío mediante la herramienta *Focal Analysis* del software ERDAS IMAGINE 2014.

### 3.3.2. Correcciones

Los algoritmos descritos a continuación se ejecutaron empleando la herramienta *Band Math* del software ENVI 5.3.

#### 3.3.2.1. Corrección atmosférica

Se convirtieron los ND originales a términos de radiancia ( $L_\lambda$ ). La radiancia es el flujo de energía que abandona una unidad de área en una dirección siguiendo un ángulo sólido particular. Se mide en  $W \cdot m^{-2} \cdot sr^{-1} \cdot \mu m^{-1}$  y se calcula a partir de la ecuación 1:

$$L_\lambda = G * ND + B \quad (\text{Ecuación 1})$$

Donde  $ND$  es el nivel digital original de cada píxel;  $G$  la ganancia y  $B$ , el sesgo.  $G$  y  $B$  son coeficientes de calibración; estos son específicos para cada banda y para cada satélite. Estos se encuentran en el metadato de cada imagen satelital como “*RADIANCE\_MULT\_BAND\_#*” y “*RADIANCE\_ADD\_BAND\_#*” respectivamente.

A partir de  $L_\lambda$  se calculó la reflectancia en la superficie terrestre ( $\rho$ ). La reflectancia es la parte de la energía recibida que refleja la superficie receptora, esta es diferente para cada superficie, se mide en tanto por uno y se considera adimensional. Para determinarla se aplicó el método basado en el objeto oscuro propuesto por Chavez (1996) (Ecuación 2), ya que la estabilidad temporal de las escenas se conserva mejor con este método (Hantson et al., 2011):

$$\rho = \frac{\pi * [L_\lambda - L_a] * d^2}{\cos \theta_z * E_{solar} * \tau_1 * \tau_2} \quad (\text{Ecuación 2})$$

Donde  $E_{solar}$  es la irradiancia exoatmosférica solar (en  $W \cdot m^{-2} \cdot \mu m^{-1}$ );  $\tau_1$  es el coeficiente de transmisión atmosférica en el camino sol-tierra;  $\tau_2$  es el coeficiente de transmisión atmosférica en el camino tierra-sensor;  $L_a$  es la radiancia espectral recibida por el sensor en un área donde sólo hay contribución de la atmósfera (área de sombra o agua según la región espectral);  $L_\lambda$  es la radiancia espectral;  $\theta_z$  es el ángulo cenital solar y  $d$  es la distancia tierra-sol medida en unidades astronómicas.

Chavez (1996) propuso la estimación de la transmisión atmosférica con valores estándar para cada una de las bandas. Para  $\tau_1$  se empleó los valores de 0,85; 0,78; 0,70; 0,91 y 0,95 para las bandas roja, verde, azul, infrarrojo cercano e infrarrojo medio respectivamente. Para  $\tau_2$  se consideró 1 en todas las bandas, como aconseja Chavez (1996), pues la observación siempre es vertical.

$L_a$  se estimó utilizando el valor mínimo del histograma de valores de  $L_\lambda$ , utilizando únicamente el área de estudio. El histograma se generó mediante el software ENVI 5.3. La *distancia tierra-sol* ( $d$ ) se obtuvo del metadato de cada imagen; esta variable se halla como "EARTH\_SUN\_DISTANCE". Por otra parte,  $\theta_z$  se puede calcular restando de 90 el valor de "SUN ELEVATION", también disponible en el metadato.

Para  $E_{solar}$  se utilizaron los valores propuestos por el USGS (2018b) para la imagen de Landsat 7. Para las imágenes de Landsat 8 se utilizaron los valores propuestos por Leutner (2016).

### 3.3.2.2. Corrección topográfica

En primera instancia se calculó el ángulo de iluminación de la escena mediante la ecuación 3 (Civco, 1989):

$$\cos \gamma_i = \cos \theta_z \cos \eta_i + \sin \theta_z \sin \eta_i \cos(\phi_a - \phi_o) \quad (\text{Ecuación 3})$$

Donde  $\gamma_i$  es el ángulo de incidencia de la luz solar en la superficie;  $\theta_z$  es el ángulo cenital solar;  $\eta_i$  es el ángulo de inclinación de la superficie de incidencia;  $\phi_a$  es el ángulo azimutal solar y  $\phi_o$  es el ángulo de orientación de la pendiente de la superficie. Los ángulos que dependen de la posición del sol son únicos para cada imagen satelital, por lo que estas variables se calcularon para cada una por separado.

Para calcular los ángulos de inclinación y orientación de la pendiente fue necesario un Modelo Digital del Terreno (MDT), con igual resolución espacial que las imágenes a corregir (30 m), generado en el software ArcGIS 10.5 a partir de archivos vector de curvas de nivel y perímetro de la microcuenca obtenidos del portal web del Instituto Geográfico Militar del Ecuador (Instituto Geográfico Militar, 2017). Por otra parte,  $\phi_a$  fue obtenido del metadato de cada imagen; este se encuentra como "SUN\_AZIMUTH".  $\theta_z$  se puede calcular restando de 90 el valor de "SUN ELEVATION", también disponible en el metadato. Para la corrección como tal se empleó el método del coseno mejorado, propuesto por Civco (1989). La ecuación es la siguiente:

$$\rho_{\lambda,h,i} = \rho_{\lambda,i} + \rho_{\lambda,i} \left( \frac{\cos \bar{\gamma} - \cos \gamma_i}{\cos \bar{\gamma}} \right) \quad (\text{Ecuación 4})$$

Donde  $\rho_{\lambda,h,i}$  es la reflectancia en terreno horizontal;  $\rho_{\lambda,i}$  es la reflectancia en terreno inclinado;  $\cos(\gamma_i)$  es el ángulo de iluminación de la escena y  $\cos(\bar{\gamma})$  es el ángulo de iluminación promedio del terreno.

### 3.4. Análisis de la vegetación

Una vez corregidas las imágenes se procedió a la aplicación de los índices de vegetación:

#### 3.4.1. NDVI

Este índice se calculó mediante la ecuación 5 (Jordan, 1969):

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad (\text{Ecuación 5})$$

Donde  $\rho_{NIR}$  es el valor de reflectancia de la banda del Infrarrojo Cercano y  $\rho_{RED}$  es el valor de reflectancia de la banda roja.

Holben (1986) propuso un valor umbral de NDVI de 0,09 para vegetación en estado crítico; por otra parte, para vegetación en condiciones promedio y vegetación densa y sana propuso valores mínimos de 0,14 y 0,50 respectivamente. Chen et al. (2006) establece un valor mínimo de NDVI de 0,20; al igual que Viedma y Chuvieco (1993), quienes plantean que las cubiertas vegetales presentan un valor umbral de 0,2. Gao (1996) establece que este índice presenta poca variación espacial en áreas con vegetación verde, es decir, en el rango elevado del espectro, esto equivale a valores de NDVI entre 0,50 y 0,90; por lo que es prudente segmentar este intervalo. En concreto, se definieron cuatro niveles de calidad vegetal considerando los umbrales descritos previamente. Los rangos empleados se muestran en la siguiente tabla:

Tabla 4. Clases de calidad vegetal empleadas.

Clasificación de cobertura vegetal	NDVI mínimo	NDVI máximo
Vegetación sana	0,700001	1,000000
Vegetación promedio	0,500001	0,700000
Vegetación enferma	0,200001	0,500000
Otros	-1,000000	0,200000

Fuente: El autor.

#### 3.4.2. NDWI

Para su cálculo se empleó la ecuación 6 (Gao, 1996):



$$NDWI = \frac{\rho_{NIR} - \rho_{SWIR}}{\rho_{NIR} + \rho_{SWIR}} \quad (\text{Ecuación 6})$$

Donde  $\rho_{SWIR}$  es el valor de reflectancia del Infrarrojo de onda corta y  $\rho_{GREEN}$  es el valor de reflectancia de la banda verde.

Gao (1996) propone un valor umbral mínimo de NDWI de 0,064 para vegetación húmeda; por otra parte, Chen et al. (2006) plantea un valor mínimo de 0,05. Valores mayores a estos indican un nivel más alto de humedad en la vegetación. Al igual que con el NDVI, la variación espacial del NDWI se acumula en un rango de valores, en este caso el rango bajo, es decir, valores de NDWI entre 0,10 y 0,40 (Gao, 1996).

Se definió cuatro clases de contenido de humedad vegetal, considerando los umbrales descritos previamente. Los rangos empleados se muestran en la siguiente tabla:

**Tabla 5.** Clases de contenido de humedad vegetal empleadas.

Cobertura vegetal	NDWI mínimo	NDWI máximo
Vegetación con alta humedad	0,300001	1,000000
Vegetación con humedad promedio	0,100001	0,300000
Vegetación con déficit de humedad	0,000001	0,100000
Otros	-1,000000	0,000000

Fuente: El autor.

### 3.5. Selección de áreas de entrenamiento y de prueba

Se recorrió el área de estudio para geolocalizar áreas representativas de cada uso del suelo. Dichas áreas tuvieron un límite mínimo de 360 m<sup>2</sup> de superficie, es decir, 2x2 píxeles. Una fracción de estas áreas fue empleada para entrenar a los métodos de clasificación supervisada, mientras que la fracción restante sirvió para evaluar dichos métodos mediante la generación de matrices de confusión.

De esta manera se crearon las regiones de interés (Regions Of Interest, ROIs) de entrenamiento y de prueba con la herramienta *ROI tool* del software ENVI 5.3. A partir de estas, en conjunto con la imagen satelital del año 2017 se desarrolló la clasificación supervisada y su posterior verificación.

Debido a que las imágenes satelitales de los años 2005 y 2013 tienen diferencias temporales considerables con la fecha de selección de áreas, se optó por determinar sus respectivas áreas de entrenamiento y de prueba mediante la comparación de estas con la imagen más reciente, a fin de emplear los mismos puntos obtenidos en áreas significativas en donde no se haya detectado gráficamente cambios drásticos del uso del suelo.

---

### 3.6. Clasificación supervisada

Se aplicaron dos métodos de clasificación supervisada: máxima probabilidad y redes neuronales. Ambos métodos clasifican cada píxel de la imagen en clases predefinidas por muestras (áreas de entrenamiento). Mientras mayor sea el número de píxeles de las áreas de entrenamiento, más precisa será la clasificación (Chuvieco, 2008). Ambos métodos de clasificación fueron aplicados mediante el software ENVI 5.3 sobre una composición RGB de las tres imágenes satelitales preprocesadas.

#### 3.6.1. Verificación

Una vez realizada la clasificación supervisada por ambos métodos y para todas las imágenes, se procedió a generar matrices de confusión para cada uno de estos. Para esto se utilizó la herramienta *Confusion Matrix* del software ENVI 5.3. Esta herramienta relaciona una cantidad de píxeles de prueba con los píxeles de entrenamiento y revela por clase de uso de suelo la cantidad de píxeles que fueron asignados correctamente y los que no. Como puntos de control para la elaboración de la matriz se emplearon áreas representativas de cada uso del suelo, al igual que en la clasificación supervisada, obtenidas mediante visitas de campo.

Finalmente se obtuvo un valor de precisión global de la clasificación para cada método e imagen analizada, dado por la herramienta y el software antes mencionado en base a la matriz de confusión generada. Este indicador se mide en porcentaje y representa la cantidad de píxeles de prueba asignados correctamente a las clases de uso del suelo. Adicionalmente, *Confusion Matrix* brinda otro valor que, a breves rasgos, permite cuantificar la calidad de la clasificación de manera complementaria al valor de la precisión global, denominado Coeficiente de Kappa (Mendoza, 2010).

A partir de este punto se trabajó con los resultados de la clasificación por el método más preciso, según la precisión global y el coeficiente de Kappa.

### 3.7. Análisis multitemporal y estadístico

Mediante el software ArcGIS 10.5, los polígonos correspondientes a cada clase de uso del suelo fueron unificados, a fin de obtener la superficie total de cada una de estas. Los polígonos de la clasificación de los años 2005 y 2017 fueron interceptados para determinar las superficies donde se dio una transición entre clases.

Los valores de superficie total y de transición fueron exportados al software Excel 2016, en el que se realizaron las operaciones matemáticas necesarias para obtener los porcentajes de ocupación de cada clase, así como una matriz de transición, siguiendo la metodología propuesta por Pontius, Shusas y McEachern (2004), además



de las tasas de cambio anual de sus superficies durante el periodo de estudio y, finalmente, mapas temáticos que representen visualmente los resultados.

### 3.7.1. Tasa de Cambio Anual (TCA)

Para estimar las TCA de las clases de uso del suelo se optó por utilizar la ecuación propuesta por Puyravaud (2003), descrita a continuación:

$$TCA = \frac{1}{t_2 - t_1} \ln \left( \frac{S_2}{S_1} \right) * 100 \quad (\text{Ecuación 7})$$

Donde  $t_1$  y  $t_2$  representan el año de evaluación inicial y final, respectivamente, y  $S_1$  y  $S_2$  representan las superficies del uso del suelo en el tiempo 1 y 2, respectivamente.

La razón del cambio en la superficie es un indicador ampliamente utilizado de la trayectoria de los ecosistema a través del tiempo, ya que el aumento o la disminución del área puede facilitar o reducir la habilidad de un ecosistema de mantener las características de su biota y los procesos fundamentales de esta (Murray et al., 2018).

### 3.7.2. Correlación

Las áreas correspondientes a cada clase fueron correlacionadas en pares de la siguiente manera: agropecuario vs forestal, agropecuario vs páramo, urbano vs forestal y urbano vs páramo. Se estableció esta configuración de tal forma que se relacione directamente la influencia de las actividades antropogénicas en la disminución de superficie del uso forestal y de páramo dentro del área de estudio. Para estimar la correlación se empleó el coeficiente de correlación de Pearson ( $r_{xy}$ ), mediante la siguiente ecuación:

$$r_{xy} = \frac{\frac{\sum XY}{N} - \bar{X}\bar{Y}}{\sqrt{\frac{\sum X^2}{N} - \bar{X}^2} * \sqrt{\frac{\sum Y^2}{N} - \bar{Y}^2}} \quad (\text{Ecuación 8})$$

Donde X y Y son los valores de las variables que se desea correlacionar. En este caso, X y Y corresponden a las áreas de cada clase de uso del suelo ordenadas cronológicamente. A partir del coeficiente de correlación de Pearson se calculó el coeficiente de determinación ( $r^2$ ), elevando al cuadrado su valor. El coeficiente de determinación ofrece una idea más cabal de la magnitud de la relación, es decir, se entiende como una proporción de variabilidad.

## CAPÍTULO III

### 4. RESULTADOS Y DISCUSIÓN

#### 4.1. Análisis de la vegetación

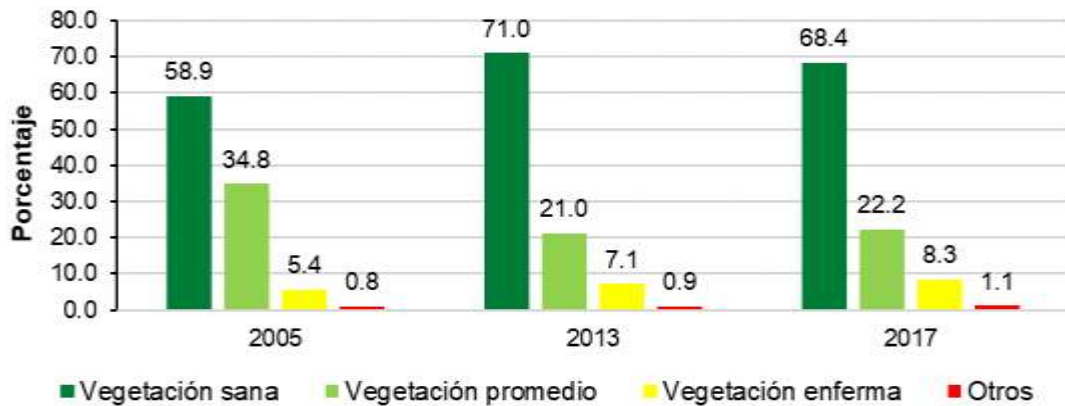
##### 4.1.1. NDVI

En la tabla 6 y la ilustración 4 se puede observar que la clase de calidad vegetal correspondiente a vegetación sana fue predominante en términos de superficie durante todo el periodo de análisis. Esta presentó un aumento de su ocupación de 4025.8, 4847.8 y 4669.2 ha, correspondientes al 58.9, 71.0 y 68.4% de la superficie de la microcuenca en 2005, 2013 y 2017 respectivamente. La vegetación promedio presentó una disminución considerable de su ocupación, pasando de 2376.8 ha en 2005 a 1516.9 ha en 2017; teniendo el pico más bajo de ocupación en 2013, con 1436.9 ha, equivalentes al 21% de la superficie de la microcuenca. La vegetación enferma presentó la menor ocupación del área de estudio, no obstante, su cubierta aumentó de 371.3 ha en 2005 a 569.0 ha en 2017, correspondientes al 5.4 y 8.3% de la superficie de la microcuenca respectivamente.

**Tabla 6.** Evolución de la calidad vegetal en superficie y porcentaje para 2005, 2013 y 2017.

Clases	2005		2013		2017	
	ha	%	ha	%	ha	%
Vegetación sana	4025.8	58.9	4847.8	71.0	4669.2	68.4
Vegetación promedio	2376.8	34.8	1436.9	21.0	1516.9	22.2
Vegetación enferma	371.3	5.4	486.7	7.1	569.0	8.3
Otros	56.7	0.8	59.3	0.9	75.4	1.1
<b>Total</b>	<b>6830.6</b>	<b>100.0</b>	<b>6830.6</b>	<b>100.0</b>	<b>6830.6</b>	<b>100.0</b>

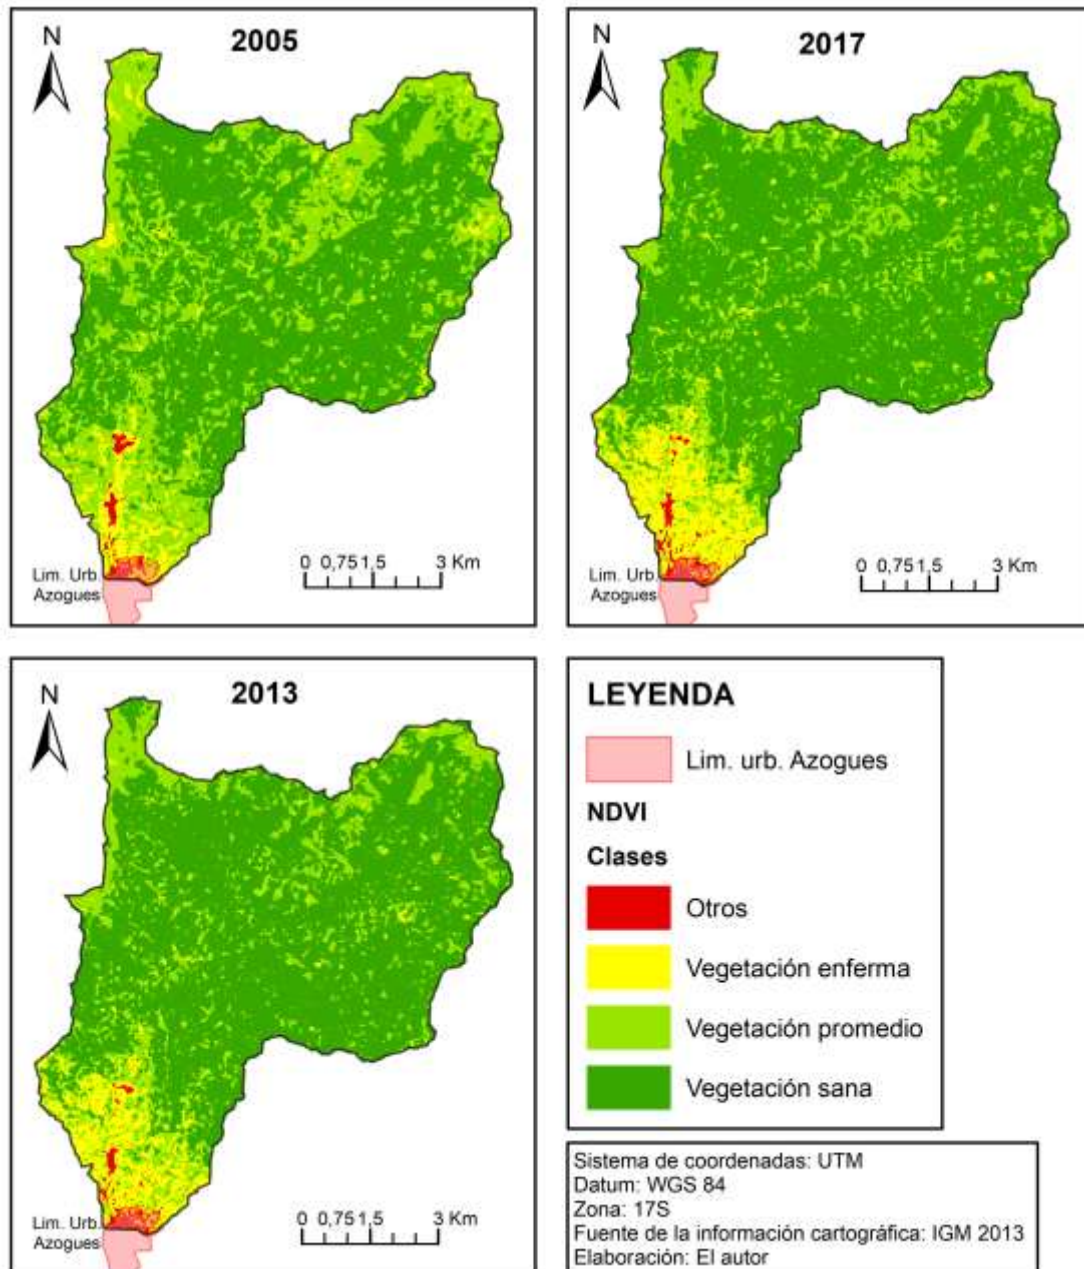
Fuente: El autor.



**Ilustración 4.** Porcentaje de ocupación de las clases de calidad vegetal con respecto al total de la superficie de la microcuenca.  
Fuente: El autor.

Concretamente, la superficie correspondiente a vegetación sana aumentó, al igual que la vegetación enferma. Estos resultados difieren parcialmente de los encontrados por Paula, Zambrano y Paula (2018), quienes analizaron el territorio de la Reserva de Producción de Fauna Chimborazo a través del NDVI, y hallaron que la superficie correspondiente a vegetación sana disminuyó de 12.06% en 1987 a 3.79% en 2015. La similitud entre resultados radica en el aumento de vegetación enferma que, según los autores, presentó un aumento de 18.4% en 1987 a 30.82% en 2015. Paula et al. (2018) atribuyen estos cambios a la expansión de la frontera agrícola, a malas prácticas agrícolas y al cambio climático.

En la ilustración 5 se muestra gráficamente la variación espacial de las clases de calidad vegetal analizadas. Como se aprecia, la vegetación enferma coincide con las periferias de la categoría Otros (Infraestructura y suelo desnudo) y el límite urbano de la ciudad de Azogues en los tres años analizados. La creciente urbanización en la parte baja de la microcuenca y la consecuente contaminación atmosférica puede explicar que esta zona presente los niveles más bajos de calidad vegetal. Por otra parte, la vegetación en estado promedio y vegetación sana se limita en su mayoría a la parte media y alta de la microcuenca, en donde la urbanización es ínfima en comparación a la agricultura, cuya presencia puede explicar los altos niveles de calidad vegetal. Mapas individuales de cada clasificación de calidad vegetal se pueden encontrar en el Anexo 1.



**Ilustración 5.** Mapa comparativo de la variación espacial y temporal de las clases de calidad de vegetación.

Fuente de la información cartográfica: IGM (2013)

Elaboración: El autor.

#### 4.1.2. NDWI

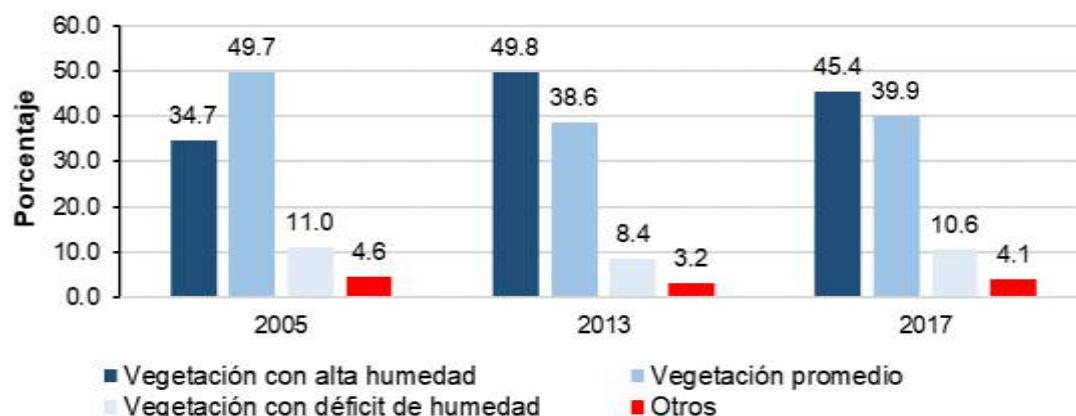
En la tabla 7 y la ilustración 6 es posible observar que la vegetación con contenido de humedad promedio fue predominante en el año 2005, con 3396.2 ha, equivalentes al 49.7% de la superficie total de la microcuenca. Esta cobertura disminuyó su ocupación a 2635.1 ha en 2013 y aumentó ligeramente a 2728.5 ha en 2017, correspondientes al 38.6 y 39.9% de la superficie total de la microcuenca, dando lugar a la vegetación con alto contenido de humedad como predominante desde 2013. Esta clase aumentó su

ocupación de 2371.7 ha en 2005 a 3402.8 ha en 2013, correspondientes al 34.7 y 49.8% respectivamente. Para 2017 esta cobertura disminuyó su ocupación, pasando a 3097.7 ha correspondientes al 45.4% de la superficie total de la microcuenca. La vegetación con déficit de humedad se mantuvo relativamente constante desde 2005 hasta 2017, con 751.8 y 725.5 ha respectivamente, teniendo el pico más bajo de ocupación en 2013, con 573.7 ha, correspondientes a 8.4% de la superficie total de la microcuenca.

**Tabla 7.** Evolución del contenido de humedad vegetal en superficie y porcentaje para 2005, 2013 y 2017.

Clases	2005		2013		2017	
	ha	%	ha	%	ha	%
Vegetación con alta humedad	2371.7	34.7	3402.8	49.8	3097.7	45.4
Vegetación promedio	3396.2	49.7	2635.1	38.6	2728.5	39.9
Vegetación con déficit de humedad	751.8	11.0	573.7	8.4	725.5	10.6
Otros	310.9	4.6	219.0	3.2	278.8	4.1
<b>Total</b>	<b>6830.6</b>	<b>100.0</b>	<b>6830.6</b>	<b>100.0</b>	<b>6830.6</b>	<b>100.0</b>

Fuente: El autor.

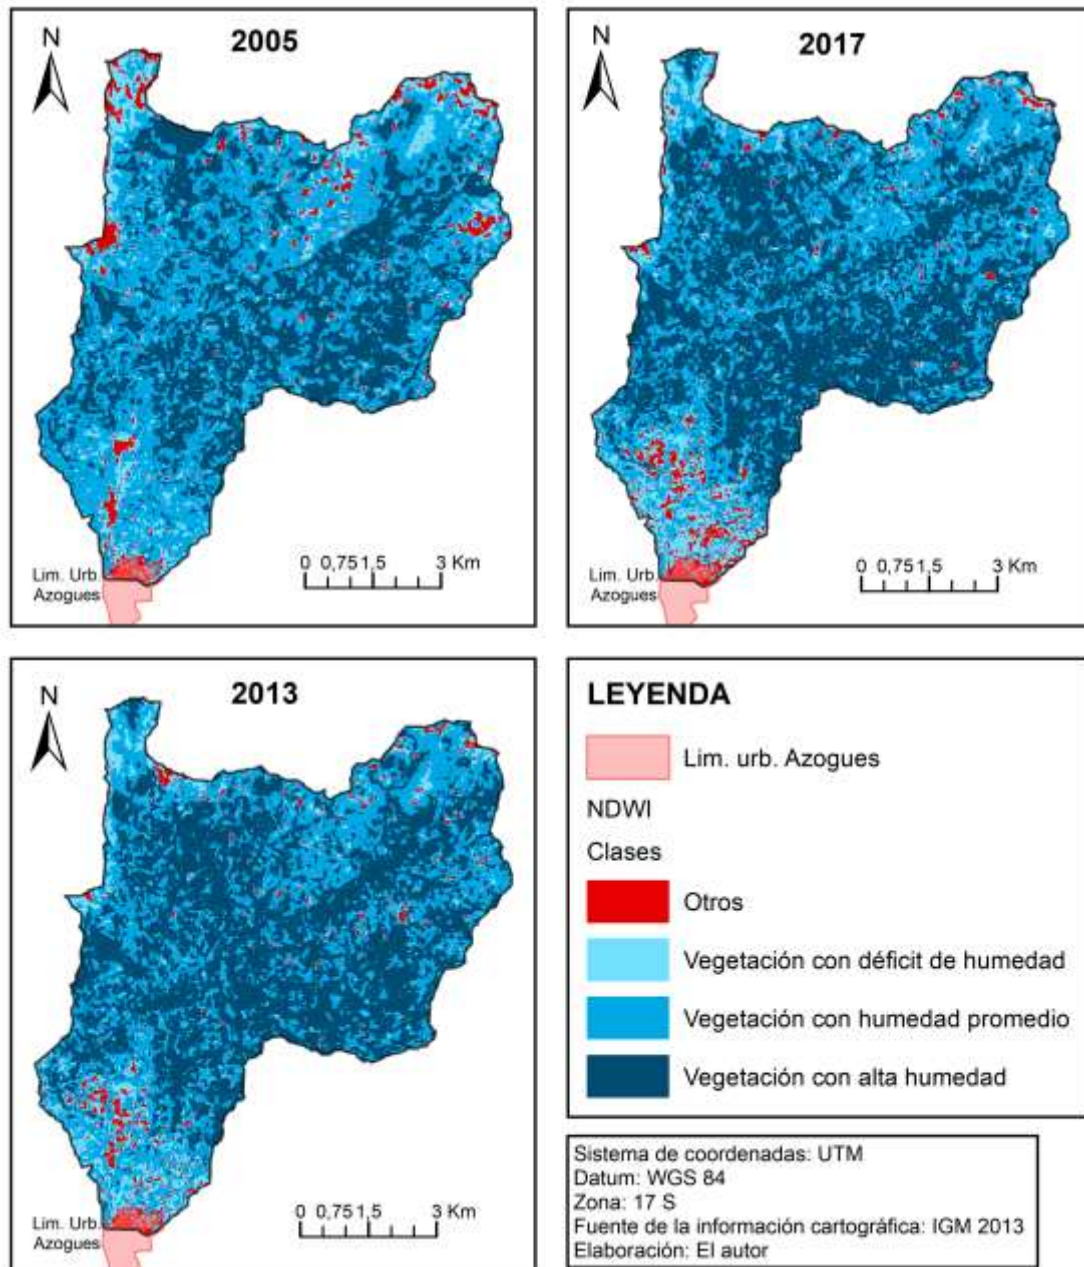


**Ilustración 6.** Porcentaje de ocupación de las clases de contenido de humedad vegetal con respecto al total de la superficie de la microcuenca.

Fuente: El autor.

En la ilustración 7 se muestra gráficamente la variación espacial de las clases de contenido de humedad vegetal analizadas. Al igual que con el NDVI, la vegetación con déficit de humedad coincide en ocupación con las periferias de la categoría Otros (Infraestructura y suelo desnudo en los tres años analizados, además de pequeñas áreas en la parte alta de la microcuenca en el año 2005, mientras que la ocupación de vegetación con contenido promedio y alto contenido de humedad corresponde a la parte media y el resto de la parte alta. Mapas individuales de cada clasificación de contenido de humedad vegetal se pueden encontrar en el Anexo 2.





**Ilustración 7.** Mapa comparativo de la variación espacial y temporal del contenido de humedad vegetal. Fuente de la información cartográfica: IGM (2013). Elaboración: El autor.

Si bien estos resultados denotan una mejoría en la calidad vegetal de la microcuenca, deben ser analizados con mayor detenimiento, puesto que los índices empleados no distinguen la cobertura vegetal que presenta un cierto grado de calidad. Es decir, una superficie con un valor elevado de NDVI puede corresponder tanto a un bosque nativo sano como a un cultivo. Así como un valor bajo de este mismo índice puede darse en una zona de vegetación arbustiva y poco densa pero no necesariamente enferma, como el páramo.

## 4.2. Clasificación supervisada

En la tabla 8 se compara la precisión global de los métodos de clasificación empleados, las matrices de confusión en detalle pueden encontrarse en el Anexo 3. La precisión global fue de 94.4, 95.1 y 99.4% y los coeficientes de kappa fueron de 0.92, 0.93 y 0.99 para 2005, 2013 y 2017 respectivamente. Como se puede apreciar, la precisión global para el método de máxima probabilidad supera el 90% en todos los casos, al igual que el coeficiente de Kappa, en el cual todos los valores son mayores a 0.9, a diferencia del método de redes neuronales que, para este caso de estudio, es claramente inferior, especialmente en la imagen del año 2005.

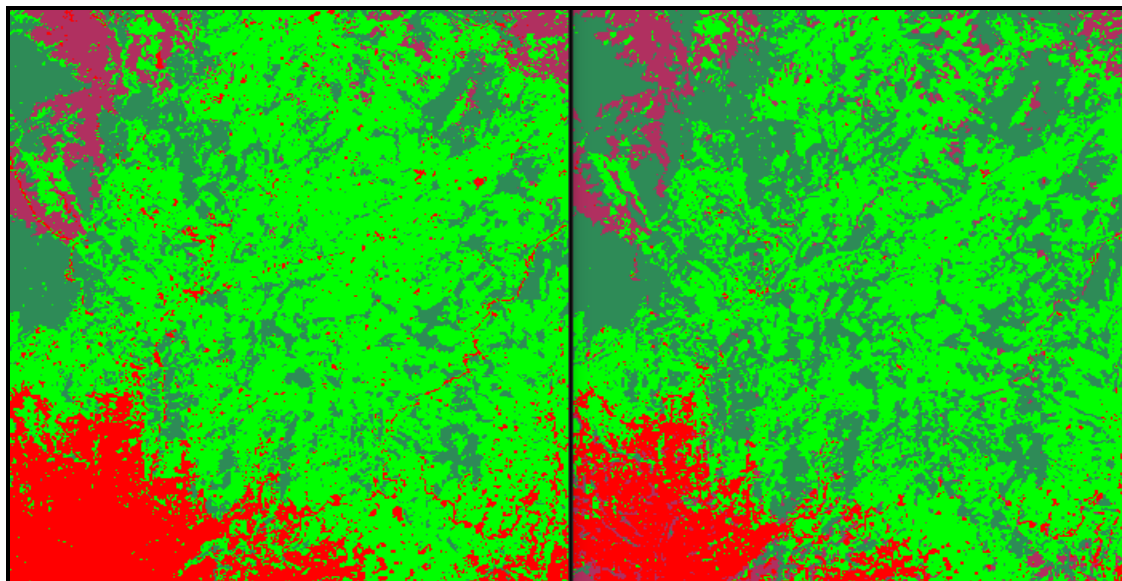
**Tabla 8.** Precisión global y coeficiente de Kappa por método de clasificación y año analizado.

Método	2005		2013		2017	
	Precisión global [%]	Kappa	Precisión global [%]	Kappa	Precisión global [%]	Kappa
Máxima probabilidad	94.4	0.92	95.1	0.93	99.4	0.99
Redes neuronales	75.5	0.66	90.4	0.86	96.6	0.95

Fuente: El autor.

Estos resultados son similares a los encontrados por Rosales (2017), cuyo análisis tuvo lugar en la cuenca del río Tahuando, provincia de Imbabura, Ecuador, quien obtuvo una precisión de 96% y un coeficiente Kappa de 0.93. También se asemejan a los encontrados por Damián (2017), cuyo análisis se dio en la microcuenca del río Jubal, provincia de Chimborazo, Ecuador, quien obtuvo una precisión global entre 84 y 90% y coeficientes kappa de 0.81 y 0.87 para la clasificación de sus imágenes mediante el método de máxima probabilidad. Este último autor sugiere que la alta precisión por este método se debe a que el algoritmo sólo se basa en la información espectral de los píxeles y no toma en cuenta formas. Obtener un coeficiente de Kappa con un valor mayor a 0.8 es indicador de una correcta correspondencia entre los usos de suelo asignados (Zhu, Liu, Chen, Zhang, & Verburg, 2010).

A manera de ejemplo, en la ilustración 8 se compara visualmente el resultado de la clasificación por ambos métodos para la imagen satelital del año 2017. A simple vista, el resultado obtenido por el método de máxima probabilidad es más preciso, con un mejor reconocimiento de la similitud en patrones de reflectancia en áreas de características similares. Por el contrario, el método de redes neuronales confunde numerosas áreas pertenecientes a las clases agropecuario y forestal con la clase de páramo. Estos resultados visuales son similares para las imágenes de los años 2005 y 2013.



**Ilustración 8.** Comparación gráfica entre el resultado de la clasificación supervisada por el método de máxima probabilidad (izquierda) y redes neuronales (derecha) para la imagen satelital del año 2017. Representación de los colores: rojo: uso de suelo urbano; verde claro: uso de suelo agropecuario; verde oscuro: uso de suelo forestal; marrón: uso de suelo de páramo.

Fuente: El autor.

### 4.3. Análisis multitemporal y estadístico

#### 4.3.1. Evolución del uso del suelo y TCA

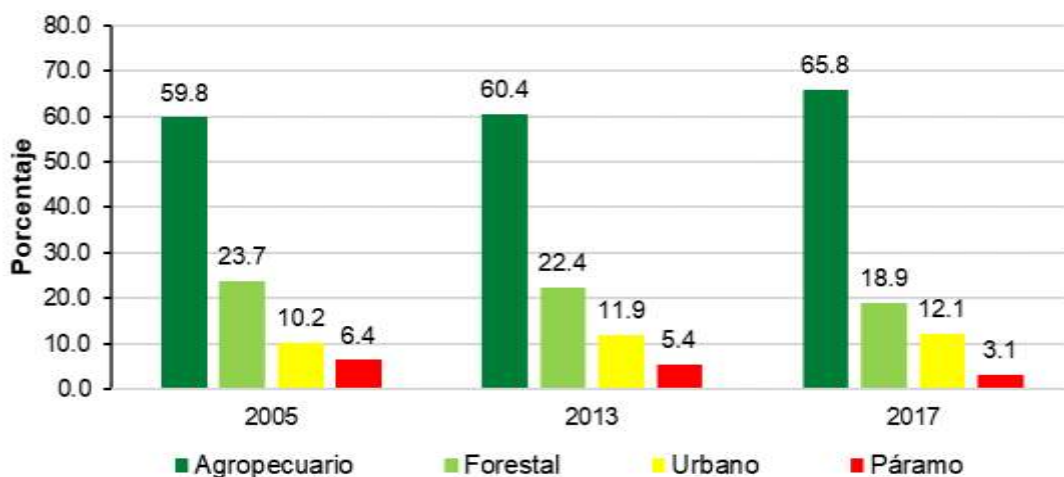
En la tabla 9 y la ilustración 9 se detallan las superficies correspondientes a cada clase de uso del suelo, además del porcentaje que estas representan con respecto al área total para cada año analizado. El uso de suelo agropecuario fue predominante en la microcuenca durante todo el periodo de análisis, aumentando su ocupación de 4028 ha en 2005 a 4123.7 en 2013, y luego a 4497.5 ha en 2017, con una TCA de 0.8 ha/año. Cabe destacar que el uso agropecuario aumentó drásticamente su ocupación en el periodo 2013-2017 (415.3 ha), en comparación a las 41.5 ha que aumentó en los ocho años anteriores a ese periodo. El uso forestal se redujo de 1617.3 ha en 2005 a 1527 ha en 2013 y a 1291.7 ha en 2017, presentando una TCA de -1.9 ha/año. Al igual que con el uso agropecuario, el uso forestal disminuyó drásticamente su ocupación en el periodo 2013-2017 (235.6 ha), en comparación al periodo 2005-2013 (90 ha). El uso urbano aumentó su ocupación durante el periodo de análisis, pasando de 693.5 ha en 2005 a 828.3 ha en 2017, con una TCA de 1.5 ha/año. Por último, el uso de páramo presentó una disminución considerable de su ocupación, pasando de 437.7 ha en 2005 a 213.1 ha en 2017, teniendo así una TCA de -6.0 ha/año, la más alta en este estudio. Este uso del suelo ha presentado el cambio más drástico dentro del territorio de la microcuenca, llegando a perder el 54% de su superficie inicial en 12 años.



**Tabla 9.** Evolución de las clases de uso del suelo en superficie y porcentaje para 2005, 2013 y 2017.

Clases	2005		2013		2017		TCA [ha/año]
	ha	%	ha	%	ha	%	
Agropecuario	4082.2	59.8	4123.7	60.4	4497.5	65.8	0.8
Forestal	1617.3	23.7	1527.3	22.4	1291.7	18.9	-1.9
Urbano	693.5	10.2	813.9	11.9	828.3	12.1	1.5
Páramo	437.7	6.4	365.7	5.4	213.1	3.1	-6.0
<b>Total</b>	<b>6830.6</b>	<b>100.0</b>	<b>6830.6</b>	<b>100.0</b>	<b>6830.6</b>	<b>100.0</b>	

Fuente: El autor.

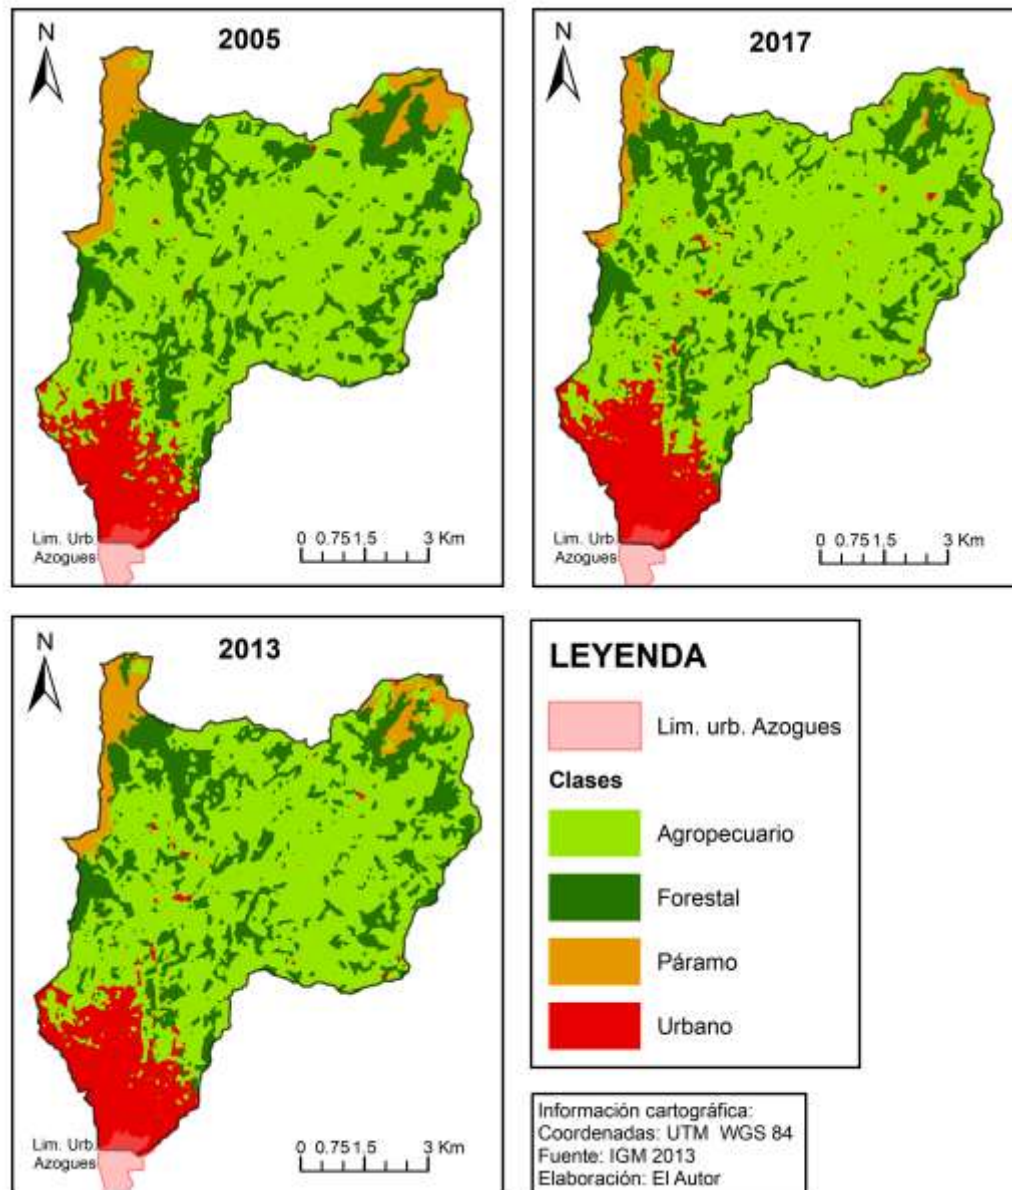

**Ilustración 9.** Porcentaje representativo de cada clase de uso del suelo.

Fuente: El autor.

Estos resultados son similares a los que obtuvo Damián (2017), quien determinó que, en su área de estudio, en dos décadas de análisis (1991-2011) las coberturas de páramo, bosque, humedal y pastizal disminuyeron en 174.4, 37.7, 453.1 y 271.3 ha respectivamente. En concreto, 14% del bosque, 9% de los humedales y 39% del pastizal iniciales fueron transformados a cultivos. Rosales (2017) también obtuvo resultados similares, demostrando que la cobertura vegetal de su área de estudio presentó una disminución de 375.92 ha en 26 años, mientras que las actividades agrícolas (cultivos y ganadería) aumentaron 560.07 ha en el mismo periodo. Ambos estudios, al igual que la presente investigación, concuerdan que la expansión de la frontera agrícola es la causa principal de la pérdida de vegetación nativa.

La ilustración 10 representa gráficamente la variación espacio-temporal de las clases de uso del suelo analizadas. Como se muestra, la fragmentación de las coberturas boscosas aumentó considerablemente, sobre todo en la parte media y alta de la microcuenca, en donde también se evidencia la aparición de pequeñas superficies correspondientes al uso del suelo urbano. La pérdida de superficie correspondiente a páramo (Tabla 9) es la característica más preocupante del análisis; se puede apreciar que las áreas perdidas de páramo son ocupadas, en su mayoría por agricultura.

Mapas individuales de cada clasificación de uso del suelo por año analizado se pueden encontrar en el Anexo 4.



**Ilustración 10.** Mapa comparativo de la variación espacial y temporal de las clases de uso del suelo.  
Fuente de la información cartográfica: IGM (2013).  
Elaboración: El autor.

El estudio realizado por Muñoz, Andrade y Gonzáles (2016) en la Reserva Ecológica “Mache-Chindul” (provincias de Esmeraldas y Manabí) determinaron que el bosque natural disminuyó de 48 046 a 38 342 ha desde 2002 hasta 2012, pasando de 40.04% a 31.95% de la superficie total de la reserva. En este mismo periodo se determinó que las categorías agrícolas de pastos y cultivos presentaron un incremento de 9 550 a 43 635 ha, es decir, de 7.96 a 36.36% de la superficie total de la reserva. Este estudio reveló un alto grado de fragmentación del bosque nativo. Muñoz et al. (2016) atribuyen la pérdida de cobertura boscosa en la reserva a la expansión de la frontera agrícola y



a la extracción ilegal de madera. La fragmentación de las coberturas vegetales en la microcuenca del Tabacay no alcanza los niveles presentes en la reserva, a pesar que sus causas también son atribuidas a la expansión agrícola, no obstante, dada la evolución de las superficies boscosas determinadas en este estudio, no se descarta la posibilidad de que eventualmente esto ocurra. Este problema debe ser considerado antes que sus consecuencias sean irreversibles. La fragmentación de una superficie boscosa puede tener serias implicaciones en la supervivencia de las poblaciones silvestres dentro de los bosques, ya que recursos vitales para muchas especies, especialmente mamíferos grandes, pueden extinguirse o quedar aislados en fragmentos de bosque inaccesibles (Myers, Mittermeier, Mittermeier, da Fonseca, & Kent, 2000; Salgado, Betancourt, & Cuesta, 2007). También es preocupante desde el punto de vista de Murray et al. (2018), quien explica que ecosistemas con una extensión geográfica pequeña están en mayor riesgo de colapsar por catástrofes ambientales (como el inminente cambio climático) que aquellos distribuidos sobre extensiones mayores.

#### **4.3.2. Matriz de transición**

La tabla 10 muestra las áreas de transición entre las clases de uso del suelo analizadas. En concreto, de las 4082.2 ha de uso agropecuario que había en 2005, 197,4 ha pasaron a forestal, 143,6 ha a urbano y 2,7 ha a páramo. Así mismo, de las 437.7 ha de páramo que había en 2005, 166,2 ha cambiaron a uso agropecuario y 67,7 ha a forestal. De igual forma, de las 1617,3 ha de uso forestal que había en 2005, 564,2 ha cambiaron a uso agropecuario, 20,2 ha a urbano y 6,7 ha a páramo. El uso urbano perdió 29 ha de las cuales 28.6 ha pasaron a uso agropecuario y 0,4 a forestal. No existió transición entre los usos de suelo urbano y páramo.

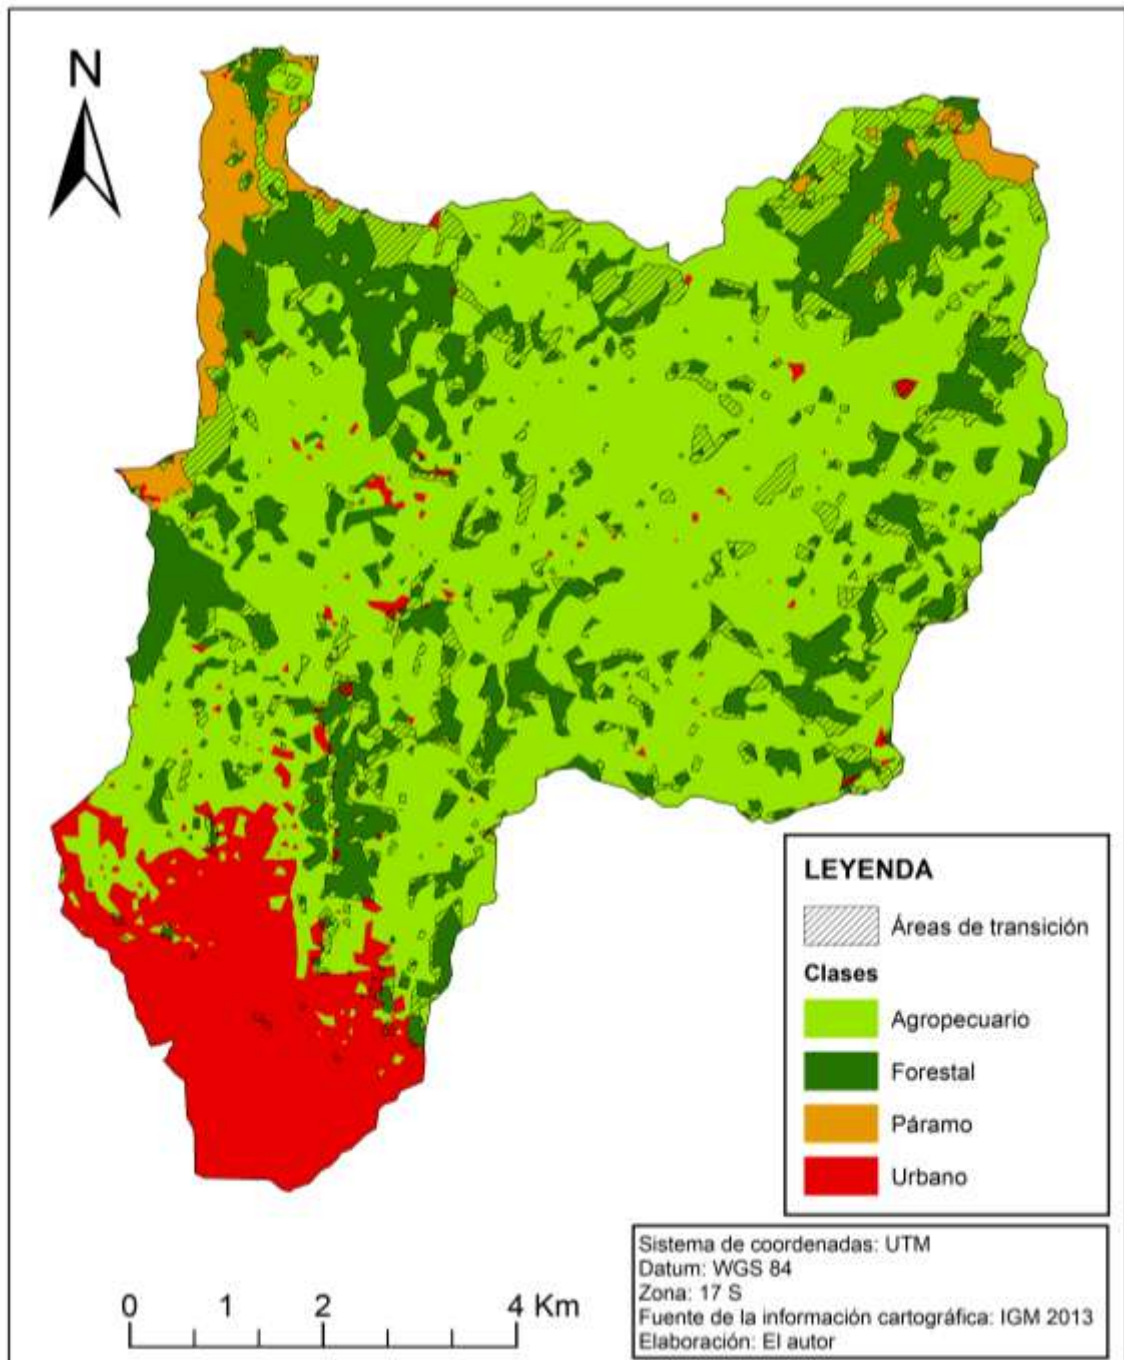
El uso de suelo con mayor pérdida de superficie fue el forestal, con 591.1 ha, mientras que el uso agropecuario fue el que presentó mayor ganancia de superficie, específicamente 759 ha. Por otra parte, el uso de suelo urbano fue aquel que menos superficie perdió, (29 ha), mientras que el páramo fue aquel que menos superficie ganó, (9.3 ha).

**Tabla 10.** Matriz de transición de clases de uso del suelo para el periodo de estudio (2005-2017).

		2017				Total 2005	Pérdida
		Agropecuario	Forestal	Urbano	Páramo		
2005	Agropecuario	3738.5	197.4	143.6	2.6	<b>4082.2</b>	343.6
	Forestal	564.2	1026.1	20.2	6.7	<b>1617.3</b>	591.1
	Urbano	28.6	0.4	664.5	0.0	<b>693.5</b>	29.0
	Páramo	166.2	67.7	0.0	203.8	<b>437.7</b>	233.8
Total 2017		<b>4497.5</b>	<b>1291.7</b>	<b>828.3</b>	<b>213.1</b>	<b>6830.6</b>	
Ganancia		759.0	265.5	163.8	9.3		

Fuente: El autor.

En la ilustración 11 se muestran las áreas de transición entre el uso de bosque y páramo con el uso agropecuario. En concreto, las áreas de transición representan la superficie que en 2005 correspondían a las categorías forestal y de páramo, y que en 2017 sirven como uso agropecuario y urbano.



**Ilustración 11.** Áreas de pérdida de uso forestal y de páramo frente a la expansión de uso agropecuario y urbano durante el periodo de estudio.  
Fuente de la información cartográfica: IGM (2013).  
Elaboración: El autor.

Como se puede apreciar, la fragmentación en las manchas de bosque y vegetación nativa aumentó considerablemente; en concreto, 591.1 ha de uso forestal se perdieron en 12 años, correspondientes al 36.5% de la superficie existente en 2005. El retroceso del páramo también es evidente, con 233.8 ha de superficie perdida en el mismo periodo antes mencionado, correspondiente al 53.4% de la superficie de páramo existente en 2005. Aquí se evidencia gráficamente que las partes media y alta de la



microcuenca, y en especial el páramo, son las zonas más afectadas por la expansión de la frontera agrícola.

El estudio realizado por Salgado, Betancourt y Cuesta (2007) en la cuenca alta del río Mazar determinó que la cobertura vegetal nativa presenta una remanencia del 71%; el 29% de la superficie restante se dividió entre frentes de colonización, pastizales, cultivos y áreas urbanas. El paisaje de la cuenca alta del Mazar mostró mayor integridad en las zonas de páramo. Este resultado es diferente al del presente estudio, en el cual el páramo es el uso del suelo más afectado. Esto puede deberse a la facilidad de acceso a estas zonas por la fragmentación del bosque nativo y las características topográficas, a diferencia de la cuenca alta del río Mazar, en donde el páramo se encuentra resguardado por amplias y espesas franjas de bosque de neblina montano y bosque siempre-verde montano alto (Salgado et al., 2007).

#### 4.3.3. Correlación

Como se muestra en la tabla 11, El uso agropecuario presenta correlación negativa fuerte frente al uso forestal ( $r = -0.984$ ) y al páramo ( $r = -0.974$ ). El uso urbano también presenta correlación negativa frente al uso forestal ( $-0,778$ ). Ya que no existió variación espacial entre las clases urbano y páramo (Tabla 10), estas categorías no fueron correlacionadas. Los resultados del coeficiente de correlación de Pearson comprueban lo obtenido en la matriz de transición antes calculada (Tabla 10), comprobando que el aumento de superficie de los usos de suelo agropecuario y urbano están relacionados directa y negativamente con la pérdida de superficie de los usos forestal y de páramo. Además, el coeficiente de determinación (calculado a partir del coeficiente de Pearson) reveló que la pérdida de bosques y páramo puede deberse hasta en un 97% al aumento de superficie del uso de suelo agropecuario. Al igual que la pérdida de bosques puede ser hasta en un 60% causa de la expansión urbana.

**Tabla 11.** Coeficiente de correlación de Pearson y coeficiente de determinación entre pares de clases.

Relación entre clases	Pearson	Determinación [%]
Agropecuario vs Forestal	-0.984	96.8
Agropecuario vs Páramo	-0.974	94.9
Urbano vs Forestal	-0.778	60.5
Urbano vs Páramo	--	--

Fuente: El autor.

---

## CAPÍTULO IV

### 5. CONCLUSIONES

La utilización integrada de los sistemas de información geográfica y la percepción remota permitió determinar satisfactoriamente los cambios ocurridos con respecto a la calidad vegetal y el uso del suelo en la microcuenca del río Tabacay.

Dos factores muy importantes en este tipo de estudio son la disponibilidad de imágenes satelitales aptas y la resolución espacial de las mismas. En este caso, la mediana resolución de las imágenes Landsat y el nivel de detalle que esto representa forzó la utilización de clases de uso del suelo poco específicas, que a su vez limitó profundizar en los detalles de la dinámica del uso del suelo dentro de la microcuenca.

Evaluar y comparar la eficiencia de dos métodos de clasificación supervisada ampliamente utilizados brinda confiabilidad adicional a los resultados. El método de clasificación supervisada por máxima probabilidad brindó mejores resultados frente al método por redes neuronales para la microcuenca estudiada.

El uso de suelo más afectado por la dinámica del paisaje en la microcuenca fue el páramo, con una tasa de cambio anual de -6 ha/año. La disminución del páramo es tan evidente, tanto visual como matemáticamente que, en 12 años de análisis, este ecosistema perdió el 54% de su superficie inicial, pasando de 437.7 ha en 2005 a 213.1 ha en 2017.

Tanto la correlación como la matriz de transición elaboradas revelan que las actividades antropogénicas, reflejadas en la expansión de la frontera agrícola y la urbanización son la causa de la pérdida y fragmentación de bosques, vegetación nativa y páramo dentro de la microcuenca. La expansión de la frontera agrícola es un problema creciente que debe ser controlado para garantizar la conservación de los ecosistemas naturales en este territorio, que brindan numerosos servicios ambientales como regulación hídrica, conservación de biodiversidad, conservación del suelo, entre otros.

Los resultados de este estudio son de utilidad para el manejo de la microcuenca del río Tabacay, y la metodología empleada puede aplicarse a cualquier territorio con características similares. Su utilidad radica en la identificación de áreas críticas de pérdida y fragmentación de bosques, vegetación nativa y páramo, así como zonas de incremento de actividades agrícolas y urbanización.



## 6. RECOMENDACIONES

Para obtener un mayor nivel de detalle tanto en las formas de los polígonos representativos como de las clases de uso del suelo, es preciso contar con imágenes multiespectrales de alta resolución. No obstante, el alcance del estudio puede verse limitado seriamente por el factor económico que esto representa.

En esta investigación se evaluó la eficiencia de dos métodos de clasificación supervisada. Máxima probabilidad y redes neuronales son dos métodos ampliamente utilizados por la eficiencia que ofrecen, pero no son los únicos existentes. Con base en los resultados de este estudio, para obtener resultados precisos en la microcuenca del río Tabacay se recomienda emplear el método de máxima probabilidad. No obstante, para asegurar la calidad de los resultados de futuras investigaciones se recomienda evaluar la eficiencia de por lo menos cinco de los métodos existentes más empleados.



## 7. REFERENCIAS

- Abualhin, K. (2016). Mapping of Underwater Seabed Morphology of the Gaza Strip Coastal Zone Using Remote Sensing Technique. *Earth Sciences Research Journal*, 20(2), C1–C7. <https://doi.org/10.15446/esrj.v20n2.50256>
- Bolstad, P. (2012). *GIS Fundamentals* (4a ed.). Acton: XanEdu.
- Chander, G., Markham, B. L., & Helder, D. (2009). Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. *Remote Sensing of Environment*, 113(5), 893–903. <https://doi.org/10.1016/j.rse.2009.01.007>
- Chavez, P. (1988). An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. *Remote Sensing of Environment*, 24(3), 459–479. [https://doi.org/10.1016/0034-4257\(88\)90019-3](https://doi.org/10.1016/0034-4257(88)90019-3)
- Chavez, P. (1996). Image-based atmospheric corrections. Revisited and improved. *Photogrammetric Engineering and Remote Sensing*, 62(9), 1025–1036.
- Chen, X.-L., Zhao, H.-M., Li, P.-X., & Yin, Z.-Y. (2006). Remote sensing image-based analysis of the relationship between urban heat island and land use/cover changes. *Remote Sensing of Environment*, 104, 133–146. <https://doi.org/10.1016/j.rse.2005.11.016>
- Chuvieco, E. (1995). *Fundamentos de teledetección* (2a ed.). Madrid: Ediciones Rialp, S.A.
- Chuvieco, E. (2008). *Teledetección ambiental* (3a ed.). Barcelona: Ariel.
- Civco, D. (1989). Topographic normalization of Landsat Thematic Mapper Digital imagery. *Photogrammetric Engineering and Remote Sensing*, 55(9), 1303–1309.
- Córdova, J., & García, N. (2013). Caracterización de islas frescas urbanas (IFU) en la ciudad de Santiago de Cali, Colombia. *Entorno Geográfico*, 9, 122–144.



- Czapla-Myers, J., McCorkel, J., Anderson, N., Thome, K., Biggar, S., Helder, D., ... Mishra, N. (2015). The ground-based absolute radiometric calibration of Landsat 8 OLI. *Remote Sensing*, 7(1), 600–626. <https://doi.org/10.3390/rs70100600>
- Damián, D. (2017). *Análisis de la dinámica de los cambios de uso del suelo mediante teledetección en una microcuenca altoandina de Ecuador* (Tesis de postgrado). Universidad de Valladolid, Palencia, España. Recuperado de <http://uvadoc.uva.es/handle/10324/26386>
- EMAPAL EP, COPOE, & PROMAS. (2005). Plan de manejo de la microcuenca del río Tabacay.
- Füreder, P. (2010). Topographic correction of satellite images for improved LULC classification in alpine areas. *Grazer Schriften der Geographie und Raumforschung*, 45, 187–194.
- GAD provincial de Cañar. (2015). Plan de desarrollo y ordenamiento territorial de la provincia de Cañar.
- Gao, B.-H. (1996). NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58(3), 257–266. [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)
- Gomasasca, M. (2004). *Basics of Geomatics* (1a ed.). Italia: Springer.
- Goward, S., Masek, J., Williams, D., Irons, J., & Thompson, R. J. (2001). The Landsat 7 mission: Terrestrial research and applications for the 21st century. *Remote Sensing of Environment*, 78(1–2), 3–12. [https://doi.org/10.1016/S0034-4257\(01\)00262-0](https://doi.org/10.1016/S0034-4257(01)00262-0)
- Hantson, S., & Chuvieco, E. (2011). Evaluation of different topographic correction methods for Landsat imagery. *International Journal of Applied Earth Observation and Geoinformation*, 13, 691–700. <http://dx.doi.org/10.1016/j.jag.2011.05.001>



- Hantson, S., Chuvieco, E., Pons, X., Domingo, C., Cea, C., Moré, G., ... Tejeiro, J. (2011). Cadena de pre-procesamiento estándar para las imágenes Landsat del Plan Nacional de Teledetección. *Revista de Teledetección*, 36, 51–61.
- Holben, B. (1986). Characteristics of maximum-value composite images from temporal AVHRR data. *International Journal of Remote Sensing*, 7(11), 1417–1434. <http://dx.doi.org/10.1080/01431168608948945>
- IGM - Instituto Geográfico Militar. (2013). Información Geográfica. Recuperado el 15 de marzo de 2018, de <http://www.geoportaligm.gob.ec/portal/index.php/descargas/cartografia-de-libre-acceso/>
- Irons, J., Dwyer, J., & Barsi, J. (2012). The next Landsat satellite: The Landsat Data Continuity Mission. *Remote Sensing of Environment*, 122, 11–21. <https://doi.org/10.1016/j.rse.2011.08.026>
- Jordan, C. (1969). Derivation of Leaf-Area index from quality of light on the forest floor. *Ecology*, 50(4), 663–666. <http://dx.doi.org/10.2307/1936256>
- Ke, Y., Im, J., Lee, J., Gong, H., & Ryu, Y. (2015). Characteristics of Landsat 8 OLI-derived NDVI by comparison with multiple satellite sensors and in-situ observations. *Remote Sensing of Environment*, 164, 298–313. <https://doi.org/10.1016/j.rse.2015.04.004>
- Leutner, B. (2016, enero 26). Landsat 8 Esun Values. Recuperado de <http://bleutner.github.io/RStoolbox/r/2016/01/26/estimating-landsat-8-esun-values>
- Lillesand, T., Kiefer, R. W., & Chipman, J. (2014). *Remote Sensing and Image Interpretation* (7a ed.). John Wiley & Sons. Recuperado de [https://books.google.es/books?hl=es&lr=&id=AFHDCAAQAQBAJ&oi=fnd&pg=PA1&dq=remote+sensing&ots=0CpPf2iAaw&sig=Y93L8cW9dAjkrzcOP\\_OTLXqpWYl#v=onepage&q&f=false](https://books.google.es/books?hl=es&lr=&id=AFHDCAAQAQBAJ&oi=fnd&pg=PA1&dq=remote+sensing&ots=0CpPf2iAaw&sig=Y93L8cW9dAjkrzcOP_OTLXqpWYl#v=onepage&q&f=false)



- Lu, D., Mausel, P., Brondizio, E., & Moran, E. (2010). Assessment of atmospheric correction methods for Landsat TM data applicable to Amazon basin LBA research. *International Journal of Remote Sensing*, 32(13), 2651–2671. <https://doi.org/10.1080/01431160110109642>
- Malarvizhi, K., Vasantha, S., & Porchelvan, P. (2016). Use of high resolution Google Earth satellite imagery in landuse map preparation for urban related applications. *Procedia Technology*, 24, 1835–1842. <https://doi.org/10.1016/j.protcy.2016.05.231>
- Markham, B. L., & Barker, J. L. (1986). Thematic Mapper bandpass solar exoatmospheric irradiances. *International Journal of Remote Sensing*, 8(3), 517–523. <https://doi.org/10.1080/01431168708948658>
- Mas, J. F., Velázquez, A., & Couturier, S. (2009). La evaluación de los cambios de cobertura/uso del suelo en la República Mexicana. *Investigación ambiental Ciencia y política pública*, 1(1), 23–39.
- Mendoza, F. (2010, marzo). Análisis multitemporal del cambio de uso de suelo en base a imágenes satelitales de los territorios indígenas de Mayangna Sauni As, Mayangna Sauni Bas, Sikilta, MatungBak/Sauni Arungka, SIPBAA, Layasilksa y el área afectada por el huracán Félix en 2007 para el periodo de tiempo 2005-2007/08 en los departamentos de Jinotega y la RAAN, Nicaragua. Terra Systems. Recuperado de <https://es.calameo.com/books/0005050546a5c03432492>
- Meyer, P., Itten, K., Kellenberger, T., Sandmeier, S., & Sandmeier, R. (1993). Radiometric corrections of topographically induced effects on Landsat TM data in an alpine environment. *ISPRS Journal of Photogrammetry and Remote Sensing*, 48(4), 17–28. [http://dx.doi.org/10.1016/0924-2716\(93\)90028-L](http://dx.doi.org/10.1016/0924-2716(93)90028-L)
- Muñoz, J. L., Andrade, M., & Gonzáles, B. (2016). Cambio multitemporal de la cobertura vegetal y fragmentación en la reserva ecológica “Mache-Chindul”



- 
- Ecuador. *European Scientific Journal*, 12(30), 152–165.  
<http://dx.doi.org/10.19044/esj.2016.v12n30p152>
- Murray, N., Keith, D., Bland, L., Ferrari, R., Lyons, M., Lucas, R., ... Nicholson, E. (2018). The role of satellite remote sensing in structured ecosystem risk assessments. *Science of The Total Environment*, 619–620, 249–257.  
<https://doi.org/10.1016/j.scitotenv.2017.11.034>
- Myers, N., Mittermeier, R. A., Mittermeier, C. G., da Fonseca, G. A. B., & Kent, J. (2000). Biodiversity hotspots for conservation priorities. *Nature*, 403, 853–858.  
<https://doi.org/10.1038/35002501>
- Paula, P. A., Zambrano, L., & Paula, P. (2018). Análisis Multitemporal de los cambios de la vegetación, en la Reserva de Producción de Fauna Chimborazo como consecuencia del cambio climático. *Enfoque UTE*, 9(2), 125–137.  
<http://dx.doi.org/10.29019/enfoqueute.v9n2.252>
- Pettorelli, N., Ryan, S., Mueller, T., Bunnefeld, N., Bogumilla, J., Lima, M., & Kausrud, K. (2011). The Normalized Difference Vegetation Index (NDVI): unforeseen successes in animal ecology. *Climate Research*, 46(1), 15–27.  
<http://dx.doi.org/10.3354/cr00936>
- Pontius, R. G., Shusas, E., & McEachern, M. (2004). Detecting important categorical land changes while accounting for persistence. *Agriculture, Ecosystems & Environment*, 101(2–3), 251–268. <https://doi.org/10.1016/j.agee.2003.09.008>
- Puyravaud, J. P. (2003). Standardizing the calculation of the annual rate of deforestation. *Forest Ecology and Management*, 177(1–3), 593–596.  
[https://doi.org/10.1016/S0378-1127\(02\)00335-3](https://doi.org/10.1016/S0378-1127(02)00335-3)
- Riano, D., Chuvieco, E., Salas, J., & Aguado, I. (2003). Assessment of different topographic corrections in Landsat-TM data for mapping vegetation types (2003). *IEEE Transactions on Geoscience and Remote Sensing*, 41(5), 1056–1061. <https://doi.org/10.1109/TGRS.2003.811693>
-



- Rosales, O. A. (2017). *Análisis multitemporal del uso del suelo y cobertura vegetal de la cuenca del río Tahuando y proyección de cambios al año 2031, en el cantón Ibarra, provincia de Imbabura* (Tesis de postgrado). Universidad Técnica del Norte, Ibarra. Recuperado de <http://repositorio.utn.edu.ec/handle/123456789/7745>
- Sahle, K., Marohn, C., & Cadisch, G. (2015). Assessment of land use and land cover change in South Central Ethiopia during four decades based on integrated analysis of multi-temporal images and geospatial vector data. *Remote Sensing Applications: Society and Environment*. <http://dx.doi.org/10.1016/j.rsase.2015.11.005>
- Salgado, S., Betancourt, F., & Cuesta, F. (2007). Caracterización de la cobertura vegetal y uso del suelo en la cuenca alta del río Mazar, provincia Cañar, Ecuador. *EcoCiencia*, 1–44.
- Sancha, E. (2010). El estudio de los índices de vegetación como base para conocer las relaciones entre la vegetación y el clima. *Tecnologías de la Información Geográfica: La Información Geográfica al servicio de los ciudadanos.*, 1095–1108.
- Servicio Geológico de los Estados Unidos. (2012, julio). Landsat Data Continuity Mission. Servicio Geológico de los Estados Unidos. Recuperado de <https://pubs.usgs.gov/fs/2012/3066/fs2012-3066.pdf>
- Servicio Geológico de los Estados Unidos. (2018a, febrero 22). Gap-Filling Landsat 7 SLC-off Single Scenes Using ERDAS Imagine 2014™. Recuperado de <https://landsat.usgs.gov/gap-filling-landsat-7-slc-single-scenes-using-erdas-imagine-TM>
- Servicio Geológico de los Estados Unidos. (2018b, febrero 22). Where can I find the solar exoatmospheric spectral irradiances (ESUN) for the Landsat 1-5 MSS, Landsat 4-5 TM, and Landsat 7 ETM+ sensors? Recuperado de <https://landsat.usgs.gov/esun>



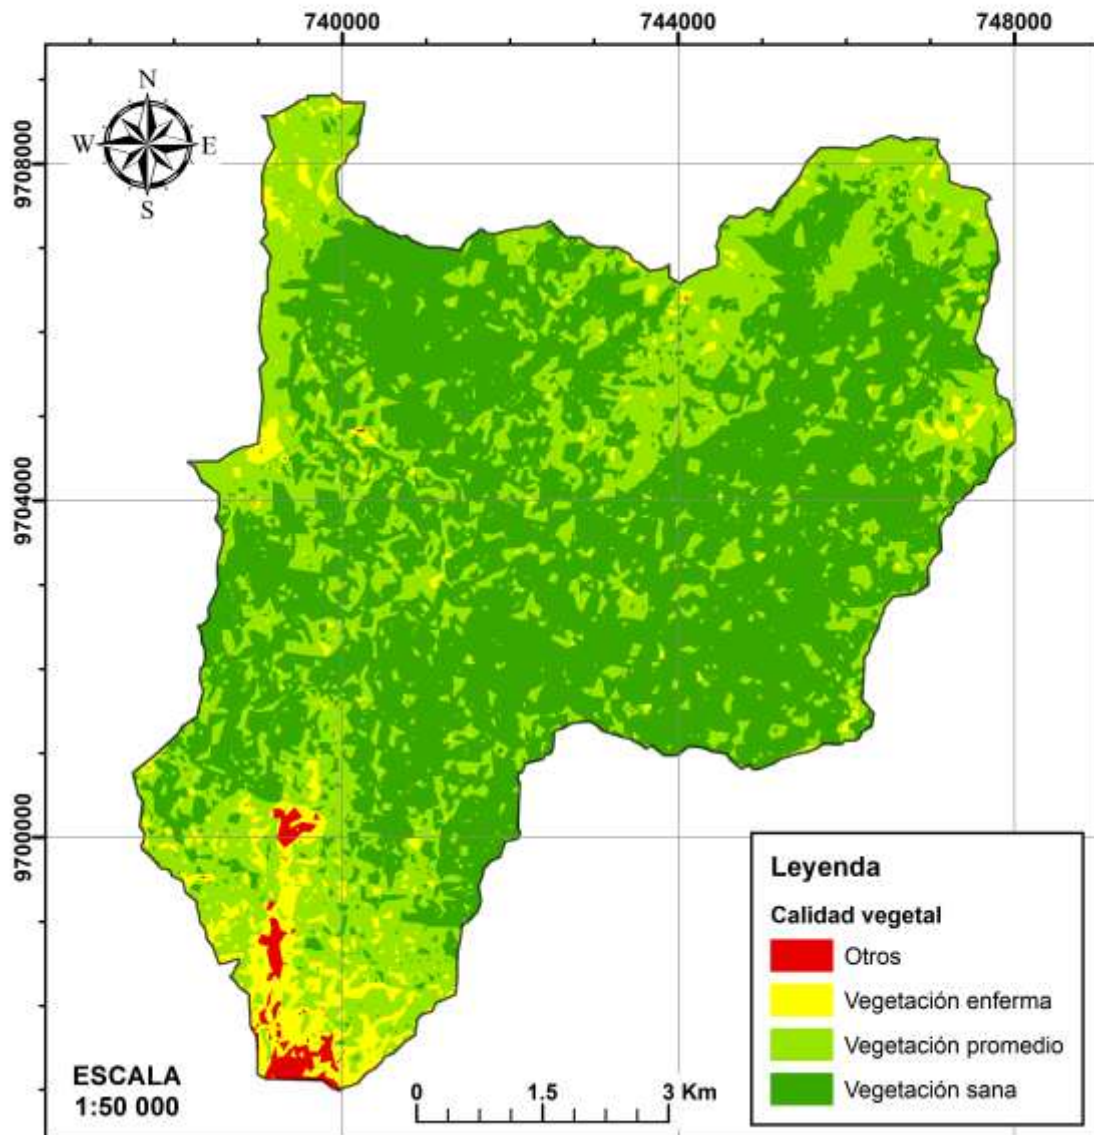
- Servicio Geológico de los Estados Unidos. (2018c, marzo 15). Earth Explorer. Recuperado de <https://earthexplorer.usgs.gov/>
- Tanré, D., Deroo, C., Herman, M., Duhaut, P., Morcrette, J. J., Perbos, J., & Deschamps, P. Y. (1990). Technical note Description of a computer code to simulate the satellite signal in the solar spectrum: the 5S code. *International Journal of Remote Sensing*, 11(4), 659–668. <https://doi.org/10.1080/01431169008955048>
- Teillet, P. M., Guindon, B., & Goodenough, D. (1982). On the Slope-Aspect Correction of Multispectral Scanner Data. *Canadian Journal of Remote Sensing*, 8(2), 84–106. <http://dx.doi.org/10.1080/07038992.1982.10855028>
- Twele, A., & Erasmi, S. (2005). Evaluating topographic correction algorithms for improved land cover discrimination in mountainous areas of Central Sulawesi. *Remote Sensing & GIS for Environmental Studies*, 113, 287–295.
- Viedma, O., & Chuvieco, E. (1993). Cartografía y evaluación de daños causados por incendios forestales mediante técnicas de teledetección. El ejemplo de la hoya de Buñol, Valencia. *Boletín de información técnica - AITIM*, (167), 60–66.
- Young, H., & Freedman, R. (2009). *Física universitaria, con física moderna* (12a ed., Vol. 2). México: Pearson Educación.
- Zhu, Z., Liu, L., Chen, Z., Zhang, J., & Verburg, P. H. (2010). Land-use change simulation and assessment of driving factors in the loess hilly region—a case study as Pengyang County. *Environmental Monitoring and Assessment*, 164(1–4), 133–142. <https://doi.org/10.1007/s10661-009-0880-2>



## 8. ANEXOS

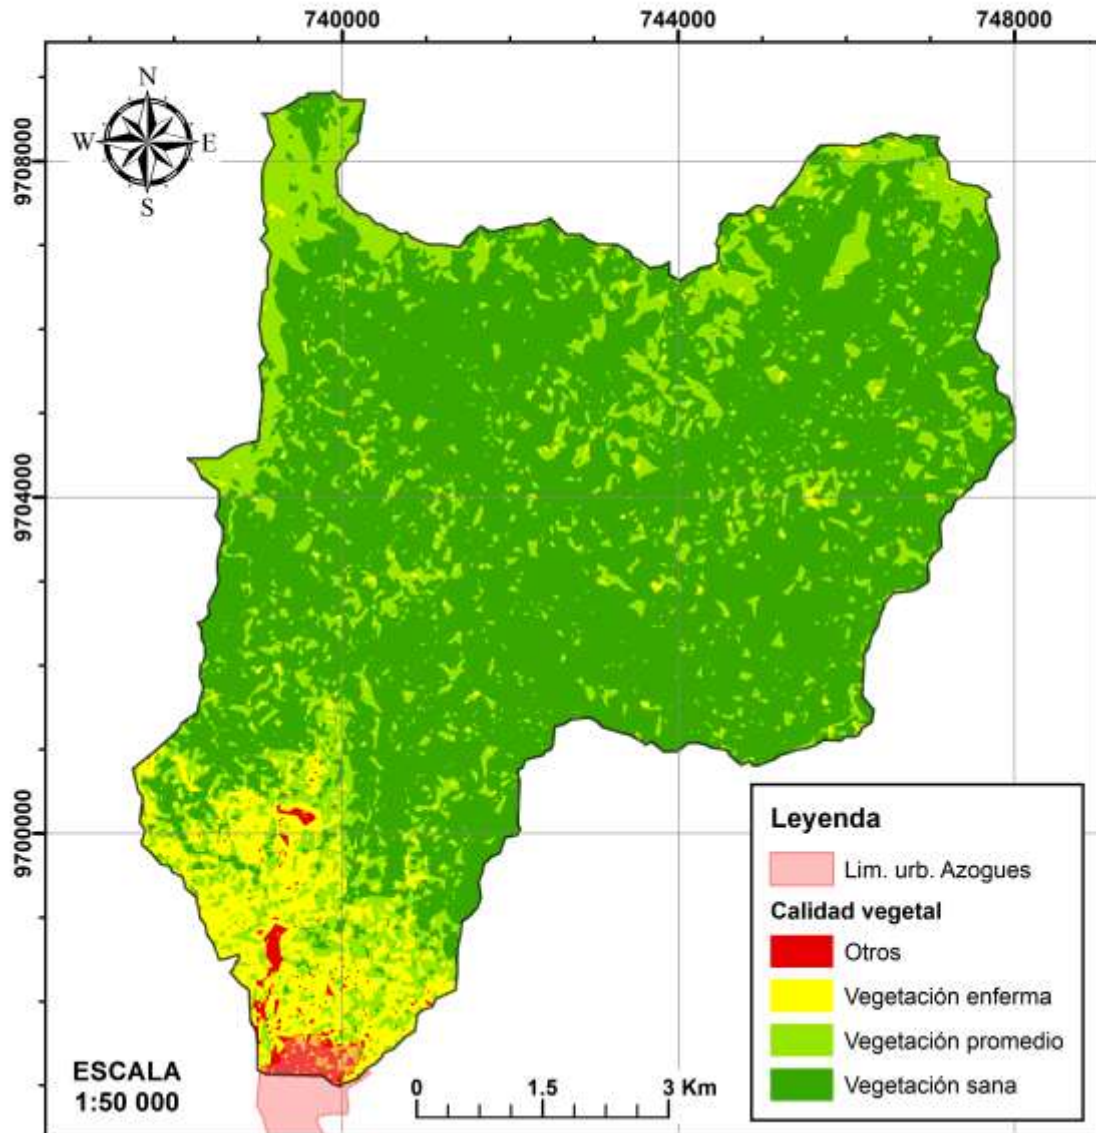
### Anexo 1: Mapas individuales de NDVI por año analizado

#### NDVI PARA LA MICROCUENCA DEL RÍO TABACAY - AÑO 2005






## NDVI PARA LA MICROCUENCA DEL RÍO TABACAY - AÑO 2013

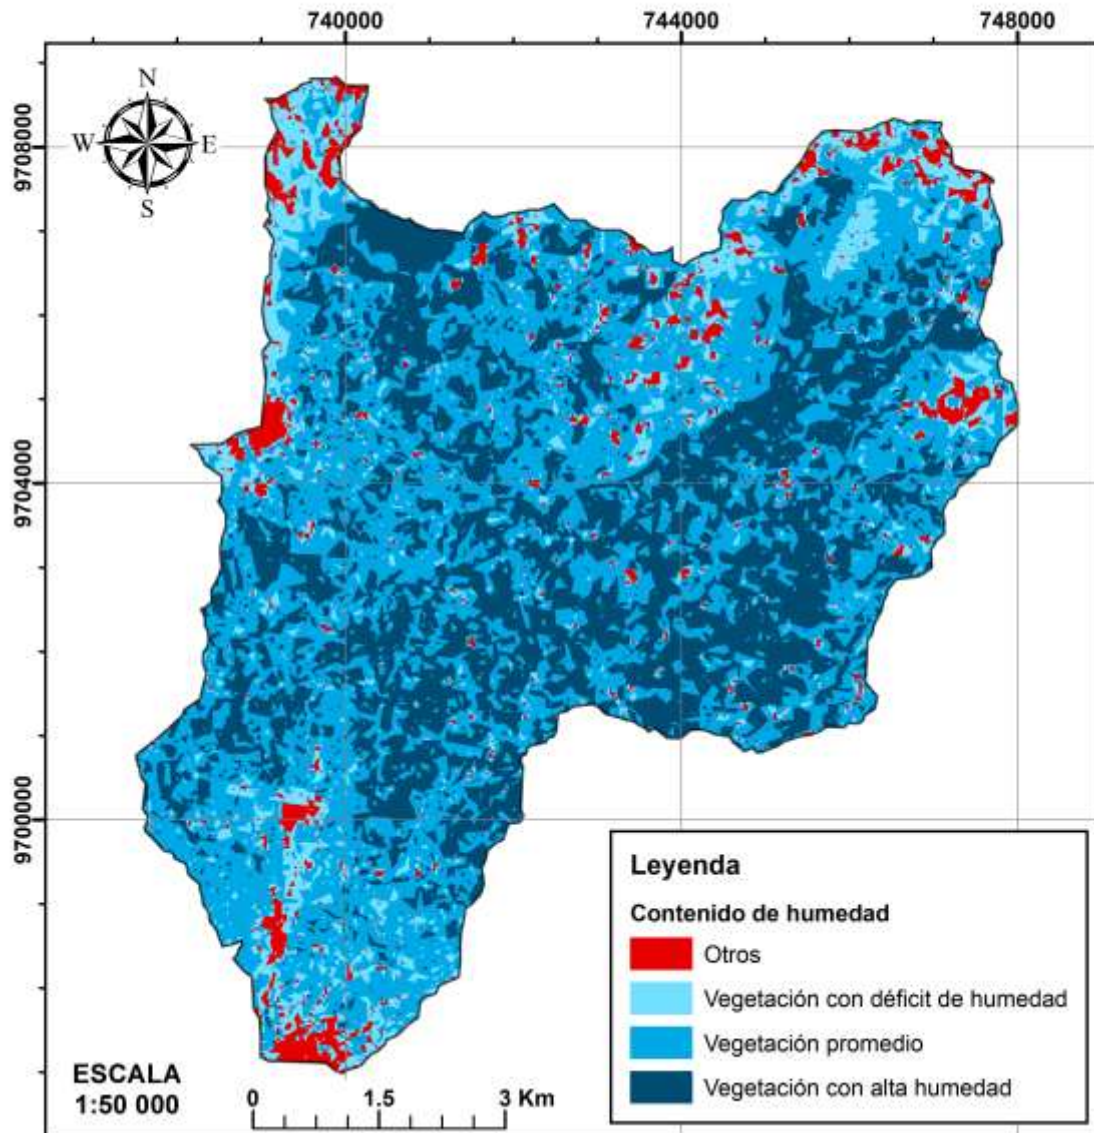


## NDVI PARA LA MICROCUENCA DEL RÍO TABACAY - AÑO 2017



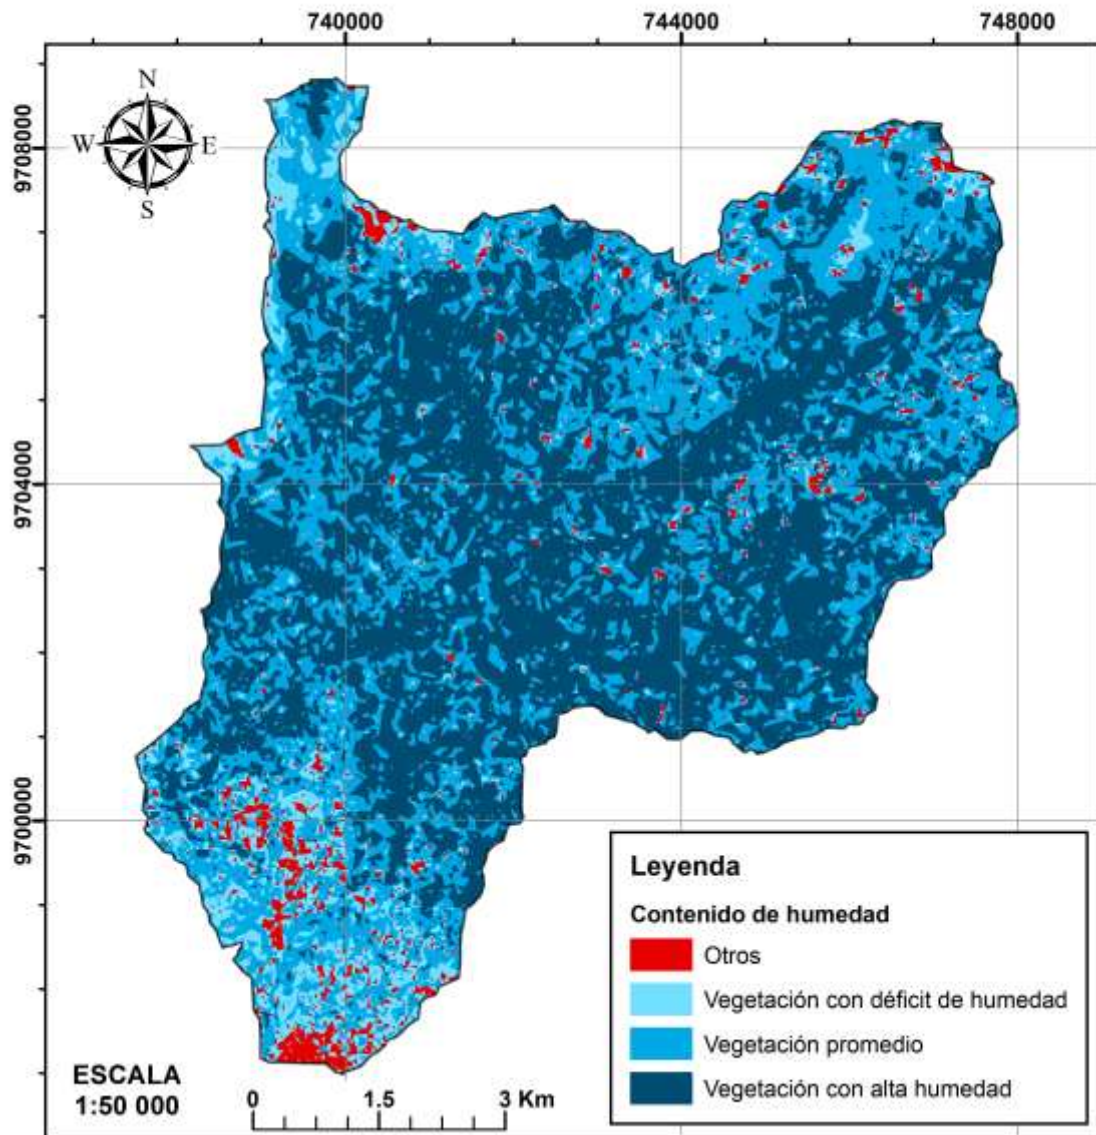
Anexo 2: Mapas individuales de NDWI por año analizado

### NDWI PARA LA MICROCUENCA DEL RÍO TABACAY - AÑO 2005

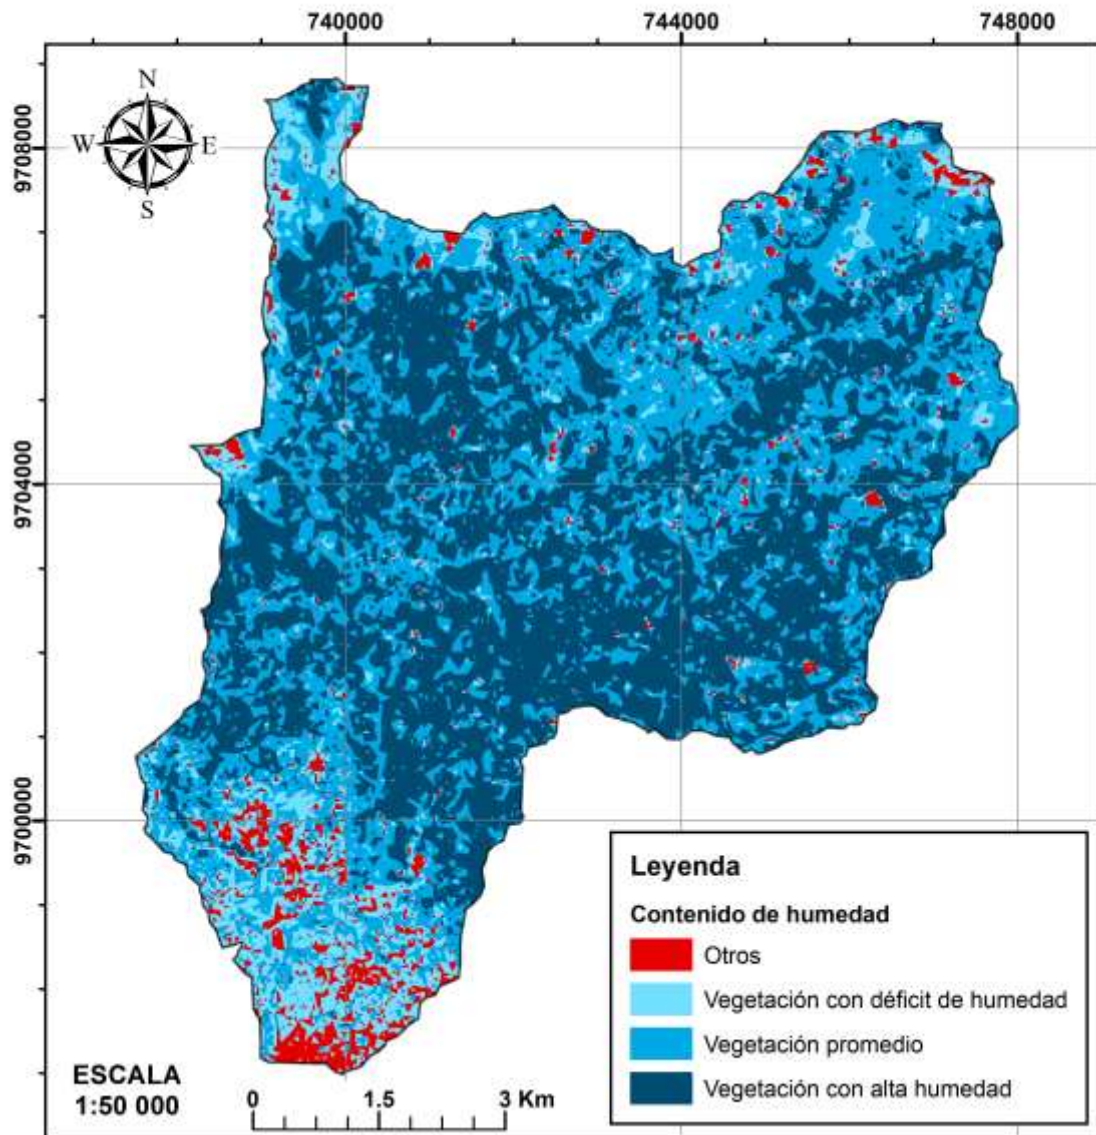




## NDWI PARA LA MICROCUENCA DEL RÍO TABACAY - AÑO 2013



## NDWI PARA LA MICROCUENCA DEL RÍO TABACAY - AÑO 2017

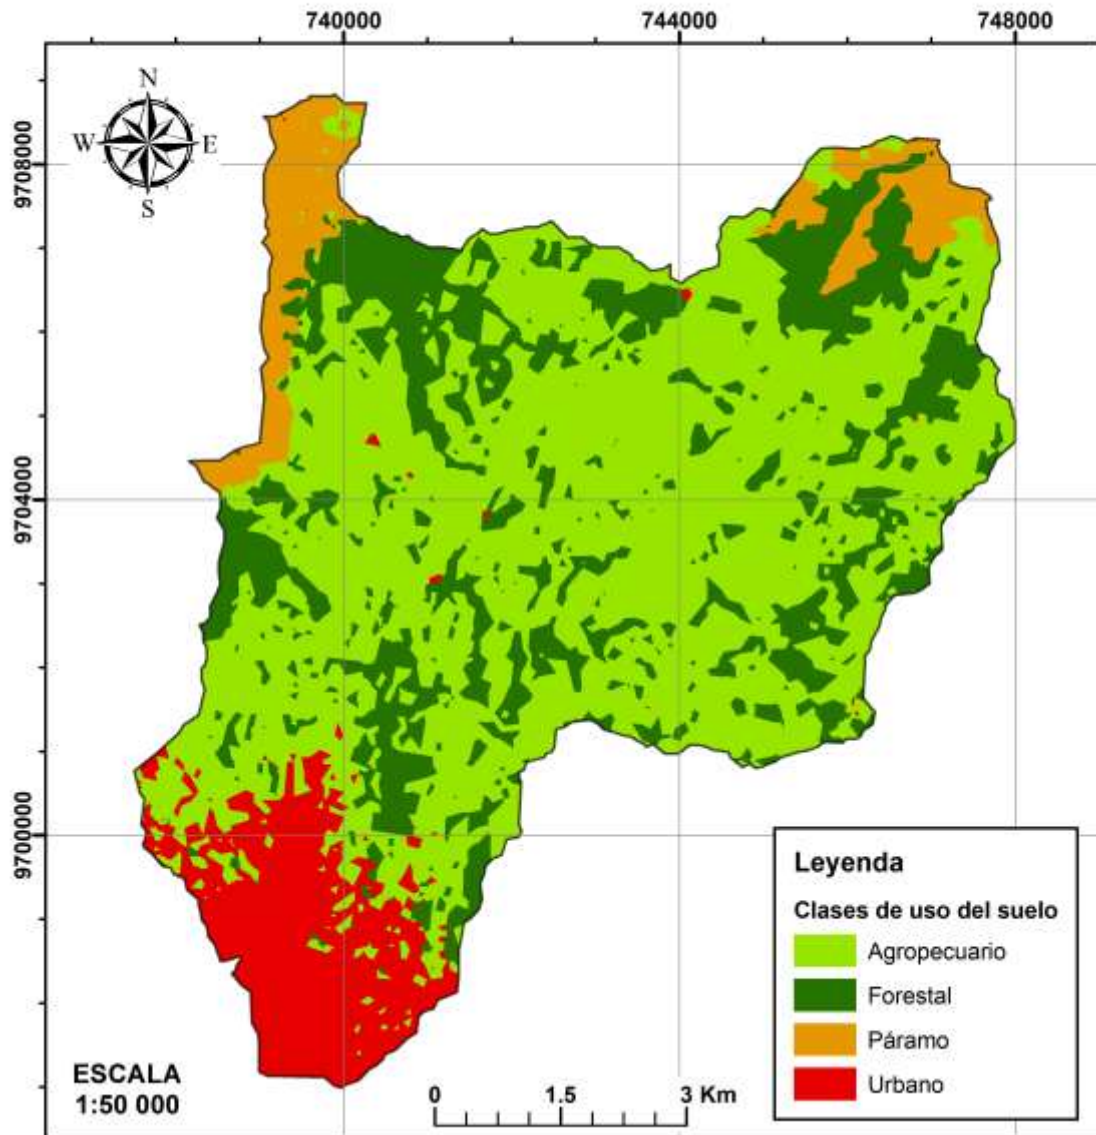


## Anexo 3: Matrices de confusión

MÁX PROB 2005	Clases		Prueba				
			Forestal	Urbano	Páramo	Agropecuario	Total
	Entrenam.	Forestal	784	0	1	1	786
		Urbano	0	185	1	0	186
		Páramo	0	0	514	23	537
		Agropecuario	9	0	85	544	638
	Total	793	185	601	568	2147	
Precisión global [%] = 94.4			Kappa = 0.92				
RED NEUR 2005	Clases		Prueba				
			Páramo	Forestal	Urbano	Agropecuario	Total
	Entrenam.	Páramo	136	0	0	0	136
		Forestal	0	733	0	0	733
		Urbano	0	0	185	0	185
		Agropecuario	465	60	0	568	1093
	Total	601	793	185	568	2147	
Precisión global [%] = 75.5			Kappa = 0.66				
MÁX PROB 2013	Clases		Prueba				
			Forestal	Agropecuario	Urbano	Páramo	Total
	Entrenam.	Forestal	160	0	0	0	160
		Agropecuario	13	134	0	0	147
		Urbano	1	0	121	2	124
		Páramo	14	0	0	162	176
	Total	188	134	121	164	607	
Precisión global [%] = 95.1			Kappa = 0.93				
RED NEUR 2013	Clases		Prueba				
			Páramo	Agropecuario	Forestal	Urbano	Total
	Entrenam.	Páramo	120	10	1	0	131
		Agropecuario	18	125	4	0	147
		Forestal	5	5	187	0	197
		Urbano	11	0	0	121	132
	Total	154	140	192	121	607	
Precisión global [%] = 90.4			Kappa = 0.86				
MÁX PROB 2017	Clases		Prueba				
			Forestal	Urbano	Agropecuario	Páramo	Total
	Entrenam.	Forestal	383	0	0	0	383
		Urbano	0	190	0	0	190
		Agropecuario	2	0	249	4	255
		Páramo	1	0	0	281	282
	Total	386	190	249	285	1110	
Precisión global [%] = 99.4			Kappa = 0.99				
RED NEUR 2017	Clases		Prueba				
			Agropecuario	Forestal	Urbano	Páramo	Total
	Entrenam.	Agropecuario	246	0	1	26	273
		Forestal	2	386	0	5	393
		Urbano	0	0	187	0	187
		Páramo	1	0	2	254	257
	Total	249	386	190	285	1110	
Precisión global [%] = 96.6			Kappa = 0.95				

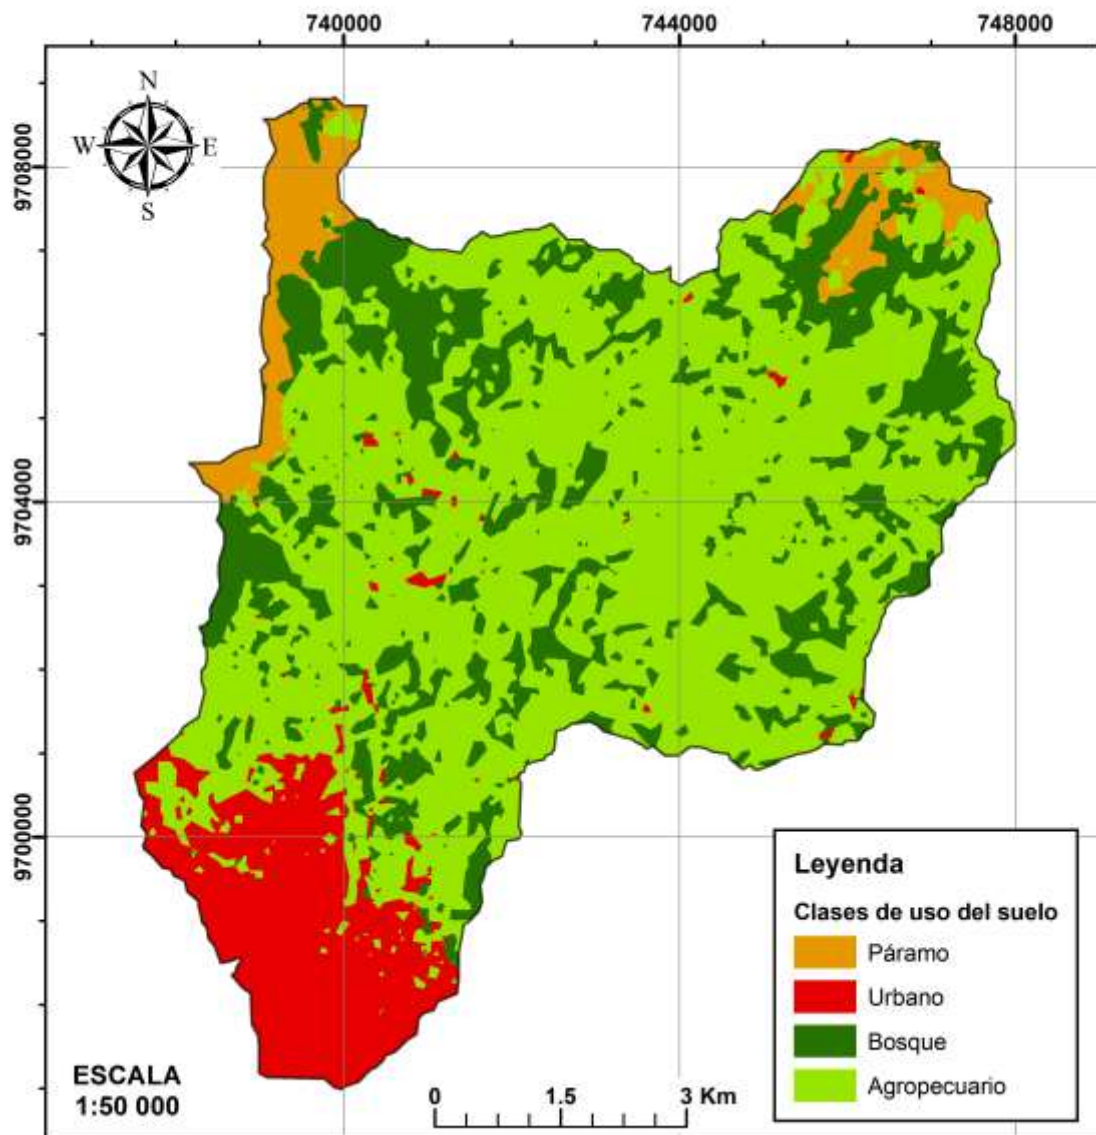
Anexo 4: Mapas individuales de uso del suelo por año analizado

### USO DEL SUELO PARA LA MICROCUENCA DEL RÍO TABACAY - AÑO 2005





## USO DEL SUELO PARA LA MICROCUENCA DEL RÍO TABACAY - AÑO 2013





## USO DEL SUELO PARA LA MICROCUENCA DEL RÍO TABACAY - AÑO 2017

