

**UNIVERSIDAD NACIONAL AMAZÓNICA DE MADRE
DE DIOS**

FACULTAD DE INGENIERÍA

**CARRERA PROFESIONAL DE INGENIERÍA
FORESTAL Y MEDIO AMBIENTE**



**PROSPECTIVA DEL CAMBIO DE USO DE SUELO EN EL DISTRITO DE
IBERIA, TAHUAMANU – MADRE DE DIOS, PERIODO 2004-2030**

TESIS PRESENTADO POR:

Bachiller: TUESTA RODRÍGUEZ, Eric

**PARA OPTAR EL TÍTULO
PROFESIONAL DE INGENIERO
FORESTAL Y MEDIO AMBIENTE**

ASESOR: DR. ALARCÓN AGUIRRE,
Gabriel

COASESOR: DRA. FRISANCHO
VARGAS, Ruth

**UNIVERSIDAD NACIONAL AMAZÓNICA DE MADRE
DE DIOS**

FACULTAD DE INGENIERÍA

**CARRERA PROFESIONAL DE INGENIERÍA
FORESTAL Y MEDIO AMBIENTE**



**PROSPECTIVA DEL CAMBIO DE USO DE SUELO EN EL DISTRITO DE
IBERIA, TAHUAMANU – MADRE DE DIOS, PERIODO 2004-2030**

TESIS PRESENTADO POR:

Bachiller: TUESTA RODRÍGUEZ, Eric

**PARA OPTAR EL TÍTULO
PROFESIONAL DE INGENIERO
FORESTAL Y MEDIO AMBIENTE**

ASESOR: DR. ALARCÓN AGUIRRE,
Gabriel

COASESOR: DRA. FRISANCHO
VARGAS, Ruth

DEDICATORIA

A Dios

Por iluminar mí camino, por bendecirme y por brindarme su fortaleza

A mi Mamá

Por sus grandes sacrificios, Por su apoyo sin límite, por creer en mí

A mi Papá

Por sus consejos para conseguir mis objetivos, por ser mí ejemplo a seguir

A mis hermanos

Jessica, Luis, Alexander, por brindarme su aliento para concluir mis estudios

A mi hija

Por ser parte de mi vida y recordarme que le debo horas de atención

A Isabel

Por su apoyo incondicional, cariño y comprensión para salir adelante.

AGRADECIMIENTOS

Al Señor de Huanca por darme el valor para cumplir con mis metas deseadas en la vida y ser mi guía para seguir adelante.

A la Universidad Nacional Amazónica de Madre de Dios por darme la oportunidad de continuar mis estudios.

Al Centro de Teledetección para el estudio y gestión de los recursos naturales de la Universidad Nacional Amazónica de Madre de Dios por el aporte científico a este estudio.

A los docentes de la Carrera de Ingeniería Forestal y Medio Ambiente por la formación académica.

A mi asesor académico el DR. Gabriel Alarcón Aguirre, por guiarme y transmitirme sus conocimientos durante la elaboración del presente proyecto

A mis compañeros/as por los buenos y malos momentos y que serán un recuerdo inolvidable en mi vida.

A Wilsón y Roberto por su disposición y colaboración en la realización del trabajo de campo.

PRESENTACIÓN

Esta investigación fue desarrollado en cumplimiento para obtener el título profesional de Ingeniero Forestal y Medio Ambiente, pero también este estudio pretende apoyar la conservación de los bosques aportando información a las autoridades mediante el diseño de un modelo de los próximos 14 años acerca de las dinámicas de cambio de uso de suelo de esta forma servirá como base para la toma de decisiones relacionados a políticas de ordenamiento y protección del territorio, planes de reforestación y uso sustentable de los recursos naturales para así revertir la tendencia de cambio de uso de suelo.

RESUMEN

Iberia es uno de los distritos de la provincia de Tahuamanu produciéndose una creciente deforestación en los últimos años producidas por las actividades antrópicas como la expansión agrícola, ganadera, tala y quema de árboles, construcción de carreteras y caminos vecinales, entre otros aspectos colaterales a la actividad, con lo que surge la necesidad de proveer a las autoridades de insumos sobre prospectiva de cambio de uso de suelo para la realización de planes de gestión del territorio. En este contexto los modelos de prospectiva del cambio de uso de suelo son una herramienta para conocer las dinámicas que ayudan a establecer los patrones de cambio de uso del suelo, y a explorar posibles escenarios. El presente trabajo tiene como objetivo analizar y modelar el cambio de cobertura (bosque a deforestación) para determinar zonas deforestadas para los periodos 2004, 2011, 2016 y 2030. Las imágenes que se usarán en esta investigación pertenecen al sensor Landsat 5 TM (2004 y 2011) y Landsat 8 OLI (2016). Los cálculos reportan para el periodo 2004, 2011 y 2016, 4 824,09 ha, 12 260,08 ha, 17 063,72 ha de áreas deforestadas respectivamente. La detección de áreas de cambio a través de imágenes de diferenciación, destacan áreas de sustracción con aumento en el cambio gradual por periodos de 2004-2011 (7 años) con 7 767,78 ha, y del 2011-2016 (5 años) con 5 123,71 ha.

Para la predicción se utilizó el software TerrSet, módulo Land Change Modeler (LCM) que opera a través del método cadenas de Markov. Para ello se elaboró el modelo predictivo al periodo 2016 y 2030, teniendo como base las imágenes de 2004-2011 y 2011-2016. La validación del modelo presenta un nivel de concordancia (índice kappa) de 96,61%, y cuantifico 25 139,51 ha de áreas deforestadas, de los cuales en 14 años (2016-2030) esta correspondería a 8 075,78 ha, adicioanles.

Palabras clave: Análisis prospectivo, Cambio de uso de suelo, deforestacion, Bosque, Cadenas de Markov, Iberia, Tahuamanu, Madre de Dios.

ABSTRACT

Iberia is one of the districts of the province of Tahuamanu that in recent years has been a growing deforestation produced by anthropic activities such as agricultural expansion, livestock, felling and burning of trees, construction of roads and roads, among other aspects collateral to the activity, with what arises the need to provide the authorities with inputs on prospective change of land use for the development of land management plans. In this context, prospective models of land use change are a tool to know the dynamics that help to establish patterns of change in land use, and to explore possible scenarios. The objective of this paper is to analyze and model the change of coverage (forest to deforestation) to determine deforested areas for the periods 2004, 2011, 2016 and 2030. The images involved in this investigation were acquired from the Landsat 5 TM sensor (2004 and 2011) and Landsat 8 OLI (2016). The calculations report for the period 2004, 2011 and 2016, 4 824.09 ha, 12 260.08 ha, 17 063.72 ha of deforested areas respectively. The detection of areas of change through differentiation images, highlight areas of subtraction with increase in gradual change for periods of 2004-2011 (7 years) with 7 767.78 ha, and 2011-2016 (5 years) with 5 123.71 ha.

For the prediction we used the TerrSet software, Land Change Modeler module (LCM) that operates through the Markov chains method. To this end, the predictive model was developed for the 2016 and 2030 periods, based on the images from 2004-2011 and 2011-2016. The validation of the model presents a level of concordance (kappa index) of 96.61%, and quantifies 25 139.51 ha of deforested areas, of which in 14 years (2016-2030) this would correspond to 8 075.78 ha, add them

Key words: Prospective analysis, Change of land use, deforestation, Forest, Markov chains, Iberia, Tahuamanu, Madre de Dios.

INTRODUCCIÓN

El distrito de Iberia (Tahuamanu – Madre de Dios) se caracteriza por tener un clima tropical: abundantes precipitaciones pluviales, húmedo y cálido, en esta área se presenta una vegetación de pacaes mixtos, purmas, chacras y bosques de colinas bajas con terrazas disectadas, donde la especie *Hevea sp.* (shiringa) es la mas representativa (IIAP 2001); y por ende una variada biodiversidad que está asociada a coberturas vegetales muy diversas. Sin embargo, esta biodiversidad se ve amenazada por las actividades antrópicas que se realizan en el área de estudio.

La deforestación esta asociada en los procesos de cambio de cobertura boscosa y el cambio de uso del suelo (Lambin et al. 2006).

Por eso, crear modelos de la ocupación y usos del suelo ayuda a entender y pronosticar su evolución futura, además la simulación a futuro ofrece una adecuada herramienta de ayuda en la toma de decisiones. Los profesionales especializados en esta línea de investigación va en aumento y las aplicaciones pueden realizarse en diferentes y complejos ambientes:

En los últimos 30 años se ha visto un aumento en las investigaciones asociadas con el modelamiento y análisis del cambio en el uso del suelo, principalmente al proceso de deforestación en los bosques tropicales (Durán-Medina et al. 2007; Müller et al. 2014).

El eje fundamental en la determinación de la modelación, está relacionado en el reconocimiento de los factores socioeconómicos y físicos influyen sobre el cambio de uso del suelo en un determinado territorio (Olmedo et al. 2010). Lo habitual de analizar los esfuerzos y de modelar la manera de como ocurren el cambio de uso del suelo se dirigen a responder preguntas, en el caso de la deforestación en el distrito de Iberia, cuantificar la deforestación histórica y actual, medir los cambios de cobertura y analizar la prospectiva a un tiempo determinado, con la finalidad de aportar a la toma de decisiones y a la gestión del territorio.

En este contexto es necesario analizar y modelar la prospectiva del cambio de uso de suelo (bosque a deforestación) para determinar zonas

deforestadas en el distrito de Iberia, Tahuamanu – Madre de Dios, para los periodos 2004, 2011, 2016 y 2030, como un instrumento de gestión al aportar información útil en los procesos de ordenamiento territorial, sobre todo cuando se necesite representar escenarios futuros de cambio de uso del suelo.

INDICE GENERAL

DEDICATORIA.....	I
AGRADECIMIENTOS	II
PRESENTACIÓN	III
RESUMEN.....	IV
ABSTRACT.....	V
INTRODUCCIÓN.....	VI
INDICE GENERAL	VIII
INDICE DE FIGURAS	XII
INDICE DE TABLAS	XVI
INDICE DE ANEXOS	XVIII
CAPÍTULO I. PROBLEMA DE INVESTIGACIÓN	1
1.1 Descripción del problema	1
1.2 Formulación del problema	3
1.2.1 Problema General	3
1.2.2 Problema Específicos	3
1.3 Objetivos del estudio	3
1.3.1 Objetivo general	3
1.3.2 Objetivos específicos.....	3
1.4 Variables.....	4
1.5 Operacionalización de variables.....	4
1.6 Hipótesis.....	5
1.7 Justificación.....	5
1.8 Consideraciones éticas.....	6

CAPÍTULO II. MARCO TEÓRICO	7
2.1 Antecedentes	7
2.1.1 Alcance internacional	7
2.1.2 Alcance nacional	9
2.1.3 Alcance local	11
2.2 Marco teórico	15
2.2.1 Deforestación	15
2.2.2 Bosque	16
2.2.3 Principios y Fundamentos de Teledetección.....	16
2.2.4 Espectro Electromagnético	17
2.2.5 Aplicación de la Imagen Satelital	18
2.2.6 Beneficios de la Utilización de Observaciones Remotas.....	19
2.2.7 Tratamiento Digital de Imágenes Satelitales Multitemporales	20
2.2.7.1 Corrección Geométrica	20
2.2.7.2 Calibración Radiométrica	21
2.2.7.3 Calibración Absoluta	22
2.2.7.4 Calibración Relativa	22
2.2.7.5 Corrección Atmosférica	22
2.2.7.6 Mejoramiento Espectral	23
2.2.7.7 Clasificación Digital.....	24
2.2.7.8 Técnicas de Post-clasificación	25
2.2.8 Diseño de muestreo	25
2.2.8.1 Las unidades de muestreo	25
2.2.8.2 El método de muestreo	26
2.2.8.3 El tamaño de muestra	29

2.2.8.4	Análisis de los datos	30
2.2.9	Programa Landsat	33
2.2.10	Modelación del cambio de Cobertura del suelo – teoría y técnicas	34
2.2.11	Algunos Modelos y Software Utilizados para el CCS	35
2.2.12	Tasa de cambio	40
2.3	Definición de términos	40
CAPÍTULO III. METODOLOGÍA DE INVESTIGACIÓN.....		42
3.1	Lugar de estudio.....	42
3.1.1	Clima e Hidrografía.....	44
3.3	Población	44
3.4	Muestra.....	45
3.5	Métodos y técnicas.....	48
3.5.1	Técnicas de recopilación de datos.....	53
3.6	Variables explicativas del cambio de cobertura de suelo	55
3.7	Clasificación supervisada de la imagen satelital	61
3.8	Tratamientos de los datos	71
3.9	Análisis predictivo.....	72
3.9.1	Análisis de cambio	74
3.9.2	Potencial de transición	79
3.9.2.1	Prospectiva de cambio al año 2016 con Land Change Modeler (LCM)	87
3.9.3	Validación del modelo LCM	89
3.9.4	Prospectiva de cambio al periodo 2030	93

3.10 Análisis estadístico.....	94
CAPÍTULO IV. RESULTADOS Y DISCUSIÓN.....	95
4.1 Cuantificación del cambio de uso de suelo entre 2004, 2011 y 2016 en el distrito de Iberia, Tahuamanu – Madre de Dios.....	95
4.1.1 Cambios de cobertura del suelo	99
4.2 Evaluación de precisión de clasificación	107
4.2.1 Validación del modelo	109
4.3. Prospectiva de cambio al periodo 2030	113
4.3.1 Cambio de cobertura del suelo con el modelo prospectivo al 2030	115
CONCLUSIONES.....	122
RECOMENDACIONES.....	124
BIBLIOGRAFÍA CONSULTADA	125
ANEXOS	140

INDICE DE FIGURAS

Figura 1. Esquemas de muestreo probabilistas más aplicados en la evaluación de la confiabilidad de mapas temáticos.	27
Figura 2. Disposición espacial de las observaciones bajo un muestreo aleatorio A: simple; B: sistemático y C: estratificado.	27
Figura 3. Tamaño de muestra necesario para alcanzar un error estándar de 0,05 en función del tamaño de la población. El tamaño de la población está representado en escala logarítmica $\log_{10}(N)$	30
Figura 4. Ubicación del área de estudio, distrito de Iberia, provincia de Tahuamanu – Madre de Dios.	43
Figura 5. Distribución de muestras por categoría, método aleatorio estratificado.	48
Figura 6. Imagen de Satelite Landsat 8 OLI 2016, colección de areas de entrenamiento a traves de firmas espectrales de la categoría bosque en el distrito de Iberia, Tahuamanu - Madre de Dios - Perú.. R(6) G(5) B(4).	51
Figura 7. Imagen de Satelite Landsat 8 OLI 2016, colección de areas de entrenamiento a traves de firmas espectrales de la categoría deforestación en el distrito de Iberia, Tahuamanu - Madre de Dios - Perú.. R(6) G(5) B(4).	52
Figura 8. Imagen de Satelite Landsat 8 OLI 2016, colección de areas de entrenamiento a traves de firmas espectrales de la categoría no bosque en el distrito de Iberia, Tahuamanu - Madre de Dios - Perú. R(6) G(5) B(4).	52
Figura 9. Imagen de satélite Landsat 5 TM, composición de banda 5-4-3 (20040729-003-068).	54
Figura 10. Imagen de satélite Landsat 5 TM, composición de banda 5-4-3 (20110903-003-068).	54

Figura 11. Imagen de satélite Landsat 8 OLI, composición de banda SWIR 1, Near Infrared y Red (20160815-003-068).....	55
Figura 12. Modelo Digital del Terreno	57
Figura 13. Modelo cartográfico generación variable pendiente.	58
Figura 14. Mapa de pendientes.	59
Figura 15. Distancia a vías principales, secundarias y trochas.	60
Figura 16. Distancia a centros poblados.	60
Figura 17. Distancia a ríos.	61
Figura 18. Proceso de corrección atmosférica.	62
Figura 19. Calibración Radiométrica	64
Figura 20. Modelo de Corrección Atmosférica - FLAASH	65
Figura 21. Expresión Band Math.....	66
Figura 22. Transformando el archivo SR2.img.....	66
Figura 23. Archivo de salida SR3.img	67
Figura 24. Proceso de Clasificación de la imagen satelital.....	68
Figura 25. Representacion del agulo de referencia.....	69
Figura 26. Proceso de Post-Clasificación de la imagen satelital.	70
Figura 27. Proceso del módulo Land Change Modeler (LCM) del software TerrSet.	74
Figura 28. Parámetros para el módulo Land Change Modeler (LCM) del software TerrSet.	75
Figura 29. Herramienta ganancias y pérdidas por categoría.....	76
Figura 30. Mapa de cambio (ganancias y pérdidas) por categoría.....	77
Figura 31. Herramienta tendencia polinomial de 3er orden para los patrones de cambio.....	78
Figura 32. Mapa de tendencia polinomial de 3er orden para los patrones de cambio.....	78

Figura 33. Herramienta de potencial de transición.	79
Figura 34. Mapa de cambio Bosque a Deforestacion y Deforestacion a Bosque.	80
Figura 35. Herramienta transformación de variable..	81
Figura 36. Mapa de la modelación de transición.	81
Figura 37. Variables utilizadas en el modelo prospectivo de cambio de uso del suelo, periodo 2016 y 2030. (a) Modelo de elevación digital - MDT, (b) Pendiente, (c) Red vial principal y secundaria, (d) Centros urbanos, (e) centros rurales, (f) Red hidrográfica, (g) Tendencia de la deforestación, y (h) Transición.....	83
Figura 38. Sub modelo de transición del Land Change Modeler – TerrSet 2004-2011, para el periodo 2016.	84
Figura 39. Potencial de transición de bosque a deforestación, modelo prospectivo 2016.	87
Figura 40. Potencial de transición de deforestación a bosque, modelo prospectivo 2016.	87
Figura 41. Prospectiva de cambio de uso: bosque a deforestación, periodo 2016.	88
Figura 42. Cambio de uso de suelo; bosque a deforestación, periodo 2016.	88
Figura 43. Proceso de validación de la cobertura observada y la cobertura simulada.	89
Figura 44. Herramienta de validación.	90
Figura 45. Modelización entre categorías.	90
Figura 46. Herramienta Cross Tab.....	91
Figura 47. Clasificación cruzada; cobertura de uso de suelo 2016 y prospectiva 2016.	92
Figura 48. Potencial de transición proyectado, periodo 2030.	93

Figura 49. Prospectiva de cambio de uso: bosque a deforestación, periodo 2030.	93
Figura 50. Imágen Landsat clasificada para el periodo 2004; cobertura de bosque y deforestación, distrito de Iberia, Tahuamanu – Madre de Dios.	95
Figura 51. Imágen Landsat clasificada para el periodo 2011; cobertura de bosque y deforestación, distrito de Iberia, Tahuamanu – Madre de Dios.	96
Figura 52. Imágen Landsat clasificada para el periodo 2016; cobertura de bosque y deforestación, distrito de Iberia, Tahuamanu – Madre de Dios.	96
Figura 53. Cambio de cobertura 2004-2011.....	101
Figura 54. Cambio de cobertura 2011-2016.....	102
Figura 55. Cambio de cobertura 2004-2016.....	103
Figura 56. Cambio de cobertura de uso del suelo, periodo 2004 al 2016, distrito de Iberia, Tahuamanu - Madre de Dios.	106
Figura 57. Matriz de confusión.....	107
Figura 58. Prospectiva de cambio de uso: bosque a deforestación, periodo 2016.	110
Figura 59. Resultados de la validación usando la herramineta Cross Tab del software TerrSet.	112
Figura 60. Prospectiva de cambio de uso: bosque a deforestación, periodo 2030.	114
Figura 61. Cambio de cobertura 2016-2030.....	116
Figura 62. Cambio de cobertura 2004-2030.....	117
Figura 63. Cambio de cobertura de uso del suelo, periodo 2004 al 2030, distrito de Iberia, Tahuamanu - Madre de Dios.	121

INDICE DE TABLAS

Tabla 1. Operacionalización de variables de estudio.	4
Tabla 2. Resultados con diferentes programas.	12
Tabla 3. Matriz de confusión expresada en proporción.	32
Tabla 4. Valoración del coeficiente kappa.	33
Tabla 5. Leyenda de clasificación de imágenes; nivel 0.	46
Tabla 6. Distribución de muestras por categoría.	47
Tabla 7. Información de adquisición de imágenes Landsat.	49
Tabla 8. Características de la imagen de satélite Landsat 5 TM.	49
Tabla 9. Características de la imagen de satélite Landsat 8 OLI.	50
Tabla 10. Variables empleadas en la regresión logística.	56
Tabla 11. Superficie de acuerdo a la altitud.	57
Tabla 12. Superficie de terreno por pendiente.	58
Tabla 13. Parámetros de calibración radiométrica Landsat 8.	63
Tabla 14. Valoración del coeficiente kappa.	71
Tabla 15. Comportamiento del modelo por transición y persistencia.	85
Tabla 16. Contrastación de variables por etapas.	85
Tabla 17. Reconocimiento cruzado de píxeles; cobertura de uso de suelo 2016 (columnas) y prospectiva 2016 (filas).	92
Tabla 18. Reporte de clasificación supervisada del distrito de Iberia, Tahuamanu – Madre de Dios, periodos 2004, 2011 y 2016.	97
Tabla 19. Matriz de tabulación cruzada para dos mapas de diferentes fechas, basado en Pontius et al. 2004.	99
Tabla 20. Ejemplos de la dinámica del cambio de cobertura de suelo.	99
Tabla 21. Matriz de tabulación cruzada y tasas de cambios entre 2004 y 2011 (datos en ha)	104

Tabla 22. Matriz de tabulación cruzada y tasas de cambios entre 2011 y 2016 (datos en ha)	104
Tabla 23. Matriz de tabulación cruzada y tasas de cambios entre 2004 y 2016 (datos en ha)	104
Tabla 24. Precisión de resultados, imagen periodo 2016.....	108
Tabla 25. Calidad de ajuste de acuerdo al índice de Kappa.	111
Tabla 26. Áreas de coberturas de suelo observadas vs prospectiva.....	113
Tabla 27. Reporte de Prospectiva de cambio de uso: bosque a deforestación, periodo 2030.	113
Tabla 28. Reporte de clasificación año de referencia 2016 y prospectiva al año 2030.	115
Tabla 29. Matriz de tabulación cruzada y tasas de cambios entre 2016 y 2030 (datos en ha).....	118
Tabla 30. Matriz de tabulación cruzada y tasas de cambios entre 2004 y 2030 (datos en ha).....	118
Tabla 31. Cambio de cobertura del suelo (bosque – deforestación) en el distrito de Iberia, Tahuamanu – Madre de Dios, periodo 2004-2030...	119
Tabla 32. Tasa de la deforestación y tasa anual de cambio en el distrito de Iberia, Tahuamanu – Madre de Dios, periodo 2004 al 2030.....	119

INDICE DE ANEXOS

Anexo 1. Matriz de consistencia prospectiva del cambio de uso de suelo en el distrito de Iberia, Tahuamanu – Madre de Dios, periodo 2004-2030	140
Anexo 2. Coberturas de deforestación del distrito de Iberia.	144

CAPÍTULO I. PROBLEMA DE INVESTIGACIÓN

1.1 Descripción del problema

Las alteraciones en la cobertura y el uso del suelo (LULUCF, por su abreviatura del inglés), es la palabra que se usa para mostrar los cambios que se realizan sobre la cobertura terrestre originada por las actividades antrópicas y/o las alteraciones en el tiempo (Soares-Filho et al. 2004).

El LULUCF está perturbando la actividad de los ecosistemas y es la principal causa de la pérdida de la biodiversidad, vulnerabilidad de los ecosistemas y fragmentación de hábitats (Lambin et al. 2003), aportando con 6-17 % en las emanaciones de dióxido de carbono en el planeta (Malhi y Phillips 2004).

Las estimaciones al año 2050, pronostican que el LULUCF será la causa mas importante en la pérdida de la biodiversidad (Sala et al. 2000). Por esto, el estudio del cambio climático, la preservación de la diversidad biológica, la administración de áreas naturales protegidas y el ordenamiento territorial son una de las mas importantes prioridades de los encargados de políticas ambientales (IPCC 2000).

Las causas que mas se asocian en los procesos de cambio uso del suelo y de la cobertura es la deforestación (Lambin et al. 2006). Los bosques tropicales, cubren cerca al 10% del planeta, a pesar de ello representa la mayor biodiversidad de la tierra y es primordial para la regulación de los recursos hídricos y en ciclo global del carbono (Mayaux et al. 2005), aportando en la deforestación de los bosques tropicales y el cambio en el uso del suelo con un alto porcentaje de las emisiones de CO₂ en todo el planeta (Chowdhury 2006).

Actualmente la importancia en el proceso LULUCF se han creado metodos para la localización de los cambios, que van desde el uso de nuevas tecnologías como son los sistemas de información geográfica, la teledetección y el análisis geoespacial, hasta el diseño de modelos que ayudan a visualizar y entender de una forma más global el comportamiento del cambio y crear escenarios factibles que ayuden a responder preguntas difíciles sobre el tema (Lu et al. 2005).

El departamento de Madre de Dios tiene un clima tropical, típico de la amazonia peruana (Sub Húmedo y Cálido, Húmedo y Cálido, Muy húmedo y semicálido), y por ende una variada biodiversidad que está asociada a coberturas vegetales muy diversas. A pesar de eso, la gran biodiversidad se encuentra en peligro por las actividades antrópicas que se realizan en el territorio, como las actividades productivas, extractivas, de ocupación del suelo, y cuya dinámica a lo largo del tiempo en mayor o menor medida se conoce, sin embargo, poco o nada se toma en cuenta para resolverla, en ese sentido, surge el interés de comprender los factores que se relacionan a la transformación de Cambio en la cobertura y Uso del Suelo (CCUS), con mayor intensidad en la deforestación, debido a las intervenciones ambientales como la pérdida de biodiversidad, el calentamiento global, la degradación de suelos, los cambios en las cuencas hidrográficas y sobre el bienestar de las personas (Alarcón, Díaz, Vela, García y Gutiérrez 2016; Geist y Lambin 2002, 2004; Lambin et al. 2001; Morton et al. 2006).

Iberia es uno de los distritos de la Provincia de Tahuamanu que se ha originado un aumento notable en el cambio de uso de suelo debido a la deforestación producidas por las actividades antrópicas como la expansión agrícola, ganadera, tala y quema de árboles, construcción de carreteras y caminos vecinales, entre otros aspectos colaterales a la actividad. Hasta el momento no se han realizado estudios que permitan proyectar los daños futuros, esta situación se agrava, por el desinterés, la desarticulación y la falta de instrumentos de gestión por parte del gobierno nacional, regional y local para resolver y planificar adecuadamente el uso del territorio, por este motivo la importancia de desarrollar una metodología para diseñar los procesos en el cambio de uso del suelo al año 2030, como apoyo al tomar decisiones para la administración del territorio. A tales efectos, se pretende diagnosticar y diseñar los cambios de uso de suelo entre los años 2004, 2011, 2016 y 2030. Asimismo, es importante estimar aquella variable más trascendental al momento de modelar el cambio de uso de suelo, de esta manera decidir cuáles son los más influyente en esta transformación de cambio.

1.2 Formulación del problema

1.2.1 Problema General

¿Cuál es la tendencia de cambio de uso de suelo en el distrito de Iberia, Tahuamanu – Madre de Dios en los periodos 2004, 2011 y 2016, como base para modelar los cambios de uso de suelo al año 2030?

1.2.2 Problema Específicos

- ¿Cuál fue el cambio de uso de suelo entre 2004, 2011 y 2016 en el distrito de Iberia, Tahuamanu – Madre de Dios?
- ¿Se podrá modelar y validar el proceso de cambio de uso de suelo para el año 2016, a partir del mapa de uso de suelo del año 2016 generado a partir de sensores remotos?
- ¿Se podrá modelar el proceso de cambio de uso de suelo para el año 2030, a partir del modelo de cambio de uso de suelo?
-

1.3 Objetivos del estudio

1.3.1 Objetivo general

Analizar y modelar las actividades antrópicas como factor de cambio del uso de suelo en el distrito de Iberia, Tahuamanu – Madre de Dios, para los periodos 2004, 2011, 2016 y 2030.

1.3.2 Objetivos específicos

- ✓ Cuantificar el cambio de uso de suelo entre 2004, 2011 y 2016 en el distrito de Iberia, Tahuamanu – Madre de Dios.
- ✓ Modelar y validar el cambio de uso de suelo para el año 2016, a partir del mapa de uso de suelo del año 2016 generado a partir de sensores remotos.
- ✓ Modelar el proceso de cambio de uso de suelo para el año 2030, a partir del modelo de cambio de cobertura del suelo.

1.4 Variables

- ✓ **Variable Dependiente:** Cobertura vegetal y no vegetal.
- ✓ **Variable Independiente:** Comportamiento del objeto en función de la unidad mínima de la imagen (píxel).

1.5 Operacionalización de variables

En la tabla 1, se presenta la operacionalización de variables.

Tabla 1. Operacionalización de variables de estudio.

Tema	Objetivos	Variables	Indicadores
Análisis prospectivo del proceso de cambio de uso de suelo en el distrito de Iberia, Tauamanu – Madre de Dios, periodo 2004 al 2030.	✓ Analizar y cuantificar el cambio de uso del suelo (bosque a deforestación) entre 2004, 2011 y 2016 en el distrito de Iberia, Tahuamanu – Madre de Dios.	Cambios de uso de suelo de los periodos 2004, 2011 y 2016.	1. Clasificación supervisada de imagen Landsat 8 OLI año 2016.
			2. Mapa y cuantificación de cambios de uso de suelo de bosque a deforestación, periodo 2004 – 2011.
	3. Mapa y cuantificación de cambios de uso de suelo de bosque a deforestación, periodo 2011 – 2016.		
	✓ Modelar y validar el proceso de cambio de uso de suelo para el año 2016, a partir del mapa de cobertura (bosque y deforestación) del año 2016 generado a partir de sensores remotos.	Prospectiva de cambio de uso de suelo (deforestación) para el periodo 2016, validado.	Mapa prospectivo de cambio de uso de suelo (deforestación) para el periodo 2016.

Tema	Objetivos	Variables	Indicadores
	✓ Modelar el proceso de cambio de uso de suelo para el año 2030, a partir del modelo de cambio de uso del suelo.	Prospectiva de cambio de uso de suelo (deforestación) para el periodo 2030.	Mapa prospectivo de cambio de uso de suelo (deforestación) para el periodo 2030.

1.6 Hipótesis

- ✓ **Hipótesis alterna (H_a):** El cambio de uso de suelo en el distrito de Iberia, Tahuamanu – Madre de Dios en los periodos 2004, 2011 y 2016, como base para determinar la prospectiva de cambio de uso de suelo al año 2030, sigue una dinámica con tendencia creciente.
- ✓ **Hipótesis nula (H_0):** El cambio de uso de suelo en el distrito de Iberia, Tahuamanu – Madre de Dios en los periodos 2004, 2011 y 2016, como base para determinar la prospectiva de cambio de uso de suelo al año 2030, no sigue una dinámica con tendencia creciente.

1.7 Justificación

Modelar la actividad y usos del suelo ayuda a entender y predecir el cambio a futuro, en tanto la simulación prospectiva proporciona una eficiente herramienta en la toma de decisiones. Los profesionales y técnicos comprometidos en este campo de investigación va en aumento (Mas et al. 2004); regeneración natural en la montaña europea; modificación de paisaje y desarrollo urbano (Aguilera 2006; Gómez y Barredo 2006; Molero et al. 2007; Valenzuela et al. 2008), entre otros.

En los últimos 30 años se ha visto un incremento en las investigaciones relacionadas con el estudio y diseño del cambio en el uso del suelo, esencialmente al proceso de deforestación en países con bosques tropicales (Durán-Medina, Mas y Velázquez 2007; Müller, Larrea, Cuéllar y Espinoza 2014).

El eje mas importante en el afán de diseñar, se da por el reconocimiento de los factores socioeconómicos y físicos influyen en el cambio de uso del suelo en un territorio (Olmedo, Melgarejo y Paegelow 2010). Usualmente los esfuerzos de analizar y diseñar los procesos de cambio de uso de suelo se dirigen a responder preguntas, en el caso del cambio de uso de suelo en distrito de Iberia – Tahuamanu, se hace necesario cuantificar el cambio de uso de suelo histórica y actual, determinar los cambios de uso de suelo y analizar la prospectiva a un tiempo determinado, con el propósito de aportar en la administración del territorio y la toma de decisiones.

1.8 Consideraciones éticas

La ejecución de la investigación no asumió ningún riesgo para el Tesista y colaboradores. El análisis de la imágenes satelitales fueron realizadas usando software con licencia del Centro de Teledetección para el estudio y gestión de los recursos naturales de la Universidad Nacional Amazónica de Madre de Dios. Se tiene en cuenta la autenticidad de los resultados; la consideración por la propiedad intelectual; consideración por la biodiversidad y el medio ambiente.

El levantamiento de datos de campo se realizarón como lo establecido por la metodología de estudio.

CAPÍTULO II. MARCO TEÓRICO

2.1 Antecedentes

2.1.1 Alcance internacional

Pinos (2016), demostró la evolución del cantón cuenca que se ubica en la provincia del Azuay, localizada en la Región centro sur del país del Ecuador, en relación con los cambios de uso de suelo se origino durante los años 1991 y 2001, ademas la tendencia de cambio hacia el año 2030. La cuenca del cantón padecio muchas modificaciones a lo largo de todo su territorio y relacionado a la abertura de una carretera sin planificación. Esto se puede constatar al analizar que la cobertura natural (herbácea, vegetación páramo, y leñosa), obteniendose una pérdida de 49 066,3 hectáreas, entre los años 1991 – 2001; la categoría de pastos y cultivos tiene un aumento de 70 639 hectáreas entre los años 1991 – 2001. El mapa de probabilidad hacia el año 2030 indica la tendencia de cambio que se ha venido dando en el territorio, el desarrollo agropoductivo y el crecimiento urbano son las principales causas de la deforestación sobre las coberturas boscosas.

Valero (2015), determino que la actividad antrópica en la microcuenca del río Cristal, provincia de Bolívar y Los Ríos – Ecuador se ha incrementado en los últimos años provocando daños irreparables a los ecosistemas naturales, acelerando así los procesos de erosión por el mal manejo de los suelos y el crecimiento de la frontera agrícola, con lo que surge la necesidad de proveer a las autoridades de insumos para la elaboración de planes relacionados al manejo de cuencas. El estudio desarrollo un modelo prospectivo del uso y cobertura de suelo para el año 2020 basado en la técnica combinada de autómatas celulares y cadenas de Markov. Para ello, se realizaron procesos de ortorectificación de fotografías aéreas de donde se extrajeron las coberturas de suelo para el periodo 1983-2000. Además, se ajustaron modelos de regresión logística, para relacionar las variables biofísicas que condicionan la evolución en los usos de suelo y las zonas de cambio, se efectuó la simulación al año 2010 y se comparó mediante el índice Kappa para determinar el grado de ajuste a la realidad y finalmente se simuló al año

2020. El estudio evidencia la pérdida de vegetación natural, disminución de áreas agrícolas e incremento de zonas de uso pecuario.

Osorio et al. (2015), reportaron los cambios en el uso del suelo y de la cobertura vegetal en la cuenca del río Coyuquilla, Guerrero- México durante los periodos 1986-2000 y 2000-2011. Se crearon mapas de las coberturas y uso del suelo haciendo uso de la interpretación de imágenes satelitales. Durante el periodo 1986-2000 se percibió una pérdida del 16% de la cobertura boscosa que afectó especialmente los bosques tropicales secos con una tasa anual de deforestación de -3,7%. De 2000-2011 se percibió una pérdida del 22% de la cobertura boscosa donde el bosque de encino, es la que se evidenció la tasa más elevada de deforestación (-5,54%). El aumento en los pastizales fue la principal causa en la pérdida de la cobertura boscosa. La pendiente del terreno, la distancia a vías terrestres, la distancia a zonas urbanas y la altitud fueron indicadores principales para demostrar la deforestación los dos periodos analizados y en los tres tipos de bosque.

Alvarez-Berríos y Aide (2015), realizó una evaluación regional de la deforestación provocada por la minería de oro en el bioma de bosque húmedo tropical en América del Sur, determinando que aproximadamente 1 680 km² de estos bosques se perdieron entre 2001 y 2013, identifica que entre los años 2007 y 2013 la deforestación fue significativamente más alta y lo asocia al aumento de la demanda mundial del oro posterior a la crisis financiera internacional ocurrida en ese periodo. Afirma que más del 90% de la deforestación ocurrió en cuatro zonas, en la Ecorregión de Bosques Húmedos Guyanés (41%), Ecorregión de Bosques Húmedos del Suroeste del Amazonas (28%), Ecorregión de bosque húmedo de Tapajós-Xingú (11%) y en el Bosque Montano del Valle de Magdalena y Ecorregión de bosque húmedo de Magdalena-Urabá (9%). Finalmente concluye que la ecorregión de Bosques Húmedos del Suroeste del Amazonas ha sido afectada por la deforestación en 473 km², gran parte de esta deforestación ocurrió en los distritos de Huepetue, Madre de Dios e Inambari en el departamento de Madre de Dios – Perú. Además, menciona que la extracción de oro está afectando a Áreas Naturales Protegidas como la

Reserva Comunal Amarakaeri, Reserva Nacional Tambopata y el Parque Nacional Bahuaja-Sonene también pertenecientes al departamento de Madre de Dios.

Müller, Larrea, Cuéllar y Espinoza (2014), presentaron resultados de la dinámica de la deforestación en las zonas bajas de Bolivia acontecida durante el periodo 2000 y 2010. Se analizaron tres tipos de usos del suelo que son las principales causantes de deforestación (agricultura a baja escala, ganadería y agricultura tecnificada). Los resultados obtenidos indican que en los últimos 10 años la ganadería fue la principal causa de cambio de uso de suelo, provocando más del 50% de la. La agricultura tecnificada apporto con un 30% a la pérdida de bosques. Las proyecciones a futuro del crecimiento agropecuario se evaluaron utilizando un diseño espacial de regresión logística, basado en variables independientes ambientales, socioeconómicas y políticas. Se realizaron dos escenarios de deforestación hasta el año 2040, uno positivo o conservacionista y uno negativo sin cambios en las dinámicas de deforestación.

2.1.2 Alcance nacional

MINAM (2015), presentaron los análisis de la cuantificación y los resultados de la disminución de bosque por deforestación en la Amazonía Peruana desde el año 2010 hasta el 2014, a través de la herramienta CLASlite y otros procesos elaborados por los técnicos de la Dirección General de Ordenamiento Territorial. Han localizado una desminución de la cobertura vegetal amazónica de 415 278 ha entre los años 2010 y 2014, con una tasa de pérdida anual de 103 819 ha/año, así mismo, registraron una superficie deforestada de 1 315 673 ha., entre los años 2000 hasta el 2014.

Finer y Novoa (2015a), presentaron un primer reporte de síntesis denominado “drives y patrones de la deforestación en la Amazonía Peruana”, el cual muestra un resultado inicial de los patrones y causas de la deforestación, basados en los quince primeros reportes publicados en el Monitoring of the Andean Amazon Project - MAAP, reportes basados en un sistema de monitoreo en tiempo real realizado entre los meses de abril a setiembre del 2015, donde identifica a la minería aurífera como uno de los

tres principales drivers en la Amazonía Sur Peruana, documentando una deforestación que asciende a más de 53 000 ha originadas por minería aurífera en la región de Madre de Dios y parte de la región de Cusco, y el 80% de esta cifra ocurrió posterior al año 2000 concentrándose en el área conocido como “La Pampa”, ubicado en de la zona de amortiguamiento de la Reserva Nacional Tambopata. Uno de los reportes (MAAP: Imagen #1) de Finer y Novoa (2015b) cuantifica que la deforestación en “la Pampa” ascendió a 1 711 ha nuevas entre los años 2013 y 2015.

Finer et al. (2016b), menciona que a través del monitoreo casi a tiempo real, se logró monitorear la invasión de la minería aurífera ilegal dentro de la Reserva Nacional Tambopata el cual inició en noviembre del 2015 y que según los registros, la deforestación en esta área supera las 450 ha.

Finer y Novoa (2017); presentaron un segundo reporte de síntesis denominado “Patrones y drivers de deforestación en la Amazonía Peruana” donde, con mayor detalle, muestra los resultados de los 50 reportes realizados por Monitoring of the Andean Amazon Project - MAAP), donde los principales hallazgos fueron las tendencias, patrones y drivers de la deforestación en la Amazonía Peruana. Propiamente la metodología empleada por MAAP proviene del análisis visual con Imágenes de Alta resolución Digital Globe con 0,5 m de resolución y Planet (3-5 m de resolución), además de datos de USGS/NASA (RapidEye 2, LandSat). Así como contribuciones de datos de investigaciones de Greg Asner y Hansen, datos generados por la Universidad de Maryland y Google. Esta síntesis explica la tendencia creciente de la deforestación entre el 2001 y 2015 en los bosques de la Amazonía Peruana, alcanzando pérdidas de más de 1 800 000 ha, el tamaño de estas pérdidas fueron agrupadas en tres categorías, pequeña escala con menos de 5 hectáreas, mediana escala que va desde 5 hasta 50 hectáreas y las de gran escala mayores a 50 hectáreas; concluyen que el 80% de las pérdidas son a pequeña escala y los categorizados como eventos a gran escala representan una amenaza latente. Al mismo tiempo, el estudio ha identificado 8 patrones de deforestación en donde el avance de la minería aurífera ilegal es considerado como uno de los patrones

emergentes que actualmente amenaza a la Reserva Nacional Tambopata. De igual manera, la síntesis reporta que la minería aurífera es uno de los 6 drivers principales de deforestación y degradación de los bosques, identificado como el driver más crítico en el sur del país. Responsabiliza a esta actividad de la pérdida total de 62 500 ha en la Amazonía Sur peruana y enfatiza que su práctica reciente es ilegal y realizada en áreas de amortiguamiento de Áreas Naturales Protegidas. La síntesis resume y articula diferentes reportes generados por MAAP, de hecho, uno de los que resaltó en la síntesis es el reporte MAAP # 50, presentado por Finer et al. (2016a), el cual estima que la deforestación por minería aurífera al sur de la Amazonía peruana equivale a 12 503 ha entre octubre del 2012 y octubre del 2016, las áreas deforestadas afectaron principalmente a la región de Madre de Dios, sin embargo, también se extiende por Cusco y Puno. El resultado afirma que la mitad de la deforestación reciente (6 407 ha) ocurrió en la Reserva Nacional Tambopata, zonas de amortiguamiento del Parque Nacional Bahuaja-Sonnene y la Reserva Comunal Amarakaeri, además que la deforestación por esta actividad ha invadido las últimas dos áreas protegidas mencionadas anteriormente. Adicionalmente los resultados estiman una deforestación de 3 997 ha causadas por la minería aurífera área conocida como La Pampa al interior de la zona de amortiguamiento de la Reserva Nacional Tambopata, entre el mismo periodo de años de estudio, es decir entre afines del 2012 al 2016.

2.1.3 Alcance local

Díaz y Pardi (2009), en su análisis relacionan los datos obtenidos de la clasificación usando la clasificación de las bandas TM/Landsat 3, 4 y 5 y el modelo lineal de mezclas espectrales para cuantificar y ubicar las áreas deforestadas en Madre de Dios, en los distritos de Iñapari hasta Iberia.

Chávez et al. (2012), realizó un estudio de Áreas deforestadas entre los años 2008-2010 en la provincia del Tahuamanu, utilizando los programas ENVI 4.7®, Erdas Imagine 9.2®, CLASlite 2.2® y SPRING 5.1® con imágenes Landsat TM 5. Donde encontraron resultados diferentes para los diferentes programas, encontrando los siguientes resultados (tabla 2).

Tabla 2. Resultados con diferentes programas.

PR 3/68 Provincia Tahuamanu	CLASLITE®	SPRING®	ENVI SAM®	ERDAS IMAGINE®
Bosque (ha)	1 236 478,41	1 255 957,56	1 239 052,41	1 257 414,84
Área Deforestada (ha)	42 184,71	22 936,95	14 923,89	21 799,26

Fuente: Chávez *et al.* (2012).

Chavez (2013), en su estudio realizado entre los distritos de Iberia y Iñapari, menciona que las políticas públicas pueden llevar a la deforestación y la fragmentación de los bosques dependiendo de las políticas de uso de suelo que se pretenden promover. A su vez, las secuencias de distintos incentivos políticos pueden generar trayectorias no lineales en la deforestación y la fragmentación del hábitat.

Chavez (2014), En su estudio recoge el caso del Perú, donde los sucesivos gobiernos nacionales han promovido usos de la tierra muy diferentes. El estudio se realizó en Madre de Dios, una región fronteriza en el sureste de la Amazonía peruana, para evaluar la deforestación y fragmentación de 1986 a 2007, que abarca varios períodos de distintos gobiernos. Utilizo imágenes clasificadas de Landsat TM, ETM + y Aster en intervalos de 5 años entre 1986 y 2001, así como imágenes bianuales de 2001 a 2007 para observar trayectorias en bosques, cultivos y pastura, y rebrote. El análisis permite observar los cambios no lineales en las clases de cobertura del suelo, así como las métricas de fragmentación relacionadas con el tamaño, la densidad, la conectividad y la configuración de las clases de cobertura vegetal a lo largo del tiempo. Distintas políticas muestran diferentes trayectorias de deforestación y valores de fragmentación. Estos hallazgos tienen implicaciones para el estudio de las políticas públicas y la dinámica espaciotemporal de la cobertura de la tierra y ofrecen nuevas herramientas de monitoreo para entender la complejidad del cambio ambiental.

Chavez y Perz (2013), evalúa la importancia de la adopción voluntaria de los incentivos políticos ofrecidos por las políticas públicas peruanas durante dos décadas para el uso de la tierra entre los pequeños agricultores de la Amazonía peruana. El análisis se centra en si los agricultores adoptaron uno o más incentivos políticos para observar los efectos sobre los usos del suelo, incluyendo bosques maduros, cultivos agrícolas, pastizales y crecimiento secundario. Emplearon modelos estadísticos multivariados para estimar los efectos de la adopción de políticas mientras que se controlan otros factores. Los hallazgos muestran que políticas distintas están asociadas con usos de la tierra en particular y en gran parte siguen las expectativas. Especificar los incentivos políticos promulgados por los gobiernos y diferenciar entre los adoptantes y los no adoptantes. El área de estudio consiste en los predios agrícolas titulados a lo largo de la Carretera Interoceánica entre el distrito de Iberia y el distrito de Ñapari, que abarca un área de 2000 km² en la provincia de Tahuamanu

Chávez et al. (2013), reporta un estudio en el cambio de uso de suelo durante un período de 15 años de 1996 a 2011 en la Provincia de Tahuamanu, Madre de Dios. Utilizando varios años de observaciones de cambio de uso de suelo para relacionar los cambios en la cobertura de la tierra con el uso de recursos naturales (pastos, madera, cultivos y productos forestales) y los tipos de tenencia basados en sus distancias de la carretera y el río Tahuamanu.

Stephen et al. (2013), La globalización económica se manifiesta en los paisajes a través de iniciativas de integración regional que involucran infraestructura transfronteriza. Aunque las relaciones entre las carreteras, la accesibilidad y la cobertura de la tierra son bien comprendidas, rara vez se han considerado en las regiones fronterizas nacionales. Por lo tanto, se sigue un análisis de la conectividad de las infraestructuras y el cambio de la cubierta terrestre en la frontera trinacional del Amazonas suroccidental donde Bolivia, Brasil y Perú se encuentran donde se pavimentó la Carretera Interoceánica. Integraron datos de satélites, encuestas, clima y otros para una muestra de comunidades rurales que difieren en términos de

pavimentación de carreteras a través de la frontera trinacional. Utilizaron una serie de variables explicativas vinculadas a la pavimentación de carreteras y otros factores que varían tanto a través como en los tres lados de la frontera para modelar su importancia para la deforestación. Un análisis multivariado de la cobertura forestal no forestal durante 2005-2010 confirma la importancia del estado de pavimentación y los tiempos de viaje, así como la tenencia de la tierra y otros factores. Estos hallazgos indican que la integración afecta a la cobertura de la tierra, pero no elimina los efectos de otros factores que varían a través de la frontera, lo cual tiene implicaciones para el estudio de la globalización, y la infraestructura transfronteriza.

Alarcón et al. (2011), realizó un estudio de deforestación en el distrito de Inambari en los años 2000 – 2009, aplicando dos métodos; sin mejoramiento espectral; 6 931,541 ha deforestadas y con mejoramiento espectral – Índice de Vegetación de Diferencia Normalizada (NDVI); 7 641,50 ha y en la que asigna a la minería como mayor responsable de los cambios de bosque desprovista de vegetación.

Ríos et al. (2012), en su estudio Análisis y modelación de deforestación para los años 1990, 2000 y 2010, la deforestación se concentró en los lugares aledaños al centro poblado de Pillcopata y se extiende por los márgenes de la vía Pillcopata-Shintuya. Las actividades de los pobladores que originan la deforestación son agropecuarias y agrícolas. En cuanto al resultado del modelo prospectivo este reporto al año 2032 un área deforestada de 7 451,1 ha, zonas que se ubican cerca a los centros poblados, a lo largo de la carretera y en los márgenes de los ríos, Kosñipata, Pilcomayo, Madre de Dios Carbón, Sabaluyoc y Queros. Al analizar con los mapas de cobertura forestal de los años 1990, 2000 y 2010 se nota como la deforestación argumenta a los factores socioeconómicos del área de estudio.

Mendoza y Alarcón (2014), evaluaron la zona de amortiguamiento de la Reserva Nacional Tambopata y el Parque Nacional Bahuaja Sonene, ubicado en la Región de Madre de Dios. Siendo el objeto de estudio, identificar y cuantificar áreas deforestadas por tipo de actividad humana aplicando la Teledetección. Se trabajaron con las imágenes del sensor

Landsat con las escenas 002-069 con fecha 28/08/2011 y la escena 003-069 con fecha 03/09/2011 obtenidos gratuitamente del INPE. Las clases definidas a clasificar fueron Minería, Pastizales, Pastizales Remontados y Tumba. Para la clasificación se utilizó el algoritmo *Spectral Angle Mapper*, por tener ventaja en las condiciones de iluminación. Los resultados reportaron: minería 7 178,50 ha, pastizales 4 631,49 ha, pastizales remontados 9 113,22 ha y tumba 1 443,15 ha respectivamente. De ello, se asume que la acción antrópica generada por la actividad minera es la que viene causando mayores impactos severos a la cobertura boscosa e impactos sociales, debido a que en los últimos años, la extracción aurífera, se ha convertido en una fiebre por la sobrevalorización de la onza de este metal y por el impacto directo e indirecto de la construcción de la vía interoceánica. Así mismo con el objetivo de contribuir a la gestión de los recursos naturales y medio ambiente, se elaboró un mapa de áreas críticas de acción antrópica, donde se tiene 3 zonas (I, II y III); siendo la zona I la más intervenida por la actividad minera, debido al grado de deterioro ambiental.

Alarcón et al. (2016), determina el área deforestada, en la parte suroeste de Puerto Maldonado – Inambari, fueron procesadas las imágenes landsat 8 OLI y landsat TM 5, utilizando la clasificación denominada “Random Forest” propuesto por la mesa de servicios ambientales y reducción de emisiones de gases de efecto invernadero. Los cambios en el área de estudio, indica a la minería aurífera aluvial como la mayor causante seguido por el asfaltado de la carretera interoceánica y por el alza del metal como el principal causante de la deforestación.

2.2 Marco teórico

2.2.1 Deforestación

La FAO (2005) define la deforestación “como la transformación del bosque en otros usos de la tierra o a la reducción de la cubierta de la copa por debajo del umbral mínimo de 10%”. Además, considera que la deforestación

y la quema son principales causantes de las emisiones de los GEI, donde predomina el CO₂, sin embargo, el proceso de descomposición orgánica genera también CH₄ (metano) gas que es 21 veces más nocivo que el CO₂ aunque es generado en bajas concentraciones (FAO 2016).

La UNFCCC (2001) citado por Achard et al. (2007) define a la deforestación como “La conversión directa, inducida por el hombre de tierras forestales a tierras no forestales”.

2.2.2 Bosque

En el Protocolo de Kioto, señala que el bosque es la “superficie mínima de tierras de 0,05 y 1,0 hectáreas, y cuenta con una cubierta coposa entre 10% y 30% y con árboles que pueden alcanzar una altura mínima in situ de 2 hasta 5 metros a su madurez” (UNFCCC 2001).

Pacheco et al. (2011), definió que la “superficie mínima de bosque 1 ha, altura mínima de cubierta 2 m y cobertura mínima de copa de 10%”.

Los bosques cumplen una valiosa función reguladora clave en “todos los procesos vinculados con el ambiente, suelo, aire, agua, clima, paisaje y con la vida en general” (FAO 2016).

2.2.3 Principios y Fundamentos de Teledetección

La teledetección es una “técnica que permite obtener información digital de los objetos situados sobre la superficie terrestre, sin necesidad de tener contacto directo con ellos; para esto, es preciso que entre los objetos y el sensor exista algún tipo de interacción, tal como, el flujo energético proveniente de la energía emitida por el propio sensor; o bien, la reflexión de la luz solar en la superficie terrestre”. De esta forma, es posible adquirir información de las cubiertas u objetos por medio de reflexión, emisión o por emisión-reflexión (Chuvienco 2008).

La Teledetección (*Remote Sensing*) se define como la “ciencia y arte de obtención de información acerca de un objeto, área, o fenómeno a través del análisis de información adquirida por un dispositivo que no está en contacto el objeto, área, o fenómeno bajo investigación” (Lillesand y Kiefer 1994).

Un sensor remoto se define como un “instrumento especial cuya tecnología permite la obtención de información de objetos sin estar físicamente en contacto con él. Estos instrumentos se conocen en conjunto como Sensores Remotos incluyendo aparatos como la cámara fotográfica, sistemas scanners y de radar” (Avery y Berlin 1992). En general los procesos y elementos involucrados en la teledetección electromagnética de los recursos terrestres se pueden separar en dos procesos básicos; la adquisición de información y el análisis de la información. El proceso de análisis de los datos involucra la aplicación de varios medios de interpretación para compilarla en forma de tablas o como archivos computacionales que pueden ser unidos a un SIG. Por último esta información es utilizada en la toma de decisiones de distintos usuarios (Lillesand y Kiefer 1994).

Cualquier sistema de teledetección “consta de tres elementos fundamentales; el sensor, el objeto observado y un flujo energético que permita poner a ambos en relación; este flujo de energía puede proceder del objeto por reflexión de la luz solar, por algún tipo de energía emitida por el propio objeto, o incluso por el sensor” (Padilla et al. 2015).

2.2.4 Espectro Electromagnético

“El flujo de energía necesario entre el sensor y el objeto observado, en un sistema de teledetección, constituye una forma de radiación electromagnética” (Padilla et al. 2015).

Esta energía electromagnética es una forma dinámica de energía que es causada por la oscilación o aceleración de una carga eléctrica, de este modo, todas las sustancias naturales o sintéticas continuamente producen o emiten un rango de energía electromagnética en proporción a su temperatura (Avery y Berlin 1992).

Toda energía térmica puede ser transferida mediante tres procesos: “convección, conducción y radiación, siendo esta última la base de la mayoría de los sistemas de teledetección” (Chuvienco y Salas 1996). Así, la radiación es el método por el cual la energía puede ser transferida desde un cuerpo a otro en ausencia de algún material intermediario. Si esta

intervención se hace presente, debe ser lo suficientemente transparente de modo de que la energía sea transferida. La radiación es el único método por el cual la energía solar puede recorrer millones de kilómetros a través del espacio y alcanzar la tierra. Este es el método de transferencia de energía con el cual se concibe un sensor remoto (Avery y Berlin 1992; Padilla et al. 2015).

Las propiedades de la radiación electromagnéticas han sido explicadas por dos teorías: “la teoría ondulatoria que la concibe como un haz ondulatorio, y la teoría cuántica que considera la radiación electromagnética como una sucesión de unidades discretas de energía, fotones o cuantos, con masa igual a cero. Según la teoría ondulatoria, la energía electromagnética se transmite de un lugar a otro siguiendo un modelo armónico y continuo, a la velocidad de la luz y conteniendo dos campos de fuerzas, uno eléctrico y otro magnético” (Padilla et al. 2015).

Las características espectrales que presentan las distintas superficies terrestres, que son motivo de investigación por distintas disciplinas, permiten reconocer ciertas bandas del espectro electromagnético que son las comúnmente utilizadas por las actuales aplicaciones de las técnicas de teledetección y que entregan las principales plataformas satelitales (Padilla et al. 2015).

La “Reflectancia de un objeto o tipo de cubierta a lo largo de todo el espectro electromagnético se denomina firma espectral, estando caracterizado cada objeto por una firma espectral concreta, que lo distingue de los demás”. (Chuvieco 1996, 2010; Jensen 2009).

2.2.5 Aplicación de la Imagen Satelital

Las imágenes satelitales se han usado por agencias gubernamentales, industriales, civiles, y comunidades educacionales en el mundo. Estos datos han sido usados en apoyo a un amplio rango de aplicaciones en áreas como el cambio global de los recursos, la agricultura, masas boscosas, geología, manejo de los recursos, geografía, cartografía, calidad del agua, y oceanografía. En este sentido se puede señalar la identificación y asociación

de suelos y cartografía, el análisis de la cobertura y producción forrajera, clasificaciones regionales de uso de suelo y generación de foto-mapas, exploración minera y de petróleo, monitoreo de la polución, cartografía e interpretación geológica, mediciones de la magnitud de nieve, monitoreo del movimiento de glaciales, detección de la erosión de playas, detección del grado de estrés en asociaciones vegetales, clasificación de la cobertura vegetal, y monitoreo de incendios forestales. Esto señala el alto potencial de la aplicación de esta información en el monitoreo de las condiciones de la superficie terrestre (Coronado-Chacón 2001).

El mayor uso que se le da a las imágenes satelitales es la “capacidad de monitorear los cambios de uso del suelo en el tiempo, debido que se cuenta con una base de datos digitales de cambio de uso de suelo donde pueden ser observadas y estudiadas. (Aide et al. 2013).

Los datos satelitales pueden ser útiles para concentrarse en las áreas en donde se requiere información. Como primer paso, se monitorean grandes áreas en orden a detectar las áreas en donde ocurrieron los cambios. Luego, los datos de alta resolución son utilizados para la revisión y actualización en áreas en donde los cambios detectados han sido significantes. Los datos apropiados en el primer paso podrían ser, por ejemplo, imágenes de gran cobertura y resolución de 20-30 metros (Aide et al. 2013).

2.2.6 Beneficios de la Utilización de Observaciones Remotas

Algunos de los beneficios obtenidos al utilizar observaciones remotas son los siguientes (Chuvieco 2002):

- ✓ Monitoreo de grandes extensiones en forma rápida, precisa, económica y homogénea.
- ✓ Es posible una rápida apreciación global de la situación, haciendo posible la medición del riesgo y el daño de la polución, enfermedades y ataques de incendios.
- ✓ Proporciona información de regiones remotas o áreas de difícil acceso.
- ✓ En áreas en donde la cobertura de nubes es persistente, los datos de radar proporcionan información consistente del recurso bosque.
- ✓ Incremento de la objetividad, velocidad de repetición y eficiencia en sus

aplicaciones.

- ✓ Formato digital que permite la interpretación automática.
- ✓ Mediciones normalizadas y controladas tanto en el tiempo como en el espacio.

2.2.7 Tratamiento Digital de Imágenes Satelitales Multitemporales

Este tratamiento se conoce en la literatura como “*Image Preprocessing*” y “está destinado a corregir los errores derivados del proceso de adquisición de la información y que puede degradar la calidad de los datos recogidos por el sensor” (Elijah y Jensen 1996).

Cuando la detección de cambios se realiza comparando, píxel a píxel, los Niveles Digitales (ND) de las distintas imágenes es necesario eliminar previamente todo tipo de cambio en los ND de la imagen que no sea debido a cambios reales en la superficie. Esto requiere un ajuste con precisión, tanto radiométrica, como geoméricamente, las imágenes que intervienen en el análisis (Chuvienco 2002).

2.2.7.1 Corrección Geométrica

Las imágenes satelitales tienen errores geoméricos de origen sistemático y no sistemático; entre las causas de errores geoméricos de origen sistemático se puede mencionar la velocidad de la plataforma y la rotación de la tierra, además, las distorsiones de origen no sistemático incluyen la posición del sensor y los errores producto de la altitud (Elijah y Jensen 1996).

a) Rectificación imagen a imagen

Es el proceso de traslación y rotación por medio de dos imágenes de igual geometría y de la misma zona geográfica son posicionadas una respecto de la otra de manera que los elementos correspondientes aparezcan en el mismo lugar en las imágenes corregidas (Elijah y Jensen 1996). Este tipo de corrección se utiliza cuando no es necesario tener asignado a cada píxel una única coordenada x, y en una proyección ortogonal, por ejemplo al comparar visualmente dos

imágenes de distinta fecha para detectar los cambios producidos en la zona de interés (Jensen et al. 1991).

b) Rectificación imagen a mapa

Es el proceso por el cual la geometría de una imagen se hace planimétrica. Este es el proceso a aplicar si se requiere precisión en las mediciones de área, dirección y distancia. Sin embargo, no todas las distorsiones causadas por la topografía de la imagen pueden ser removidas. Este proceso normalmente utiliza puntos de control terrestre a través de los cuales realizar la rectificación. Esta operación se realiza por medio de dos operaciones: (1) la interpolación espacial que establece la naturaleza de la transformación de las coordenadas geométricas para así ubicar los píxeles originales a su posición en la imagen rectificadas y (2) la intensidad de interpolación que es la aplicación de algún mecanismo a través del cual determinar el valor de brillo asignado al píxel rectificado (Chuvieco 2002; Chuvieco y Salas 1996; Jensen, Lin, Yang, Ramsey III, Davis y Thoemke 1991).

2.2.7.2 Calibración Radiométrica

Idealmente, el flujo de radiación recogido por un sensor remoto, en varias bandas, es una representación precisa del flujo de radiación de las características de la superficie terrestre. Desafortunadamente esto no ocurre y pueden ingresar errores al sistema de colección de información de varias maneras. Por ejemplo, errores radiométricos en los datos percibidos pueden ser introducidos por el mismo sensor remoto cuando los detectores individuales no funcionan apropiadamente o son inapropiadamente calibrados (Chuvieco 2002; Elijah y Jensen 1996). Por otro lado la intervención atmosférica entre el terreno de interés y el sensor remoto pueden contribuir con tanto ruido (error) que la energía recibida por el sensor no se parece a lo que fue reflejado o emitido por el terreno (Elijah y Jensen 1996).

2.2.7.3 Calibración Absoluta

La radiación solar es selectivamente difundida y absorbida al entrar en contacto con la atmósfera terrestre. La energía emanada desde el cielo y recibida por el sensor es un indicador verdadero aun cuando se destruya nuestra habilidad para medir la reflectancia espectral de los patrones del terreno. De hecho, los científicos pueden considerar a la difusión y absorción atmosférica de la energía como el verdadero indicador y a la energía reflejada desde la tierra como el origen del ruido o error. No obstante, muchos de los analistas de la tierra consideran nocivo el efecto de la difusión y absorción atmosférica como fuente de error que puede minimizar la habilidad para extraer información útil del terreno desde datos obtenidos por sensores remotos (Elijah y Jensen 1996; Salinero et al. 2006).

2.2.7.4 Calibración Relativa

La corrección radiométrica relativa puede ser utilizada para normalizar las intensidades entre las diferentes bandas dentro de una escena (por ejemplo para remover la respuesta errónea del sensor, líneas abandonadas o rayados) y, para normalizar las intensidades de las bandas de los datos de una de la imagen en una fecha y estandarizarla a la escena escogida en el análisis. La corrección radiométrica relativa generalmente no requiere reunir mediciones atmosféricas en el tiempo de adquisición de la información, que son muy difíciles de obtener cuando se utiliza información histórica de un sensor remoto (Salinero, Salinero, Viola, Maclean, Goodman, Krynine y William 2006).

2.2.7.5 Corrección Atmosférica

La corrección atmosférica busca recuperar la radiancia intrínseca del objeto de estudio, obtenida de la señal recibida por el sensor. Para ello se requiere: 1) convertir los ND de cada banda a valores de radiancia (L), 2) la radiancia se transforma a valores de reflectividad en el techo de la atmósfera "Top of Atmosphere" (TOA) y 3) se obtiene mediante FLAASH la conversión a valores de reflectancia (Kruse 2004).

2.2.7.6 Mejoramiento Espectral

Ciertos estudios mencionan que para el mejoramiento espectral se tienen que usar técnicas que ayuden a desarrollar la disposición de la información satelital para su posterior análisis cuantitativo.

✓ **Análisis de Componentes Principales (ACP)**

Pla (1986), señala que el “análisis de componentes principales es un método que permite la estructuración de un conjunto de datos multivariados obtenidos de una población, cuya distribución de probabilidades no necesita ser conocida, siendo los objetivos más importantes de su aplicación los que se mencionan a continuación”:

1. Crear nuevas variables que ayuden a revelar los datos contenidos en el grupo original de datos.
2. Disminuir la dimensionalidad del problema que se está investigando, como paso previo hacia futuros análisis.
3. Quitar, en lo posible, algunas de las variables originales si aportan poca información.

El Análisis de Principales Componentes (ACP) es una “transformación de los datos crudos del sensor remoto que entrega como resultado nuevas imágenes de componentes principales que son más interpretables que los datos originales” (Singh y Harrison 1985). El análisis de ACP se puede usar para comprimir la información contenida en las bandas de una imagen satelital en dos o tres imágenes modificadas de originales componentes. (Elijah y Jensen 1996).

✓ **Índices**

Es una alternativa para la medición de la vegetación y su estado sanitario basado en el análisis de la información espectral de los sensores remotos (Goel y Norman 1992).

“Es así como la vegetación verde saludable, en la región del infrarrojo cercano del espectro, refleja una mayor cantidad de energía que la vegetación senescente o que los suelos secos y desnudos,

presentado un comportamiento inverso en la región visible del espectro” (Goel y Norman 1992).

2.2.7.7 Clasificación Digital

Es el proceso mediante el cual “los píxeles de una imagen satelital multibanda son etiquetados según la categoría a la que pertenecen; a partir de esta imagen puede generarse una cartografía temática y el inventario estadístico de la superficie involucrada en cada categoría” (Chuvieco y Salas 1996; Pla 1986).

La clasificación digital distingue las siguientes fases: “1) definición digital de las categorías (fase de entrenamiento), 2) agrupación de los píxeles en una de esas categorías (fase de asignación), y 3) comprobación y verificación de resultados” (Chuvieco y Salas 1996).

✓ Fase de entrenamiento.

La clasificación digital comienza con la definición de las categorías que se pretenden distinguir en la imagen. “Se trata de una clasificación basada en los valores numéricos, por lo tanto se trata de obtener el rango de ND que identifica a cada categoría para todas las bandas que intervienen en la clasificación; existe una cierta dispersión en torno al ND medio de cada categoría” (Chuvieco y Salas 1996). Por esto la fase de entrenamiento “trata de definir con rigor cada una de las categorías que se pretenden distinguir teniendo en cuenta su dispersión en la zona de estudio” (Chuvieco y Salas 1996). Entre los métodos tenemos:

1) Método supervisado; “este método de entrenamiento requiere un cierto conocimiento de la zona de estudio que permite delimitar sobre la imagen unas zonas o áreas representativas de las distintas categorías que se pretenden discriminar” (Chuvieco y Salas 1996).

2) Método no supervisado; “este método asume que los ND de la imagen se agrupan en una serie de conglomerados (o clúster) que se corresponden con grupos de píxeles con un comportamiento espectral homogéneo y que, por ello, deberían definir unas clases

informativos de interés” (Chuvieco y Salas 1996) .

✓ **Fase de asignación**

En esta etapa se evalúa los principales algoritmos de clasificación. “Desde un punto de vista estadístico, todos los algoritmos definen un área de dominio de cada clase en torno a su centro mediante un conjunto de funciones; un determinado píxel será asignado a una clase si sus ND se encuentran dentro de los límites establecidos para dicha clase” (Chuvieco y Salas 1996; Elijah y Jensen 1996).

2.2.7.8 Técnicas de Post-clasificación

La efectividad de esta alternativa depende de cómo se diferencian espectralmente las categorías clasificadas. En ocasiones esta clasificación puede ser complicada, y si se utilizan todas las bandas de cada fecha, se puede tener información redundante (Means et al. 1999).

La Post-clasificación es el método cuantitativo de detección más comúnmente utilizado. Requiere de la rectificación y clasificación de cada imagen, para luego ser comparados píxel a píxel a través de una matriz. Desafortunadamente, los errores en la clasificación individual de cada imagen se ven reflejados clasificación final (Argany y Saradjian ; Yagoub et al. 2015). Por ello es necesario que la clasificación individual de las imágenes sea lo más exacto como sea posible (Müller y Brandl 2009).

2.2.8 Diseño de muestreo

El diseño de muestreo tiene que permitir realizar estimaciones estadísticas a partir de las muestras, ser sencillo de implementar y analizar.

2.2.8.1 Las unidades de muestreo

La unidad de muestreo “permite relacionar la localización de la información del mapa y del terreno. Puede ser un punto, un píxel, un grupo de píxeles, un polígono del mapa o una unidad de superficie con formas predeterminadas, por ejemplo, un cuadro o un círculo de una hectárea”; no existe un consenso definitivo sobre la unidad de muestreo más adecuada

(Boca y Rodríguez 2012; Chuvieco 1996; Chuvieco y Salas 1996; François-Mas et al. 2003); su elección depende en mucho de los objetivos de la evaluación, del proceso de mapeo, de la estructura del paisaje y de las categorías que más le interesan al usuario. Si la unidad de muestreo “es un punto, se compara la clasificación del mapa con relación a este punto con la misma localización en el terreno; en la práctica, lo que se evalúa es una superficie alrededor del punto” (Van der Wel et al. 1998).

2.2.8.2 El método de muestreo

“Sirve para seleccionar una pequeña muestra del área cartografiada, de tal forma que sea representativa de la totalidad del mapa; en un diseño de muestreo probabilista, todas las unidades de muestreo presentes en el mapa tienen una probabilidad conocida superior a cero de ser seleccionadas, a esta probabilidad de selección se le denomina probabilidad de inclusión. (Boca y Rodríguez 2012; François-Mas, Reyes Díaz-Gallegos y Pérez-Vega 2003). Las técnicas de muestreo más utilizadas en el análisis de la confiabilidad temática son: aleatorio simple, aleatorio estratificado, sistemático, sistemático no alineado y por conglomerados (figura 1 y 2).

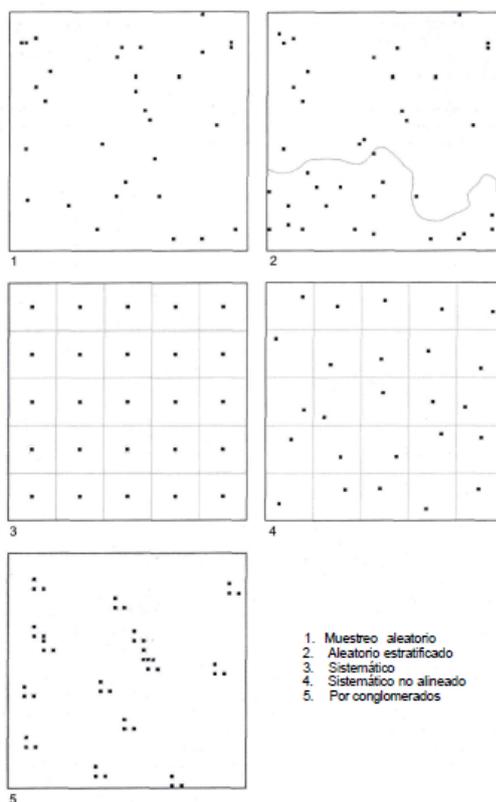


Figura 1. Cuadro de probabilidades de muestreo más usado en la estimación de la confiabilidad de mapas temáticos.

Fuente: Modificado de Chuvieco y Salas (1996).

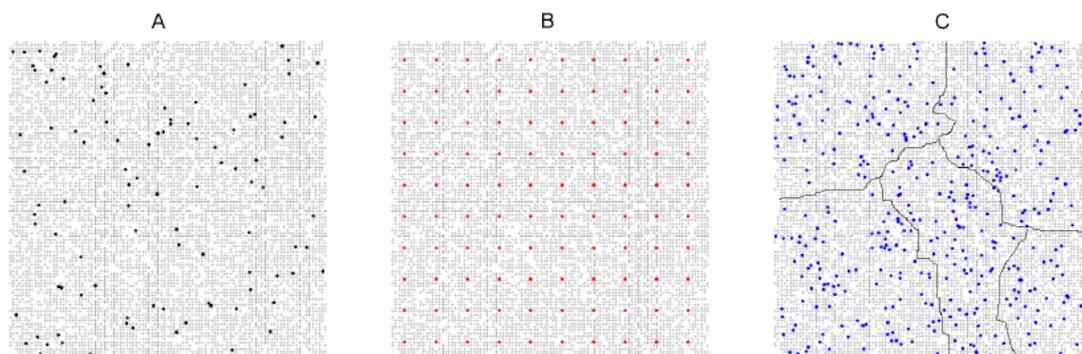


Figura 2. Distribución espacial de las observaciones bajo un muestreo aleatorio A: simple; B: sistemático y C: estratificado.

Fuente: (Boca y Rodríguez 2012).

Aleatorio simple. “Los sitios de verificación se eligen de tal forma, que todos tienen la misma probabilidad de ser seleccionados; esta selección genera sitios de muestreo dispersos en todo el territorio, lo que implica asumir los costos de traslado” (Boca y Rodríguez 2012; Congalton 1988;

Fitzpatrick-Lins 1981; François-Mas, Reyes Díaz-Gallegos y Pérez-Vega 2003).

Aleatorio estratificado. “La muestra se realiza dividiendo a la población en estratos, con base en una variable auxiliar (altitud, región ecológica, división administrativa, facilidad de acceso, clase en el mapa, entre otros), lo que permite tener cierto control sobre la distribución de los sitios de muestreo y obtener información sobre subconjuntos de la población” (Boca y Rodríguez 2012; François-Mas, Reyes Díaz-Gallegos y Pérez-Vega 2003).

Sistemático. “La muestra se distribuye a intervalos regulares a partir de un punto seleccionado de manera aleatoria, pero puede originar algún error cuando existe algún patrón periódico en el área estudiada” (Boca y Rodríguez 2012; Chuvieco 1996; François-Mas, Reyes Díaz-Gallegos y Pérez-Vega 2003).

Sistemático no alineado. “La muestra se distribuye de manera regular, pero con un cierto grado de libertad y permite representar todo el territorio” (Boca y Rodríguez 2012; François-Mas, Reyes Díaz-Gallegos y Pérez-Vega 2003).

Por conglomerados. “Se selecciona un sitio aleatoriamente y se toman varias muestras vecinas de acuerdo con un esquema predeterminado” (Boca y Rodríguez 2012; François-Mas, Reyes Díaz-Gallegos y Pérez-Vega 2003).

“Los muestreos aleatorios simples, sistemático, sistemático no alineado y por conglomerados son probabilistas y resultan en probabilidades de inclusión, iguales para todas las unidades de muestreo; los muestreos estratificados, como el estratificado aleatorio, con un número igual de unidades de muestreo por estrato, conducen a probabilidades de inclusión diferentes según el estrato” (Boca y Rodríguez 2012; François-Mas, Reyes Díaz-Gallegos y Pérez-Vega 2003; Stehman 2000).

“Estudios comparativos de estos diferentes esquemas de muestreo pueden encontrarse en” (Congalton 1988; Fitzpatrick-Lins 1981; Stehman 2000).

“Existen numerosos ejemplos de diseños sesgados que no se pueden considerar como estadísticamente robustos, debido a que la muestra no es representativa del conjunto del mapa; por ejemplo, la selección de sitios de

verificación ubicados en el centro de los polígonos de los mapas conduce a una evaluación optimista de la confiabilidad del mapa, ya que los errores son más frecuentes en las zonas de transición entre diferentes tipos de cobertura (Hammond y Verbyla 1996). Otro ejemplo de evaluación sesgada, “es la utilización de los campos de entrenamiento o de píxeles correlacionados con estos campos para evaluar la confiabilidad de clasificaciones digitales” (Boca y Rodríguez 2012; François-Mas, Reyes Díaz-Gallegos y Pérez-Vega 2003; Stehman y Czaplewski 1998).

2.2.8.3 El tamaño de muestra

El tamaño de la muestra se refiere al número de sitios de verificación utilizados para estimar la confiabilidad del mapa. Entre más grande sea el tamaño de la muestra, más precisa será la evaluación; sin embargo, por razones de costo y tiempo, es conveniente determinar el tamaño de muestra mínimo, para alcanzar los objetivos de la evaluación. Congalton (1988), “sugiere muestrear una superficie aproximada al 1% de la superficie cartografiada”. En otra publicación Congalton (1991) recomienda verificar por lo menos 50 sitios por categoría, y de 75 a 100 si el área en estudio es superior a 400 000 ha o si hay más de 12 categorías. En estadística tradicional la desviación estándar de la estimación de una proporción depende del tamaño de la muestra, del tamaño de la población estudiada y de la proporción (Stehman 2000; Wonnacott y Wonnacott 1991) (ecuación 1).

$$q = \sqrt{\frac{N-n}{N}} \sqrt{\frac{p(1-p)}{n}} \quad (1)$$

Donde q es la desviación estándar de la estimación de la confiabilidad, N tamaño de la población, n tamaño de la muestra y p la confiabilidad de la muestra.

“Se grafica el tamaño de la muestra n en función del tamaño de la población N con base en la ecuación (1) para el caso en el cual la confiabilidad p es de 0,5 (la mitad de los sitios de verificación está correctamente identificada en

el mapa) y la desviación estándar es de 0,05” (Stehman 2000; Wonnacott y Wonnacott 1991) (figura 3).

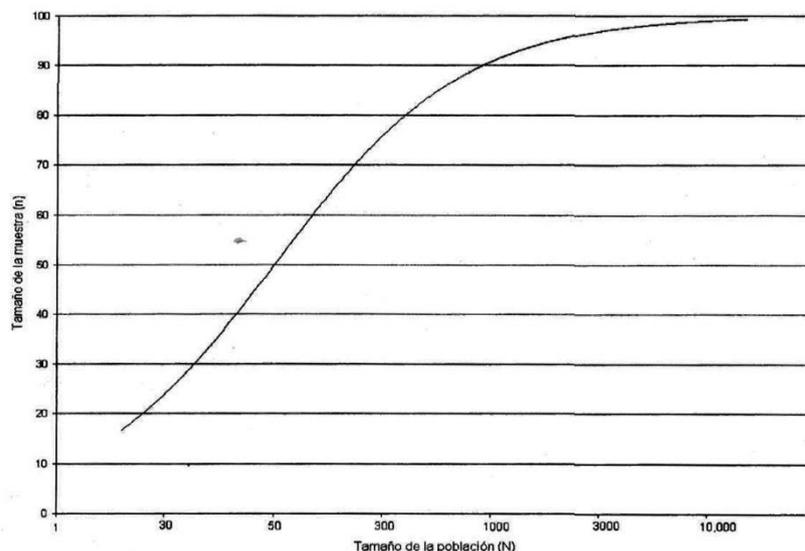


Figura 3. Tamaño de muestra necesario para alcanzar un error estándar de 0,05 en función del tamaño de la población. El tamaño de la población está representado en escala logarítmica $\log_{10}(N)$.

Fuente: Stehman (2000).

2.2.8.4 Análisis de los datos

El análisis de los datos de confiabilidad normalmente se hace a través de una matriz de confusión, las filas representan normalmente las clases de referencia y las columnas las clases del mapa. “El error de comisión representa la proporción de sitios de verificación cartografía da en una cierta clase, pero que en realidad pertenece a otra categoría y el error de omisión se refiere a la proporción de sitios de verificación correspondiente a una categoría que fue cartografiada en otra” (Aronoff 1982; Chuvieco 1996; François-Mas, Reyes Díaz-Gallegos y Pérez-Vega 2003).

Congalton (1991), recomienda realizar una estandarización de la matriz de confusión. “Ésta se realiza llevando a cabo un ajuste iterativo para que las columnas y las filas de la matriz sumen 1 y argumenta que esta

normalización permite ajustar los valores de la matriz tomando en cuenta las filas y las columnas”.

(Boca y Rodríguez 2012; François-Mas, Reyes Díaz-Gallegos y Pérez-Vega 2003; Stehman 1997; Stehman y Czaplewski 1998), está en desacuerdo con esta estandarización, porque no permite obtener estimaciones consistentes.

Stehman (1997), demuestra que las estimaciones de confiabilidad derivadas de una matriz normalizada no son consistentes con las derivadas de una matriz basada en toda la población y sugiere no usar matrices estandarizadas.

Con base en la matriz de confusión, se desarrollaron varios índices de confiabilidad (Stehman y Czaplewski 1998) que se mencionan a continuación:

En el muestreo aleatorio estratificado, la cantidad de sitios por categoría no es proporcional a la cubierta de la superficie por cada categoría y el valor obtenido no se puede interpretar de esta forma (Boca y Rodríguez 2012; Card 1982; François-Mas, Reyes Díaz-Gallegos y Pérez-Vega 2003).

“Existen índices que dan cuenta de la confiabilidad de cada una de las clases de la leyenda como: *a)* la confiabilidad del usuario, que puede interpretarse como la probabilidad que un sitio clasificado como *A* y aleatoriamente seleccionado sea realmente *A* en el terreno, y *b)* la confiabilidad del productor, que es la proporción de sitios de verificación de la clase *A* que están representados en el mapa o en la base de datos como tal” (Van der Wel, Van der Gaag y Gorte 1998).

Aronoff (1982), “define el riesgo del productor como el hecho de rechazar un mapa aceptable y el riesgo del usuario, aceptar un mapa no confiable”.

Los índices de confiabilidad mencionados antes no consideran a los elementos fuera de la diagonal de la matriz (Boca y Rodríguez 2012; François-Mas, Reyes Díaz-Gallegos y Pérez-Vega 2003; Rosenfield y Fitzpatrick-Lins 1986). Por este motivo, se diversificó el uso del coeficiente de Kappa. Para los cálculos se describen a continuación (tabla 3).

Tabla 3. Matriz de confusión expresada en proporción.

Referencia	Mapa				Total
	1	2	...	q	
1	P_{11}	P_{12}	...	P_{1q}	P_{1+}
2	P_{21}	P_{22}	...	P_{2q}	P_{2+}
...
q	P_{q1}	P_{q2}	...	P_{qq}	P_{q+}
Total	P_{+1}	P_{+2}	...	P_{+q}	

Fuente: (Cerde y Villarroel 2008; Landis y Koch 1977).

Las anotaciones se utilizan en las siguientes ecuaciones:

$$K = \frac{P_0 - P_c}{1 - P_c} \quad (2)$$

Donde K es el índice de Kappa, P_0 la proporción de área correctamente clasificada y P_c la confiabilidad resultante del azar.

P_0 se obtiene al sumar los elementos de la diagonal:

$$P_0 = \sum_{k=1}^q p_{kk} \quad (3)$$

P_c se obtiene al sumar el producto de las sumas marginales:

$$P_c = \sum_{k=1}^q p_k + p_{+k} \quad (4)$$

El índice de Kappa se calcula para todas las categorías, con base en las columnas o en las filas de la matriz.

El índice de Kappa para la fila /se obtiene según;

$$K_l = \frac{p_{ii} - p_i + p_{+i}}{p_{i+} - p_i + p_{+i}} \quad (5)$$

El índice de Kappa para la columna; se obtiene según:

$$K_j = \frac{p_{jj} - p_j + p_{+j}}{p_{j+} - p_j + p_{+j}} \quad (6)$$

En la tabla 3 se muestra la matriz expresada en proporción y los valores de estos índices de confiabilidad hallados a partir del coeficiente de Kappa presentada en la tabla 4.

Tabla 4. Valor del índice de kappa.

Coeficiente Kappa	Fuerza de la Concordancia
0,00	Pobre
0,01 – 0,20	Leve
0,21 – 0,40	Aceptable
0,41 – 0,60	Moderada
0,61 – 0,80	Considerable
0,81 – 1,00	Casi perfecta

Fuente:(Cerde y Villarroel 2008; Landis y Koch 1977).

2.2.9 Programa Landsat

El programa Landsat ha revolucionado la forma de ver y estudiar nuestro planeta. Esta serie de datos, que se inició en 1972, es la más larga de la historia y continua registrando los cambios en la superficie terrestre desde el espacio.

“En la actualidad el programa se encuentra en su octava versión denominada: “Landsat Data Continuity Mission” (LDCM) es el octavo satélite

de observación de la serie Landsat y continuará el legado de archivo de los anteriores satélites, convirtiéndose de esta manera en el futuro de los satélites de observación de la tierra de mediana resolución con más historia. Este programa amplía, mejora y avanza en el registro de imágenes multispectrales, manteniendo la misma calidad de sus siete predecesores; tras el lanzamiento, el satélite LDCM será rebautizado como Landsat 8” (Ariza 2013).

“La plataforma LDCM, fue construida por la empresa Orbital Sciences Corporation en Gilbert, Arizona, tiene una vida útil de 5 años, pero lleva suficiente combustible para 10 años de operaciones. La nave orbitará de norte a al sur durante el día, cruzando el ecuador a las 10 a.m., hora local, con una órbita aproximada de unas 438 millas (705 kilómetros) por encima de la Tierra” (Ariza 2013).

“El satélite Landsat 8 incorpora dos instrumentos de barrido: Operational Land Imager (OLI), y un sensor térmico infrarrojo llamado Thermal Infrared Sensor (TIRS). Las bandas espectrales del sensor OLI, aunque similares a el sensor Landsat 7 ETM +, proporcionan una mejora de los instrumentos de las misiones Landsat anteriores, debido a la incorporación de dos nuevas bandas espectrales: un canal profundo en el azul visible (banda 1), diseñado específicamente para los recursos hídricos e investigación en zonas costeras, y un nuevo canal infrarrojo (banda 9) para la detección de nubes cirrus. Adicionalmente una nueva banda de control de calidad se incluye con cada producto de datos generado” (Ariza 2013). “Esto proporciona información más detallada sobre la presencia de características tales como las nubes, agua y nieve; por otra parte el sensor TIRS recoge dos bandas espectrales en longitudes de onda incluidas por la misma banda en los anteriores sensores TM y ETM+” (Ariza 2013).

2.2.10 Modelación del cambio de Cobertura del suelo – teoría y técnicas

Dos aproximaciones prevalecen en la modelación de patrones espaciales de los cambios de uso del suelo: (a) Modelos basados en regresión, y (b) Modelos en base a transición espacial.

“Los primeros establecen relaciones entre un amplio rango de variables predictivas y las probabilidades de cambio de cobertura del suelo (CCS); debido a la naturaleza espacial de muchas de las variables de entrada, la integración con los Sistemas de Información Geográfica (SIG) es esencial ya que permite un manejo y análisis espacialmente explícito de los datos asociados al modelo” (Qi y Wu 1996). Por tanto “la modelación estadístico-espacial del cambio de cobertura del suelo (CCS), se deriva de la combinación y uso de técnicas cartográficas, sistemas de información geográfica y modelos estadísticos multivariantes; su objetivo principal es identificar la magnitud y distribución espacial del cambio, proyectar y desplegar cartográficamente su probabilidad de ocurrencia en el futuro cercano, bajo el supuesto que las técnicas de manejo del suelo continuarán siendo similares al pasado cercano” (Sandoval y Oyarzun 2004).

Además, los diseños basados en transición espacial incluyen a las técnicas estocásticas Automatas Celulares (AC) y en el método de Cadenas de Markov (Pontius y Malanson 2005; Zhou y Liebhold 1995). Estos modelos indican indirectamente que las áreas colindantes afectan en la probabilidad de transición del área central. Los AC “incorporan reglas simples acerca de los efectos de adyacencia espacial que gobiernan la dinámica del sistema y que dan lugar a patrones de comportamientos emergentes que son usualmente más complejos que aquellos generados por simples modelos de equilibrio” (Henríquez y Azócar 2006).

2.2.11 Algunos Modelos y Software Utilizados para el CCS

✓ CA_Markov

Se fundamenta en las cadenas de Markov sugerido por el matemático ruso Andrei Markov en 1907. “Estos modelos (también llamados markovianos) se hicieron espacialmente explícitos cerca del año 1990, cuando empezaron a integrar el componente de autómatas celulares permitiendo que la probabilidad de transición de un pixel esté en función de los pixeles vecinos” (Cabral y Zamyatin 2006).

De esta manera, el módulo CA_Markov de Idrisi o TerrSet ayuda a realizar predicciones del uso del suelo teniendo en cuenta la proximidad espacial, “la probabilidad de presencia de las coberturas (EMC y/o Regresión Logística) y la probabilidad de transición de las coberturas de un estado a otro en diferentes épocas” (Sang et al. 2011).

Posteriormente, se indica con mucho mas detalle como funcionan las *cadena de markov* que se utilizarón para realizar las matrices de áreas de transición, “la *regresión logística* que sirvió para elaborar los mapas de idoneidad y las reglas de *autómatas celulares* que usa el modelo también” (Sang, Zhang, Yang, Zhu y Yun 2011).

✓ **GEOMOD**

Este modelo también se encuentra en el software IDRISI ahora TerrSet. “Geomod es un modelo más simple y más reciente, que usa cantidades (de área o pixeles que van a cambiar) especificadas por el operador (en lugar de la matriz de transición de markov) y un mapa de idoneidad (probabilidad de presencia) para simular el cambio de una sola categoría a otra usando una relación lineal entre los periodos de tiempo del inicio y el final” (Cabral y Zamyatin 2006). Geomod reconoce la permanencia de algún cambio que se está diseñando, por ejemplo, si un pixel está catalogado como actividades antrópicas en 1990 se mantendrá en actividades antrópicas en 2008. Esta caso varía respecto a los modelos markovianos, por ejemplo, un predio agropecuario, al ser abandonado y si no existiera actividad antrópica, podría transformarse en un bosque secundario aproximadamente en 10 años, eso hace entender que los procesos de regeneración vegetal es realidad que hay que tomar en cuenta en los bosques tropicales. Sin embargo “en un proceso de crecimiento urbano si puede cumplirse esta regla ya que un área que es urbana en un tiempo dado, al cabo de unos pocos años es poco probable que deje de serlo” (Pontius y Chen 2006).

✓ **Land Change Modeler (LCM)**

Incluido en el software Idrisi ahora TerrSet, el módulo Land Change Modeler (LCM) forma parte en el análisis de los datos, sobre todo en la noción de cambio de usos del suelo. “La modelización propiamente dicha y las aplicaciones anexas en materia de ecología de paisaje y biodiversidad, así como implicaciones en la ordenación y gestión territorial. La modelización espacio-temporal prospectiva está dividida en dos fases: la de elaboración de los modelos de potencial de transición y la puesta en práctica de la predicción y/o obtención de escenarios” (Olmedo, Melgarejo y Paegelow 2010).

Se puede aclarar que LCM y CA_Markov son módulos diferentes pero complementos en algunas funciones. LCM explica, caracteriza y diseña las transiciones entre las categorías CA_Markov distribuye la superficie estimada para cada categoría mediante los correspondientes mapas de idoneidad de localización, que pueden ser elaborados mediante un modelo numérico, mientras que. “Para ello, ambos procedimientos establecen relaciones entre variables explicativas de distinta naturaleza (drivers) y las categorías de cobertura de suelo o las transiciones, aunque utilizando métodos diferentes, es decir, evaluación multicriterio o regresión logística en CA_Markov, como ya se ha señalado, y redes neuronales en LCM” (Mishra et al. 2014).

✓ **Change of Land Use and its Effects at Small Scale (CLUE)**

CLUE es un programa gratuito para crear modelos, que se basado en un método probabilístico de tipo regresión logística. El diseño CLUE, “es un modelo explícito, especialmente para el cambio de cobertura de suelo y sus efectos, cuyo objetivo es hacer un espaciamiento de las multicapas y la descripción cuantitativa de los cambios de uso de la tierra; la metodología de CLUE se basa en el análisis de los sistemas de uso de la tierra como sistemas complejos multi-nivel y opera con los sistemas de cobertura del suelo en la interfaz de múltiples sistemas sociales y ecológicos” (Cai et al. 2004; Veldkamp y Fresco 1996).

✓ Regresión Logística (RL)

El análisis de regresión logística multivariante (RLM) “tiene la misma estrategia que el análisis de regresión lineal múltiple, el cual se diferencia esencialmente del análisis de regresión logística porque la variable dependiente es continua; en la práctica el uso de ambas técnicas tienen mucha semejanza, aunque sus enfoques matemáticos son diferentes” (Pena 2009).

“Las variables explicativas pueden ser cuantitativas o cualitativas; y la ecuación del modelo no es una función lineal de partida, sino exponencial; si bien, por sencilla transformación logarítmica, puede finalmente presentarse como una función lineal” (Pena 2009).

Al usar el modelo de RL, en vez de diseñar un modelo de regresión para calcular los valores concretos de la variable a estudiar, se construye una función basada en el cálculo de la probabilidad que la variable de interés adopte el valor del evento previamente definido, de la manera siguiente:

$$y = \ln\left(\frac{p}{1-p}\right) \quad (7)$$

Después de elaborar un conjunto de transformaciones matemáticas se puede decir que:

$$p = \frac{1}{1+e^{-\text{modelo de regresión}}} \quad (8)$$

Lo que se quiere por medio de la RLM es manifestar la probabilidad de que ocurra el evento en estudio, como función de algunas variables. “En la bibliografía referida al CCS (cambio de cobertura del suelo), a estas variables explicativas o influyentes se las conoce como *drivers*; la técnica de regresión logística por la naturaleza de su variable dependiente ha sido usada en el campo de la medicina, psicología, ciencias ambientales y otras” (Pena 2009).

✓ Cadenas de Markov

Una de las metodologías para determinar las posibilidades de cambio en la cobertura de suelo son las Cadenas de Markov. El método obtiene una

matriz de transición de Markov normalmente a través de relacionar los mapas de cobertura de suelos de dos tiempos t_0 y t_1 .

Las cadenas de Markov son procesos de memoria pequeña en el sentido que solo “memorizan” el último estado visitado para decidir cuál será el próximo. En términos formales, el proceso $i \in N$ con espacios de estados E , es una cadena

$$P(X_{n+1} = y | X_n = x_n, \dots, X_0 = x_0) = P(X_{n+1} = y | X_n = x_n) \quad (9)$$

Donde $x_n \in E$. En procesos con “larga memoria” el valor que toma la técnica encada proceso depende de el pasado (Paegelow et al. 2002; Vega 2004).

✓ **Autómatas Celulares (AC)**

Los AC fueron creados en los años 50 por Von Neumann como consecuencia de un estudio sobre realización de sistemas de complejidad no limitado. “La solución que Von Neumann dio a este problema, fue que la construcción de dicho sistema fuese hecha por otro sistema computacional de menor complejidad, que a su vez habría sido construido por otro de menor complejidad, hasta llegar a uno cuya complejidad fuese abordable por el ser humano” (González et al. 2012).

“Por lo general, en un autómata celular, el estado de una célula en una generación determinada depende única y exclusivamente de los estados de las células vecinas y de su propio estado en la generación anterior” (Hurtado 2014).

Lo importante de este tipo de diseño se basa en que puede representar fenómenos en los que las variables se modifican en forma moderada dependiendo de su estado y no en forma continua dependiendo de una función matemática.

Para proponer un diseño de AC se necesita seguir algunas pautas, entre las mas representativas se encuentran están las reglas de transición en cada interacción. Es así que el estado de un AC en un tiempo $t+1$ (**Ep+1Tij**) está en función de su propio estado (**EpTij**) en el tiempo t y de los estados de todos

los elementos ubicados en su vecindad, pudiendo representarse de la siguiente manera:

$$\mathbf{E}^p + \mathbf{1T}_{ij} = f(\mathbf{E}^p\mathbf{T}_{ij}, \mathbf{E}^p\mathbf{T}_{i-1j-1}, \mathbf{E}^p\mathbf{T}_{i-1j}, \mathbf{E}^p\mathbf{T}_{i-1j+1}, \mathbf{E}^p\mathbf{T}_{ij-1}, \mathbf{E}^p\mathbf{T}_{ij+1}, \mathbf{E}^p\mathbf{T}_{i+1j-1}, \mathbf{E}^p\mathbf{T}_{i+1j}, \mathbf{E}^p\mathbf{T}_{i+1j+1}) \quad (10)$$

Donde:

- **T_{ij}**: representa el AC o celda de la posición i,j en el espacio (Tabla 3)
- **E^p**: representa el conjunto [**a, b, c, d,...,n**] de estados que puede tomar el AC en el tiempo o iteración **p**.
- **E^p+1T_{ij}**: representa el estado particular de un AC en función del estado de sus vecinos y de las reglas de transición planteadas.

2.2.12 Tasa de cambio

La tasa de cambio anual indica el cambio en porcentaje de las coberturas de suelo al principio de cada año. Utiliza la superficie de una determinada cobertura en dos épocas diferentes y el número de años transcurridos para determinar cómo ocurren estos cambios (FAO 1996; citado en Velázquez et al. 2001).

$$q = \left[\left(\frac{A_2}{A_1} \right)^{\frac{1}{(t_2-t_1)}} - 1 \right] \times 100 \quad (11)$$

Donde q es la tasa anual de cambio expresada en porcentaje, y A1 y A2 corresponden a la superficie en los tiempos t1 y t2, respectivamente.

2.3 Definición de términos

Análisis prospectivo: Menciona que los estudios que se realizan tiene la finalidad de prevenir lo que puede ocurrir, es una técnica que apoya en las decisiones para una buena planificación, en este estudio sirve para tomar decisiones para el uso sostenible de los recursos naturales, facilitando un ordenamiento territorial según las actividades que se realizan.

Cambio de uso de suelo: “El cambio del uso y cobertura del suelo (LULUCF, por sus siglas en inglés), es el término utilizado para indicar las modificaciones que se realizan sobre la superficie terrestre causadas por la actividad humana y/o las perturbaciones a través del tiempo” (Soares-Filho et al. 2004).

Deforestación: La FAO (2005) “define a la deforestación como la transformación del bosque en otros usos de la tierra o a la reducción de la cubierta de la copa por debajo del umbral mínimo de 10%”. Además, considera que la “deforestación y la quema son principales causantes de las emisiones de los GEI, donde predomina el CO₂, sin embargo, el proceso de descomposición orgánica genera también CH₄ (metano) gas que es 21 veces más nocivo que el CO₂ aunque es generado en bajas concentraciones” (FAO 2016).

Bosque: En el Protocolo de Kioto, señala que el bosque “es la superficie mínima de tierras de 0,05 y 1,0 hectáreas, y cuenta con una cubierta coposa entre 10% y 30% y con árboles que pueden alcanzar una altura mínima in situ de 2 hasta 5 metros a su madurez” (UNFCCC 2001).

Cadenas de Markov: Una de las metodologías para determinar la probabilidad de cambio en la cobertura de suelo. “El método obtiene una matriz de transición de Markov generalmente a través de la comparación de mapas de cobertura de suelos de dos fechas t₀ y t₁; este método consiste en analizar sistemas que contienen ciertos parámetros de probabilidad, teniendo como mejor predictor el uso pasado y actual de dicha cobertura” (Irwin y Bockstael 2001; Irwin y Geoghegan 2001).

CAPÍTULO III. METODOLOGÍA DE INVESTIGACIÓN

3.1 Lugar de estudio

La región de Madre de Dios se ubica al sur oriente del Perú. Limitando por el norte con la Región de Ucayali y con el país de Brasil, por el sur con las Regiones de Cusco y Puno, con el oeste con las regiones de Ucayali y Cusco, por el este con el país de Bolivia. “Posee una frontera internacional de 584 km, de los cuales 314 km son con Brasil y 270 km con Bolivia; el departamento de Madre de Dios está dividido políticamente en 3 provincias y 11 distritos” (GOREMAD y IIAP 2009).

El área de estudio comprende el distrito de Iberia localizado en la provincia de Tahuamanu (figura 4), al noreste de la región Madre de Dios de Perú. El proyecto geográficamente se ubica entre las coordenadas 11°17'27" – 11°25'57" LS y 69°40'22" – 69°22'06" LO, y presenta un mosaico con distintas reglas de uso del suelo, áreas privadas en el sector agrícola, concesiones forestales maderables, shiringa, reforestación, conservación y ecoturismo.

“La zona de estudio forma parte de una gran cuenca geológica sedimentaria, ubicada entre el Escudo Brasileiro y la faja Sub-Andina y está caracterizada por la presencia de suaves ondulaciones, formadas por material cuaternario acumulado sobre formaciones pre-existente; es por consiguiente, una depresión tectónica donde se acumularon gruesas secuencias sedimentarias que presentan en superficie pliegues muy suaves” (ONERN 1997).

En general, el área de estudio se caracteriza por la presencia de lluvia abundante casi todo el año, diferenciándose una estación conocida como invierno de octubre a mayo y una estación seca conocida como verano de junio a septiembre, “esta diferencia no llega a influenciar significativamente en el comportamiento de la vegetación del área; la evaporación registrada en las estaciones de Iberia en periodo de 1980 a 1989 fue 598,4 mm” (OEA 2008).

En esta zona presenta “vegetación propia de pcales mixtos, bosques de terrazas disectadas, bosques de colinas bajas y de chacras y purmas, donde la especie *Hevea* sp. (shiringa) es la más sobresaliente” (IIAP 2001).

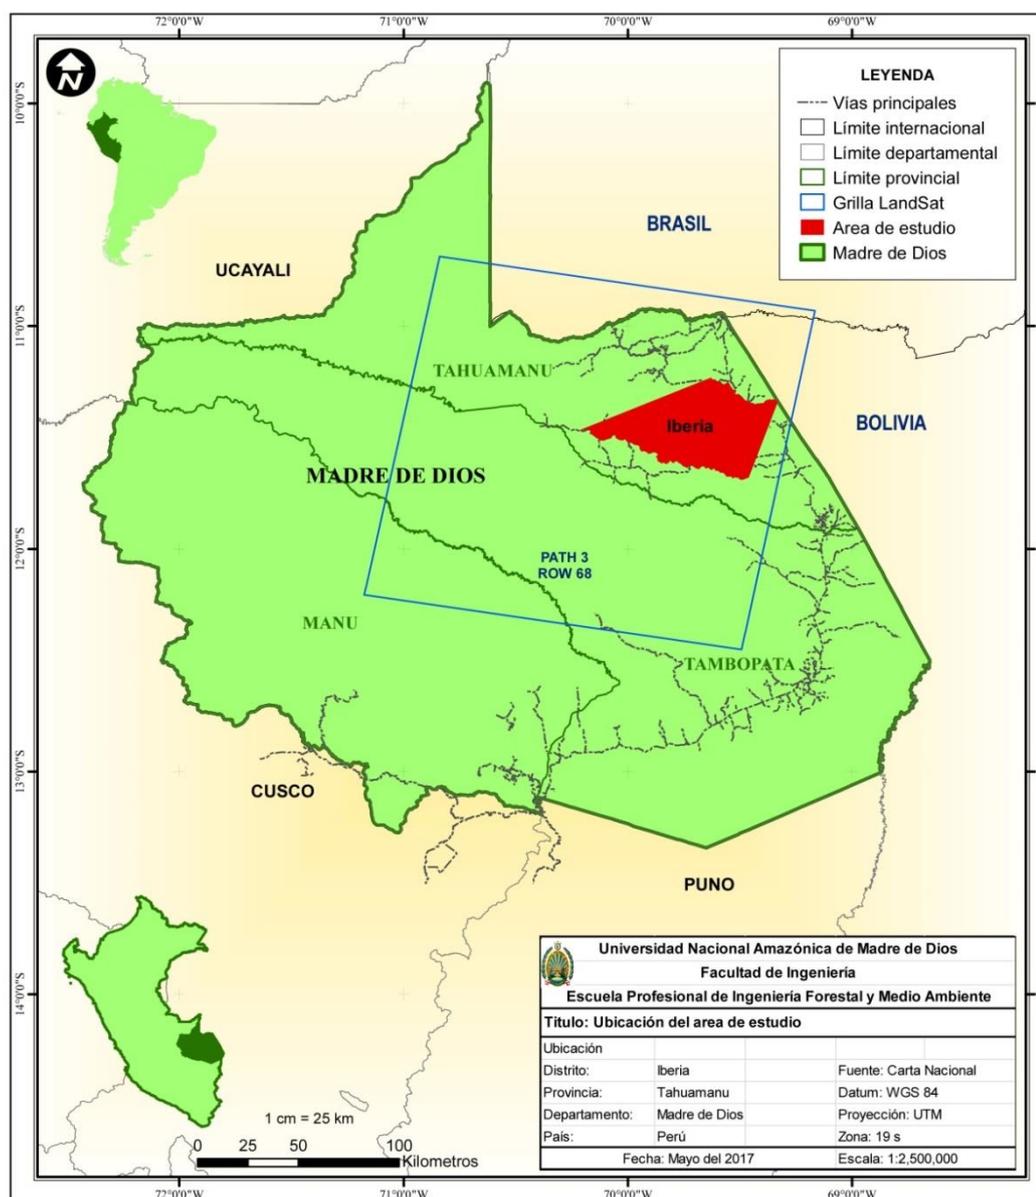


Figura 4. Ubicación del área de estudio, distrito de Iberia, provincia de Tahuamanu – Madre de Dios.

3.1.1 Clima e Hidrografía

Presenta un clima tropical: caluroso, húmedo y muchas precipitaciones. Con una temperatura promedio anual de 26°C; llegando como máximo a 38°C durante agosto y setiembre; las temperaturas mínimas llegan a 8°C. Las lluvias disminuyen considerablemente durante los meses de junio a agosto, aumentando las lluvias durante los meses de diciembre y marzo.

El río Tahuamanu, quebradas y riachuelos forman parte de los recursos hídricos que atraviesan el distrito, constituyéndose un medio de transporte. “La vegetación que predomina y abarca la mayor superficie corresponde a la clasificación de bosque húmedo tropical” (GOREMAD y IIAP 2009).

3.2 Tipo y diseño de investigación

La investigación es de tipo descriptiva, correlacional y predictivo, ya que se tratara de ver la cuantificación, cambios de cobertura del suelo, y análisis predictivo de cambio de uso de suelo en el distrito de Iberia, al año 2030 (Baray 2006; Castro 2003; Cazau 2006; Hernández et al. 2010).

En cuanto al diseño la investigación es Transaccional (transversal) y longitudinales de tendencia o trend, ya que se analiza, se cuantifica los cambios en la cobertura y modela las zonas deforestadas en periodos determinados (2004, 2011 y 2016) (Baray 2006; Castro 2003; Cazau 2006; Hernández, Fernández y Baptista 2010).

3.3 Población

Se considerará como población el distrito de Iberia, que comprende una superficie de 255 369,25 ha (2 553,69 km²).

3.4 Muestra

Para determinar el número de muestras a coleccionar en campo se utilizó la distribución binomial de probabilidad (Anaya y Chuvieco 2010; Chuvieco y Hantson 2010), la muestra se encontró haciendo uso de la siguiente fórmula:

$$n = \frac{Z^2 p(qN)}{(N-1)E^2 + Z^2 + pq} \quad (12)$$

Dónde:

Z: valor de la curva normal estandar a un nivel determinado de probabilidad, 1,96 (95%).

p: es porcentaje de aciertos estimado, 0,50 (50%).

q: es el porcentaje de errores ($q = 1 - p$), 0,50 (50%).

N: tamaño de la población.

E: el error permitido, 0,05 (5%).

$$n = \frac{(1,96)^2 * 0,5(0,5 * 255\ 369,25)}{(255\ 369,25 - 1) * 0,05^2 + 1,96^2 + (0,5 * 0,5)}$$

$$n = 388,25 = 388$$

Esta muestra fue distribuida, para que en toda el área de estudio sea representativa. Ello se dio a través de un modelo de muestreo probabilístico, donde las unidades de muestreo presentes en el área de estudio tienen una probabilidad superior a cero de ser considerados, este tipo de probabilidad de selección se le conoce como probabilidad de inclusión. “Las técnicas de muestreo más empleadas en el proceso de evaluación de la contabilidad temática son: aleatorio simple, aleatorio estratificado, sistemático, sistemático no alineado y por conglomerados” (François-Mas, Reyes Díaz-

Gallegos y Pérez-Vega 2003). Para nuestro caso se aplicó el muestreo *Aleatorio estratificado*.

Para determinar las categorías y el cambio de cobertura de suelo se trabajó bajo la leyenda nivel cero; cuya leyenda fue adaptado por la “Mesa de Servicios Ambientales y Reducción de Emisiones de Gases de Efecto Invernadero causadas por la Deforestación y Degradación de los Bosques de Madre de Dios propuesta en el año 2013; desarrollada por CORINE Land Cover” (IDEAM 2010) (tabla 5). Donde se utiliza una leyenda de orden, que relaciona varios niveles de escala espacial con varios niveles de detalle temático “niveles de la leyenda jerárquica definición de una serie de clases en el nivel 1”.

Tabla 5. Leyenda de clasificación de imágenes; nivel 0.

Descripción Nivel 0	Código Nivel 0	Descripción Nivel 1	Código Nivel 1
Deforestación	3	Áreas Urbanizadas	1
Deforestación	3	Área de Extracción Minera	2
Deforestación	3	Áreas Agrícolas	3
Deforestación	3	Agua de disposición Residual	11
Bosque	1	Bosque	4
Bosque	1	Sombra de montaña con vegetación	4,1
Bosque	1	Área con Vegetación Pacales y Arbustivos	5
Bosque	1	Áreas Húmedas	7
No Bosque	2	Áreas sin vegetación (Playas)	6
No Bosque	2	Área sin vegetación – Montaña	6,1
No Bosque	2	Sabanas	12
No Bosque	2	Cochas secas	12,1

Descripción Nivel 0	Código Nivel 0	Descripción Nivel 1	Código Nivel 1
No Bosque	2	Nieve	13
No Bosque	2	Vegetación riverseña	14
Cuerpos de Agua	2	Superficies de Agua	8
ND	0	Nubes	9
ND	0	Sombras de Nubes	10

Fuente: MSAR (2013); Tomado y adaptado de CORINE Land Cover (IDEAM 2010).

Se dividió a la población en estratos para obtener la muestra, según las categorías y el cambio de cobertura de suelo, bajo la leyenda nivel cero; cuya leyenda fue adaptado por la “Mesa de Servicios Ambientales y Reducción de Emisiones de Gases de Efecto Invernadero causadas por la Deforestación y Degradación de los Bosques de Madre de Dios propuesta en el año 2013 (tabla 5); desarrollada por CORINE Land Cover” (IDEAM 2010), que permite tener cierto control sobre la distribución de los sitios de muestreo y obtener información sobre subconjuntos de la población.

Para la distribución de las muestras por categorías, se tomó y adaptó a lo propuesto por Congalton (1991) donde sugiere probar unos 50 lugares por categoría, y de 75 a 100 si el lugar a estudiar supera los 400 000 ha. Bajo estos criterios la muestra se distribuyó como se indica en la tabla 6 y figura 5.

Tabla 6. Distribución de muestras por categoría.

Descripción Nivel 0	Descripción Nivel 1	Área (ha)	Número de muestras
Deforestación	Áreas Urbanizadas	315,95	55,00
Deforestación	Áreas Agrícolas	17 196,96	100,00
Bosque	Bosque	223 300,59	100,00

Descripción Nivel 0	Descripción Nivel 1	Área (ha)	Número de muestras
Bosque	Bosque húmedo	9 192,63	58,00
Bosque	Área con Vegetación Pacales y Arbustivos	4 015,47	75,00
No Bosque	Áreas sin vegetación (Playas)	434,98	
Cuerpos de Agua	Superficies de Agua	912,68	

Fuente: Elaboración propia

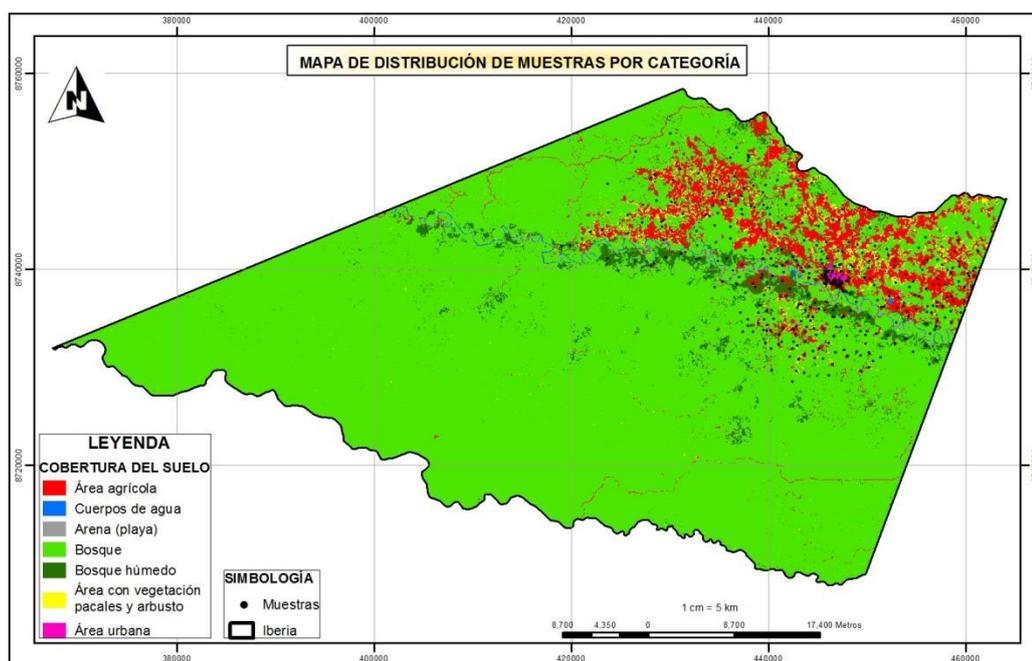


Figura 5. Distribución de muestras por categoría, método aleatorio estratificado.

3.5 Métodos y técnicas

Para la evaluación se utilizó imágenes Landsat TM 5 (tabla 8) correspondientes a los años 2004, 2011, y imágenes Landsat 8 OLI (tabla 9) para el año 2016, que están incluidas en el Sistema Geodésico Mundial (WGS) 84 datum. Estas imágenes de satélites fueron elegidos en base a la

disponibilidad de imagen libre de nubes durante la estación seca de julio a septiembre (tabla 7).

Tabla 7. Información de adquisición de imágenes Landsat.

Sensor	Pat Row	Fecha de Imagen
Landsat 5TM	003 68	29 de Julio 2004
Landsat 5TM	003 68	03 de Septiembre 2011
Landsat 8 OLI	003 68	15 de Agosto 2016

Fuente: USGS (2017).

Tabla 8. Características de la imagen de satélite Landsat 5 TM.

Satélite	Bandas espectrales	Longitudes de Onda (μm)	de Resolución
Landsat Thematic Mapper 5 (TM5)	Banda 1-Azul	0,45-0,52	30m
	Banda 2-Verde	0,53-0,61	30m
	Banda 3-Rojo	0,63-0,69	30m
	Banda 4-Infrarojo cercano	0,78-0,90	30m
	Banda 5-Infrarrojos de onda corta	1,55-1,75	30m
	Banda 6-Infrarojo térmico	10,4-12,5	60m
	Banda 7-Infrarrojos de onda corta	2,09-2,35	30m

Fuente: (Li et al. 2013; Roy et al. 2014; Sokeng et al. 2016).

Tabla 9. Características de la imagen de satélite Landsat 8 OLI.

Satélite	Bandas Espectrales	Longitud de Onda (μm)	Resolución
OLI	Banda 1-Costero/Aerosol	0,433-0,453	30m
	Banda 2-Azul	0,450-0,515	30m
	Banda 3-Verde	0,525-0,600	30m
	Banda 4-Roja	0,630-0,680	30m
	Banda 5-Infrarrojo cercano (NIR)	0,845-0,885	30m
	Banda 6-Infrarrojo de onda corta (SWIR 1)	1,560-1,660	30m
	Banda 7-Infrarrojo de onda corta (SWIR 2)	2,100-2,300	30m
	Banda 8-Pancromática	0,500-0,680	15m
	Banda 9-Cirrus	1,360-1,390	30m
LANDSAT-8 TIRS	Banda 10-Infrarrojo termal o de onda larga	10,30-11,30	100m
	Banda 11-Infrarrojo termal o de onda larga	11,50-12,50	100m

Fuente: (Li, Jiang y Feng 2013; Roy et al. 2014; Sokeng et al.2016).

El proceso se basa en una clasificación multiespectral supervisada en base al método de SAM (Spectral Angle Mapper), con la combinación de bandas 5, 4, 3 para imágenes Landsat 5 TM y con la combinación de bandas 6, 5, 4 para imágenes Landsat 8 OLI. Para el procesamiento y análisis de las imágenes se utilizó el ENVI 5,3® y ArcGis 10,5® con licencia del Centro de Teledetección para el estudio y gestión de los recursos naturales de la Universidad Nacional Amazónica de Madre de Dios. Previamente a este proceso se distribuyó puntos de validación, para lo cual en el presente trabajo se realizó a través de la recolección de puntos de las áreas de entrenamiento extraídas de las diferentes zonas de áreas deforestadas en el

distrito de Iberia, a través de la verificación in situ mediante del uso de GPS (Garmin Map 60 CSx, y Garmin Map 62 CSx). Seguidamente se realizó la validación por medio de una matriz de confusión (cuya exactitud fue medida mediante el índice de Kappa).

Para la elección de los lugares de prueba se utilizó el módulo de Perfil Espectral (Spectral Profile) del software ENVI 5,3®, herramienta que nos permite realizar la colecta de firmas espectrales y reconocer las coberturas para clasificar las imagenes satelitales del periodo 2004, 2011 y 2016.

Para la clasificación de las categorías, se utilizó la leyenda nivel cero; adaptada por la “Mesa de Servicios Ambientales y Reducción de Emisiones de Gases de Efecto Invernadero causadas por la Deforestación y Degradación de los Bosques de Madre de Dios” propuesta en el año 2013 (cuadro 6), desarrollada por CORINE Land Cover (IDEAM 2010). Con esta consideración se determinaron tres categorías; 1. Bosque (Bosque y áreas con vegetación Pacales y Arbustivos) (figura 6), 2. Deforestación (Área Urbana y Áreas Agrícolas) (figura 7), y 3. No bosque (Superficies de Agua y Áreas sin Vegetación - playas) (figura 8).

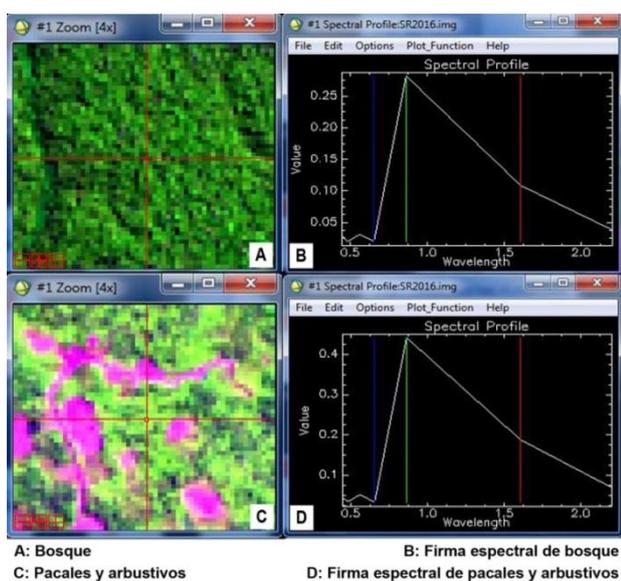


Figura 6. Imagen de Satelite Landsat 8 OLI 2016, colección de areas de entrenamiento a traves de firmas espectrales de la categoría bosque en el distrito de Iberia, Tahuamanu - Madre de Dios - Perú. R(6) G(5) B(4).

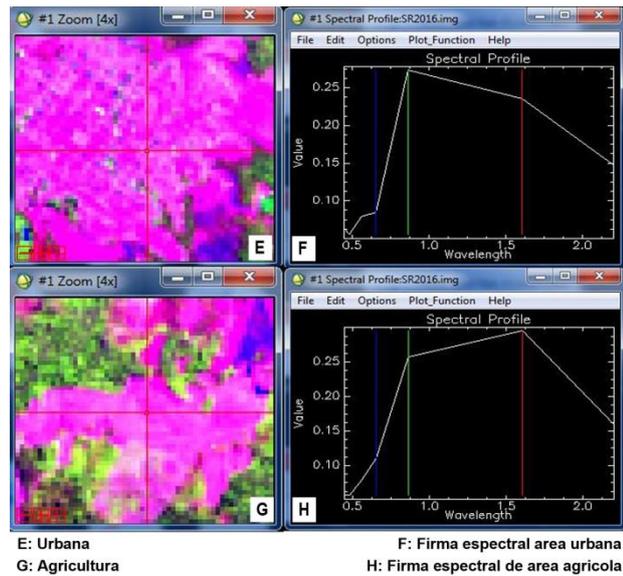


Figura 7. Imagen de Satelite Landsat 8 OLI 2016, colección de areas de entrenamiento a traves de firmas espectrales de la categoría deforestación en el distrito de Iberia, Tahuamanu - Madre de Dios - Perú. R(6) G(5) B(4).

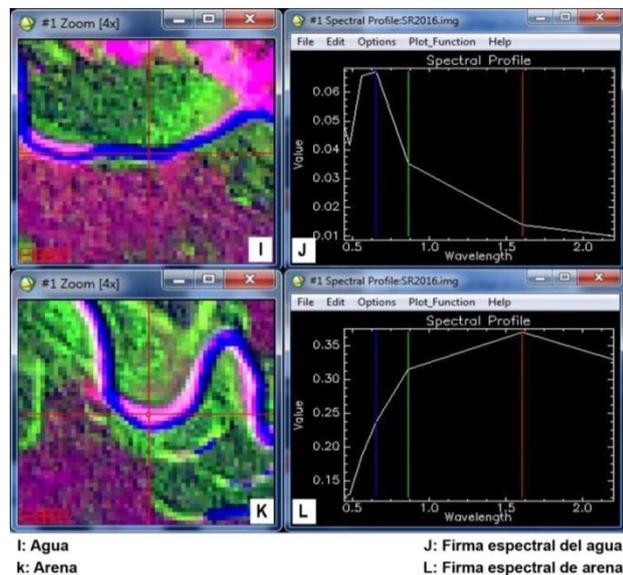


Figura 8. Imagen de Satelite Landsat 8 OLI 2016, colección de areas de entrenamiento a traves de firmas espectrales de la categoría no bosque en el distrito de Iberia, Tahuamanu - Madre de Dios - Perú. R(6) G(5) B(4).

Durante el estudio de las dinámicas originadas sobre cobertura vegetal para el periodo 2004 al 2011, se determinó las tendencias de cambio y se infirió la superficie probable de bosque a deforestación al año 2016. Para la modelación de la deforestación al año 2016 y 2030 se aplicó el método de Cadenas de Markov, disponible en el software TerrSet® - Clark Labs, Clark University USA, con licencia del Centro de Teledetección para el estudio y gestión de los recursos naturales de la Universidad Nacional Amazónica de Madre de Dios. Este método representa la predicción de la naturaleza de un sistema en un determinado tiempo considerando dos estados precedentes (t_0 y t_1), en este estudio las nuevas condiciones de probabilidad y de uso de de cambio en el distrito de Iberia al año 2030 (Paegelow, Olmedo y Toribio 2002; Rodríguez y Bautista 2006).

3.5.1 Técnicas de recopilación de datos

Material bibliográfico: Esta etapa se realizó durante todo el proceso de la elaboración de la tesis, a través de la búsqueda exhaustiva de información relacionado al presente estudio.

Selección de coberturas y obtención de imágenes de satélite:

1. Inicialmente se utilizó imágenes provenientes del satélite Landsat 5 TM, con una resolución de 30m x 30m por pixel con la combinación de bandas 5, 4, 3 (tabla 8), del año 2004 (figura 9) y del año 2011 con la combinación de bandas 5, 4, 3 (figura 10), obtenidas del servidor del USGS Glovis: The Global Visualization Viewer. Debido a que el área comprende el distrito de Iberia, se considerara el Path-row 3/68.
2. Seguidamente se utilizó imágenes provenientes del satélite Landsat 8 OLI, con una resolución de 30m x 30m por pixel con la combinación de bandas 6, 5, 4 (tabla 9), del año 2016 (figura 11), obtenidas del servidor del USGS Glovis: The Global Visualization Viewer. Debido a que el área comprende el distrito de Iberia, se considerara el Path-row 3/68.

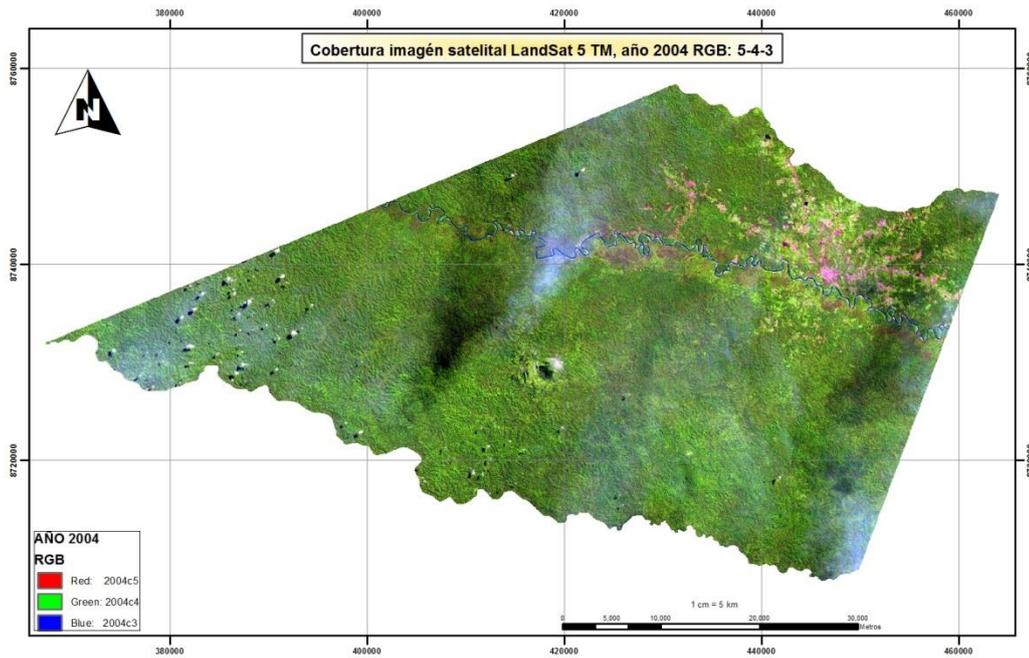


Figura 9. Imagen de satélite Landsat 5 TM, composición de banda 5-4-3 (20040729-003-068).

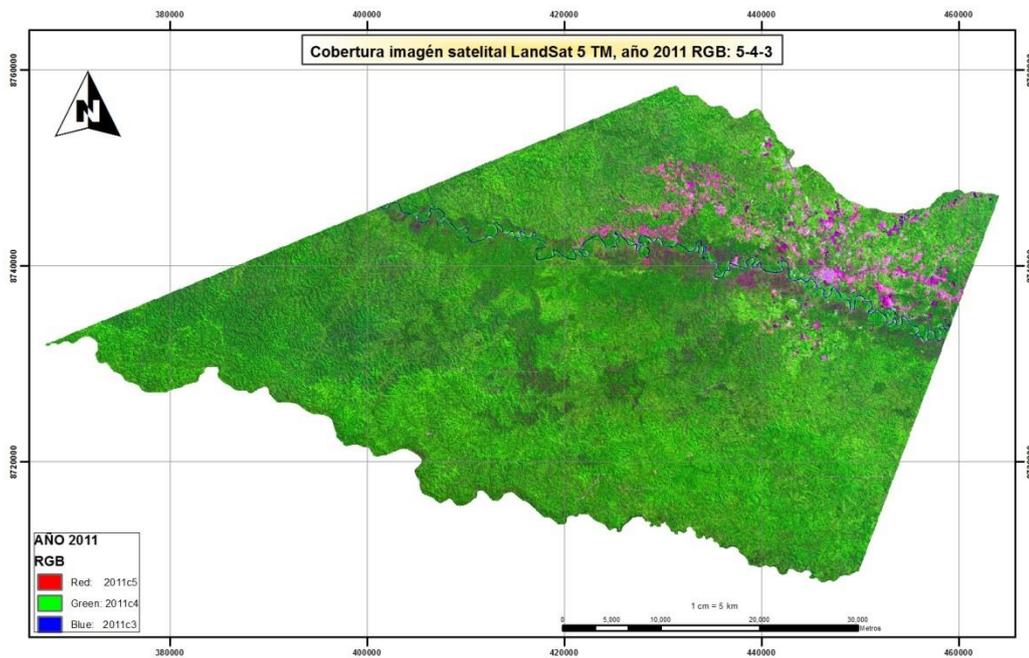


Figura 10. Imagen de satélite Landsat 5 TM, composición de banda 5-4-3 (20110903-003-068).

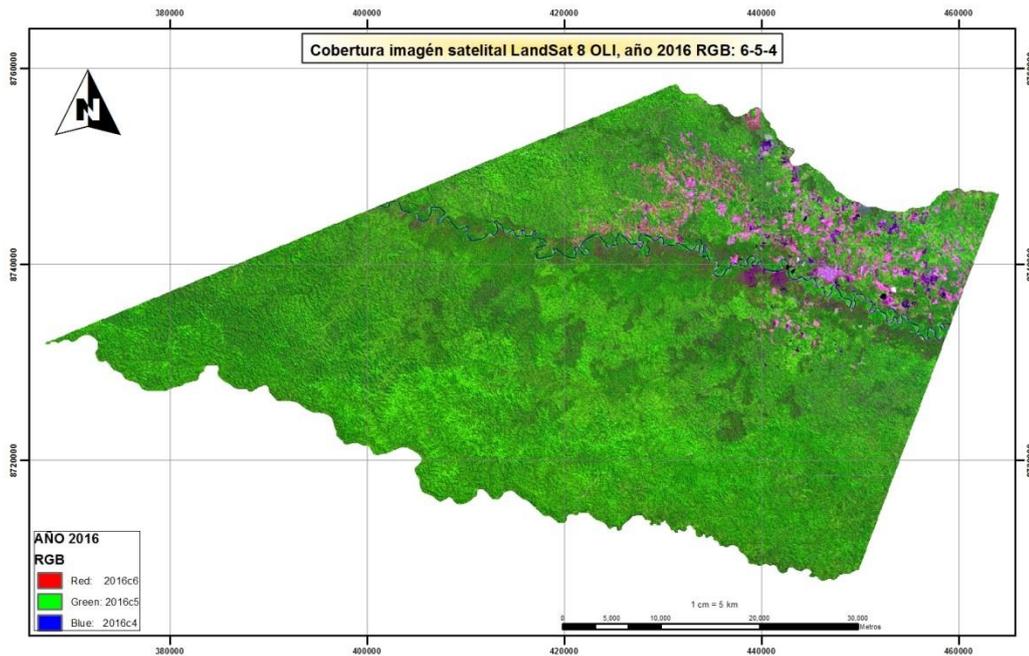


Figura 11. Imagen de satélite Landsat 8 OLI, composición de banda SWIR 1, Near Infrared y Red (20160815-003-068).

Para la selección de las imágenes se consideró que el Path-row no presente nubosidad, ya que podría inferir negativamente en la clasificación para la categoría bosque, no bosque y deforestación. Para ello se seleccionó imágenes de época no lluviosa en el área y que tenga similitud de fecha con las imágenes clasificadas para los años 2004, 2011 y 2016.

3.6 Variables explicativas del cambio de cobertura de suelo

Para la generación de las variables explicativas se requiere de la siguiente información: Modelo Digital de Tereno (MDT), pendiente, vías principales, vías secundarias, centros poblados, cuerpos de agua (tabla 10).

Tabla 10. Variables empleadas en la regresión logística.

Variable explicativa	Descripción	Fuente
MDT	m.s.n.m	Elaboración propia a partir de ASTER
Pendiente	Pendiente en %	Elaboración propia a partir del MDT
Distancias a vías principales	Carretera interoceánica	Elaboración propia a partir de cobertura DRFFS 1:500000
Distancias a vías secundarias	Careteras secundarias que conectan zonas pobladas rurales y urbanas	Elaboración propia a partir de cobertura DRFFS 1:500000
Distancia a centros poblados	Comunidades	Elaboración propia a partir de puntos de poblados
Distancia a ríos	Ríos principales y secundarios	Elaboración propia a partir de cobertura DRFFS 1:500000

Fuente: Elaboración propia

El procedimiento de obtención de las variables explicativas fue el siguiente.

➤ **MDT**

El Modelo Digital de Terreno (MDT) se obtuvo a través de las imágenes ASTER que son una fuente rápida de imágenes satelitales georreferenciadas listas para ser geoprocesadas en un software SIG como Arc Gis (figura 12). Las imágenes ASTER se seleccionaron del portal del Servicio Geológico de los estados Unidos (USGS 2017).

La altitud máxima es de 460 m.s.n.m. y la mínima de 232 m.s.n.m., además se observa que existe una gradiente altitudinal en sentido noroeste – sureste, que corresponde a la dirección del flujo del río Tahuamanu. En la

tabla 11 se puede observar que la mayor parte del distrito de Iberia (78,19 %) tiene alturas entre 308 y 384 m.s.n.m.

Tabla 11. Superficie de acuerdo a la altitud.

Altitud (m)	Superficie (ha)	%
<308	49 038,19	19,20
308-384	199 660,54	78,19
384-460	6 670,52	2,61

Fuente: elaboración propia

La altitud crea contrastes fuertes del lugar que daña directa o indirectamente los procesos biológicos del área de estudio, por ejemplo el desarrollo de la agricultura, la ganadería y aumento de la deforestación.

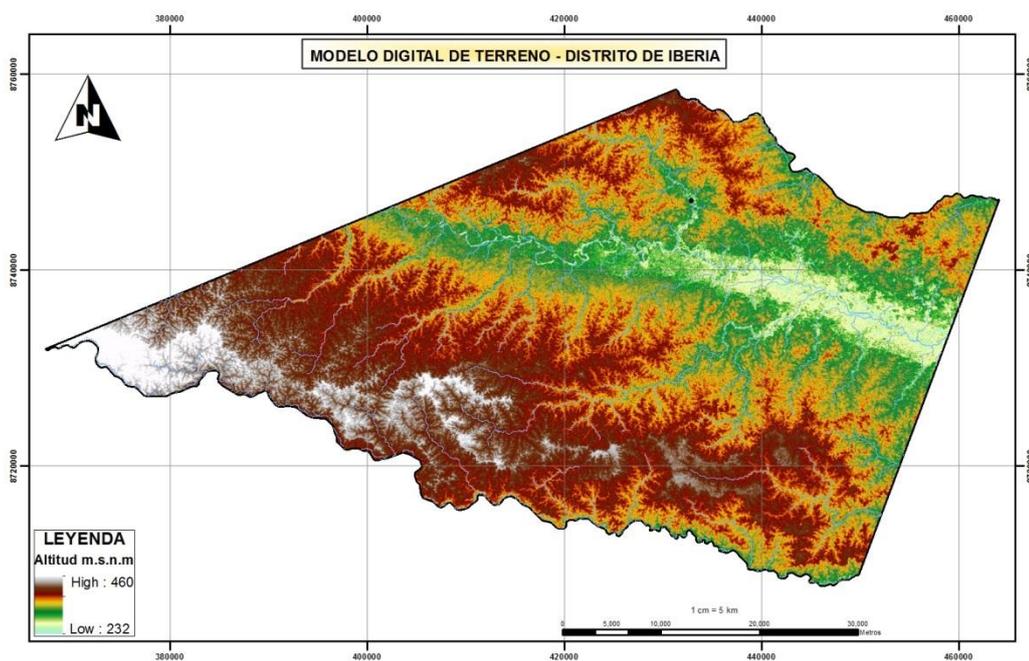


Figura 12. Modelo Digital del Terreno

➤ Pendiente

El raster de pendiente en porcentajes se generó a partir del MDT, utilizando la herramienta "Slope" de la extensión "Spatial Analyst" del software ArcGis, con tamaño de pixel 12 metros (figura 13)

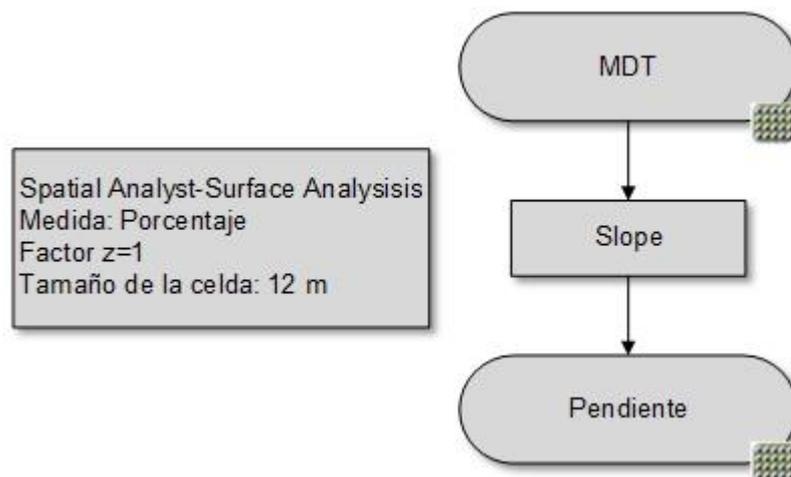


Figura 13. Modelo cartográfico generación variable pendiente.

De acuerdo a la tabla 12 en el distrito de Iberia existe una superficie de 255 346,81 ha (99,99% del área total de Iberia) con pendientes menores a 45%, es decir una inclinación en su totalidad baja, área de fácil acceso que permite el desarrollo de actividades forestales, agrícolas, ganaderas y con un alto potencial de deforestación.

Tabla 12. Superficie de terreno por pendiente.

Pendiente (%)	Superficie (ha)	%
< 45	255 346,81	99,99
> 45	22,44	0,01

Fuente: elaboración propia

La pendiente es una variable de mucha importancia en el modelamiento porque nos ayuda a determinar si existen o no limitaciones en el avance de la deforestación debido a la inclinación del terreno. Las zonas de bajas

pendientes presentan accesos más fáciles y por lo tanto mayor facilidad a cambiar de cobertura (figura 14) (Ceballos, López, Trujillo, & Gutierrez, 2005).

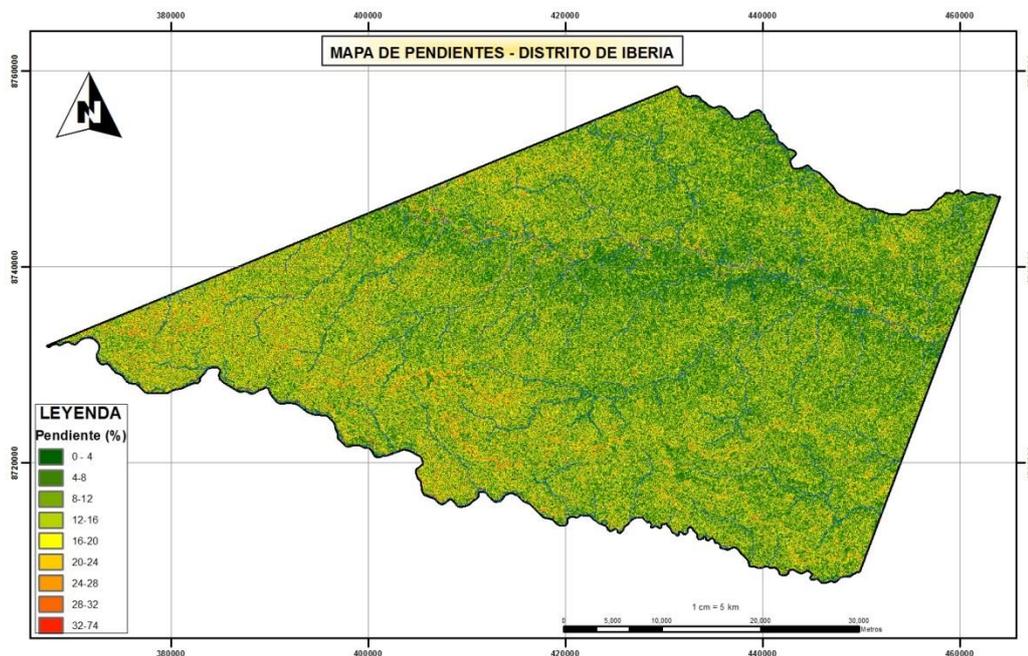


Figura 14. Mapa de pendientes.

- **Distancia a: Carreteras principales, carreteras secundarias, centros poblados y ríos.**

Para el cálculo de las distancias existieron desde cada objeto, en este caso coberturas en formato vector: vías principales y secundarias, puntos de poblaciones y cuerpos de agua. Se utilizó la herramienta “Euclidean Distance” de la extensión “Spatial Analyst Tools” dando como resultado un raster.

El parámetro de accesibilidad se obtuvo de la distancia euclidiana a diferentes elementos de la red vial principal, secundaria y trochas (figura 15). El mapa de distancias a centros poblados se generó a partir de las distancias desde los puntos de las comunidades (figura 16). Para el cálculo de la distancia a ríos se ingresó la cobertura en formato vector de ríos que drenan el distrito

de Iberia, dando como resultado un raster que contiene la variable continua de distancia a ríos simples (figura 17).

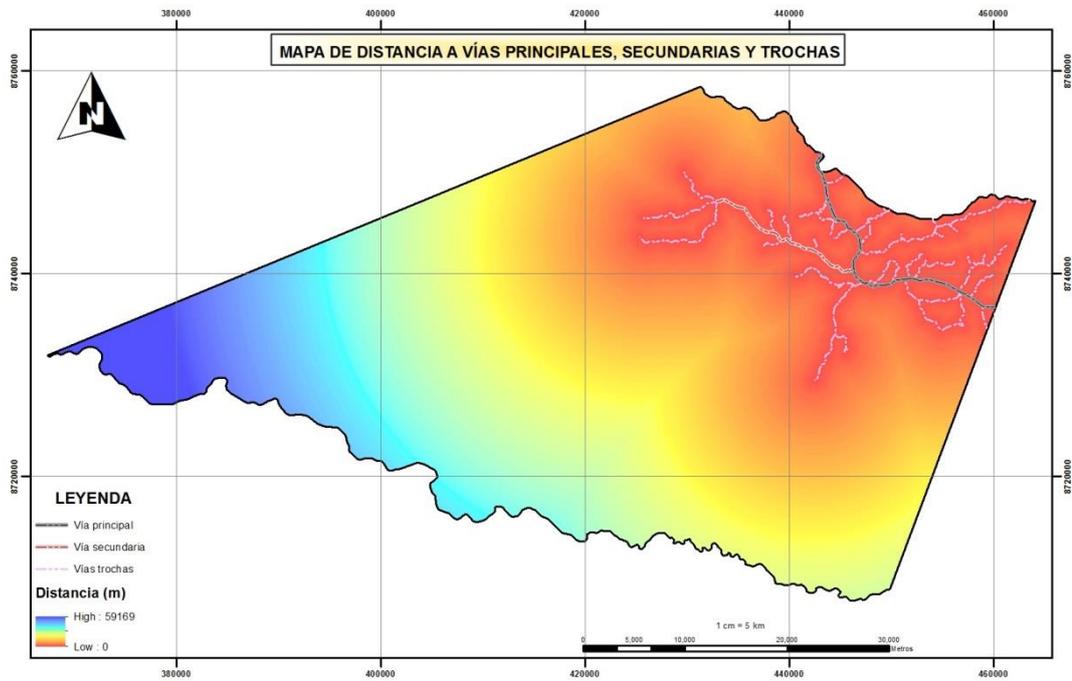


Figura 15. Distancia a vías principales, secundarias y trochas.

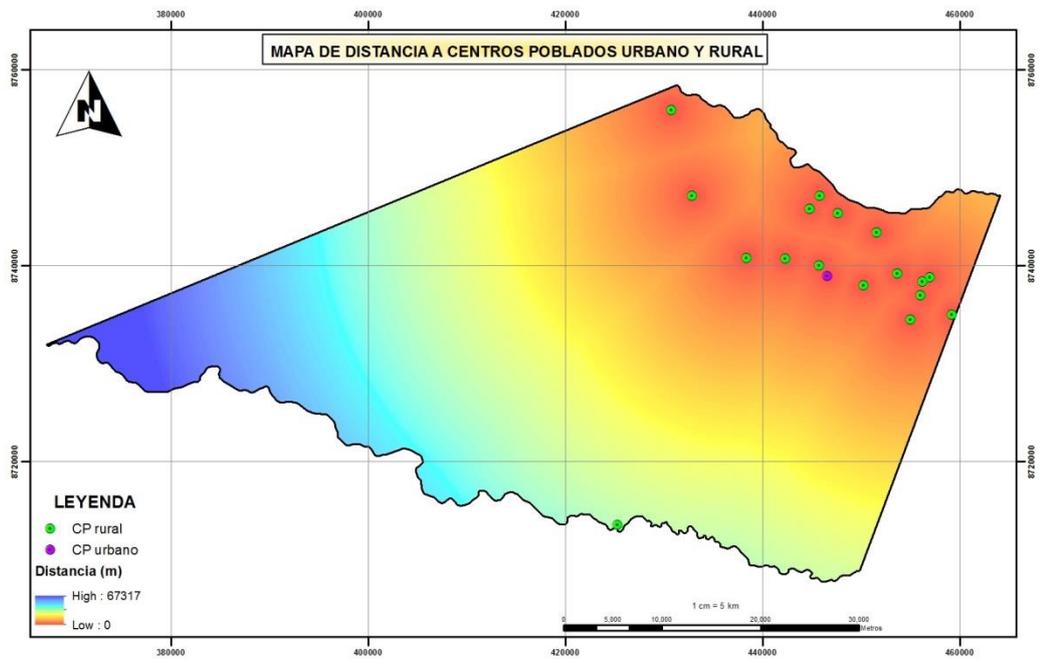


Figura 16. Distancia a centros poblados.

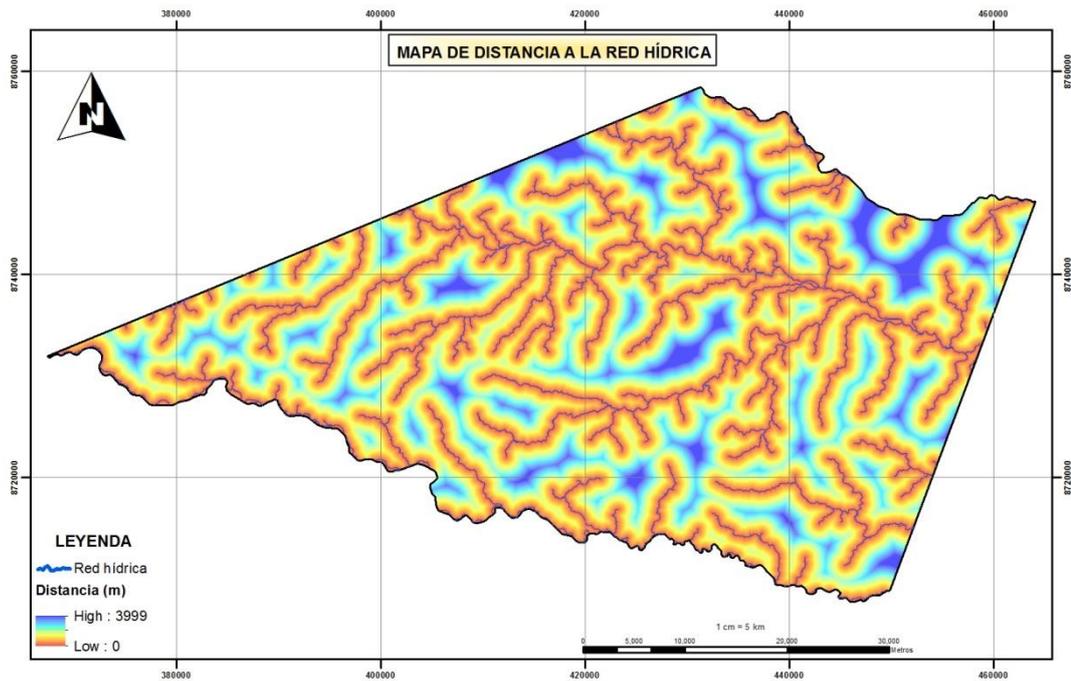


Figura 17. Distancia a ríos.

Los procesos originarios del cambio de uso de suelo son de origen antrópico; para esto, se incluyen variables que consideren de alguna manera la influencia humana y la accesibilidad que se tiene hacia las diversas coberturas de suelo.

La deforestación y aclareo de la cobertura vegetal cae aceleradamente conforme disminuye la distancia a vías principales y secundarias (Liu, et al, 1993 citado en Pidal, 2003; Sigtierrez, 2011).

3.7 Clasificación supervisada de la imagen satelital

Tratamiento digital que se basa en intensidad radiométrica de cada pixel en las distintas bandas utilizadas para su interpretación. La clasificación para el presente estudio comprendió tres (3) fases:

Pre-Procesamiento, el cual consistió en realizar todos los procesos necesarios para la preparación de los datos satelitales, para su posterior clasificación, comprendiendo así desde la unión de bandas hasta el recorte

del área de interés. El objetivo principal es contar con información rectificada de calidad, la misma que fue utilizada posteriormente para extraer las coberturas del suelo del área de estudio. Para la corrección atmosférica de las imágenes se efectuarán los siguientes procesos (figura 18)

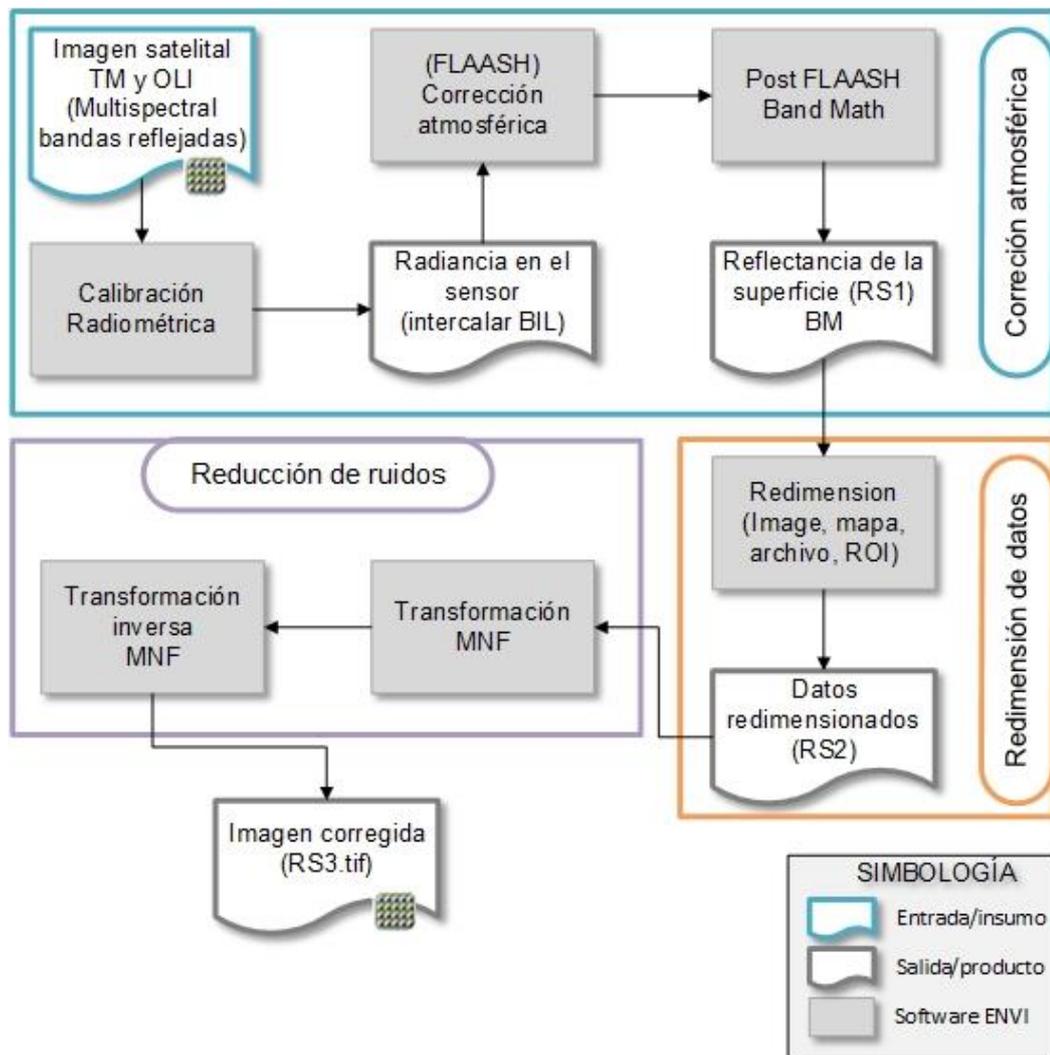


Figura 18. Proceso de corrección atmosférica.

Dado que el sensor Landsat 8 es tan reciente, las versiones anteriores de ENVI no tienen la funcionalidad adecuada para procesar correctamente estos datos, por lo que es necesario utilizar desde la versión ENVI 5.0 Service Pack 3, con la actualización para archivos OLI de Landsat 8 (envi50sp3_r4). Para abrir la imagen se accede al archivo que contiene la

extensión _MTI.txt, que corresponde al formato de imagen con metadatos disponible para Landsat 8, este se abre desde la opción de File/Open as/Landsat/GeoTIFF with Metadata.

El primer paso para la corrección es la conversión a radiancia. Para esto se debe ir a la opción de Toolbox/Radiometric Correction/ Radiometric Calibration; la imagen inicialmente se despliega dividida en 5 segmentos: multiespectral (que posee los infrarrojos), la banda cirrus, térmica, pancromática y calidad. La imagen fue codificada por el método de intercalado de banda por línea o BIL este método toma la información de la cantidad de filas y columnas y almacena todos los valores de la primera fila de la imagen para la primera banda, seguidos los valores de la primera fila para la segunda banda y así hasta la última banda. La mayoría de las imágenes se representan en BSQ; sin embargo, la extensión FLAASH de ENVI requiere que las imágenes se representen en BIL.

De todas las opciones que se muestran se debe seleccionar la que termina con MultiSpectral y asignar los diferentes valores de calibración radiométrica según se especifica en la tabla 13 y figura 19.

Tabla 13. Parámetros de calibración radiométrica Landsat 8.

Campo	Valor
Tipo de calibración	Radiancia
Intervalo de salida	BIL
Tipo de dato de salida	Flotante
Factor de escala	0.10
Directorio de salida	Nombre y directorio de salida

Fuente: elaboración propia

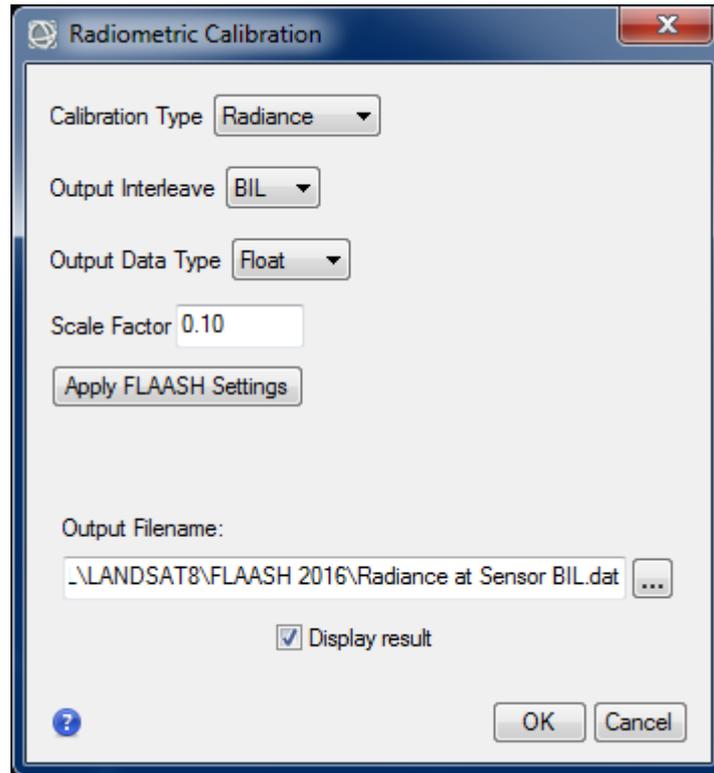


Figura 19. Calibración Radiométrica

Al finalizar se obtiene una imagen con el cambio de valores de Números Digitales a valores de radiancia, además el tipo de formato de imagen en el archivo de salida es .dat. Esta imagen de datos conserva la información que viene del metadato en formato BIL.

Como paso siguiente, se procede a realizar el proceso de la corrección atmosférica. Para ello se abre el archivo de salida (el .dat), posteriormente ir a la herramienta de FLAASH y en el factor de escala utilizar para la calibración es 1. Automáticamente se deben leer del archivo de la imagen los valores de latitud (lat) y longitud (long). Respecto de los parámetros requeridos, en el tipo de sensor dejar la opción desconocido-msi (UNKNOWN-MSI), en altitud del sensor se debe poner 705 km y el tamaño de pixel se coloca automáticamente, al igual que los valores de lat-long. La elevación variará en cada una de las imágenes que se vayan a calibrar. Además la fecha del vuelo y el tiempo de vuelo se deben extraer del metadato (ENVI 2009)

Para ello se debe seleccionar el método de extracción de aerosoles de dos bandas (K-T), como paso adicional se debe ir a la configuración multispectral y en ella buscar la opción de filtro archivo de función: y colocar la siguiente dirección: “Ruta de instalación de ENVI \Files\Exelis\ENVI50\classic\filt_func\ldcm_oli.sli” la selección del modelo atmosférico, modelo de aerosoles y visibilidad inicial dependerá de las condiciones de la imagen (figura 20); finalmente al ejecutar la corrección atmosférica la imagen resultante contiene los datos en reflectancia espectral. (ENVI – HELP Versión 5.0), 2011.

Figura 20. Modelo de Corrección Atmosférica - FLAASH

La corrección atmosférica produce mínimos y multiplica la reflectancia por 10000, para cambiar la escala de los datos de la Reflectancia (0 – 1) se utiliza la ecuación 13 y figura 21.

$$\text{Band Math} = (B1 \leq 0) * 0 + (B1 \geq 10000) * 1 + (B1 > 0 \text{ and } B1 < 10000) * \text{float}(b1) / 10000 \quad (13)$$

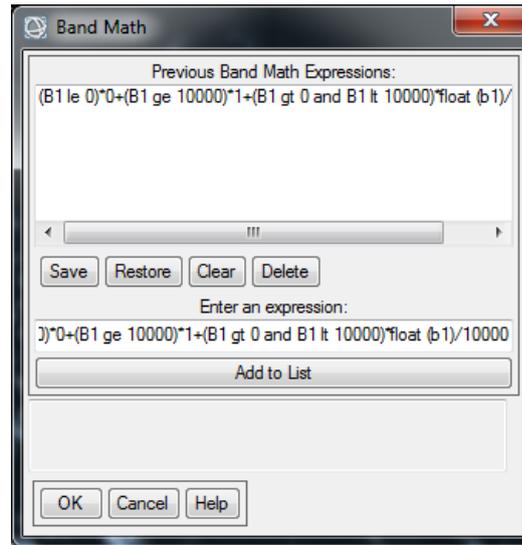


Figura 21. Expresión Band Math

El recorte del área de interés es generado por el programa ENVI según el archivo raster del área de estudio.

Para la reducción del ruido se utiliza la herramienta MNF (figura 22) que transforma la rotación para determinar la dimensionalidad inherente de datos de imagen, para segregar ruido en los datos, y para reducir los requisitos computacionales para procesamiento posterior (Boardman y Kruse, 1994).

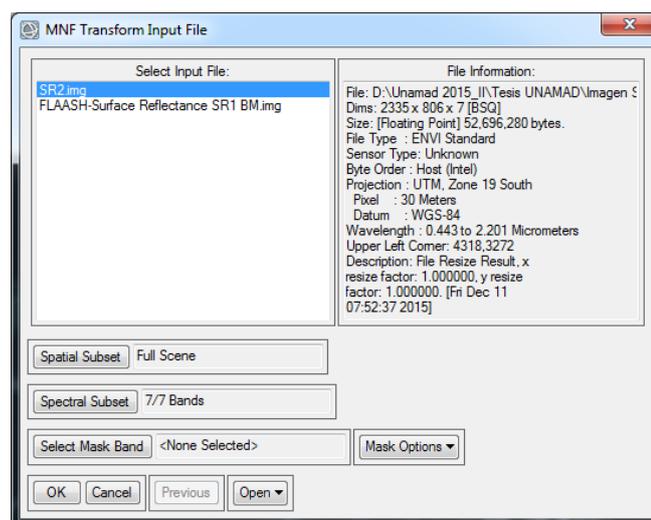


Figura 22. Transformando el archivo SR2.img

Para transformar las bandas de nuevo a su espacio de datos original se utiliza la herramienta Inverse MNF Transform (figura 23) creándose un nuevo archivo SR3.img

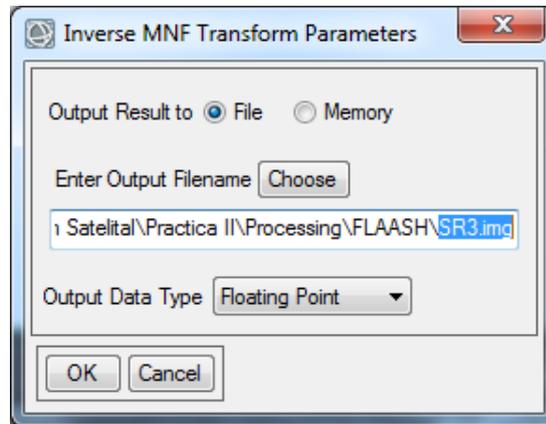


Figura 23. Archivo de salida SR3.img

Procesamiento, el cual consistió en la clasificación propiamente dicha de la imagen, en donde se ubica espacios concretos de la imagen satelital (con ayuda de interpretación de fotografías aéreas y salida de campo o por conocimiento propio). Estos lugares se denominan “áreas de entrenamiento porque sus características espectrales se usan para que el algoritmo de clasificación las compare estadísticamente con las de otra parte cualquiera de la imagen” (Chuvieco y Hantson 2010; Jensen, Lin, Yang, Ramsey III, Davis y Thoemke 1991). El presente estudio utilizó la clasificación multiespectral supervisada en base al método de SAM (Spectral Angle Mapper), con la combinación de bandas 6, 5, 4 para imágenes Landsat 8 OLI. Se siguió el siguiente proceso (figura 24).

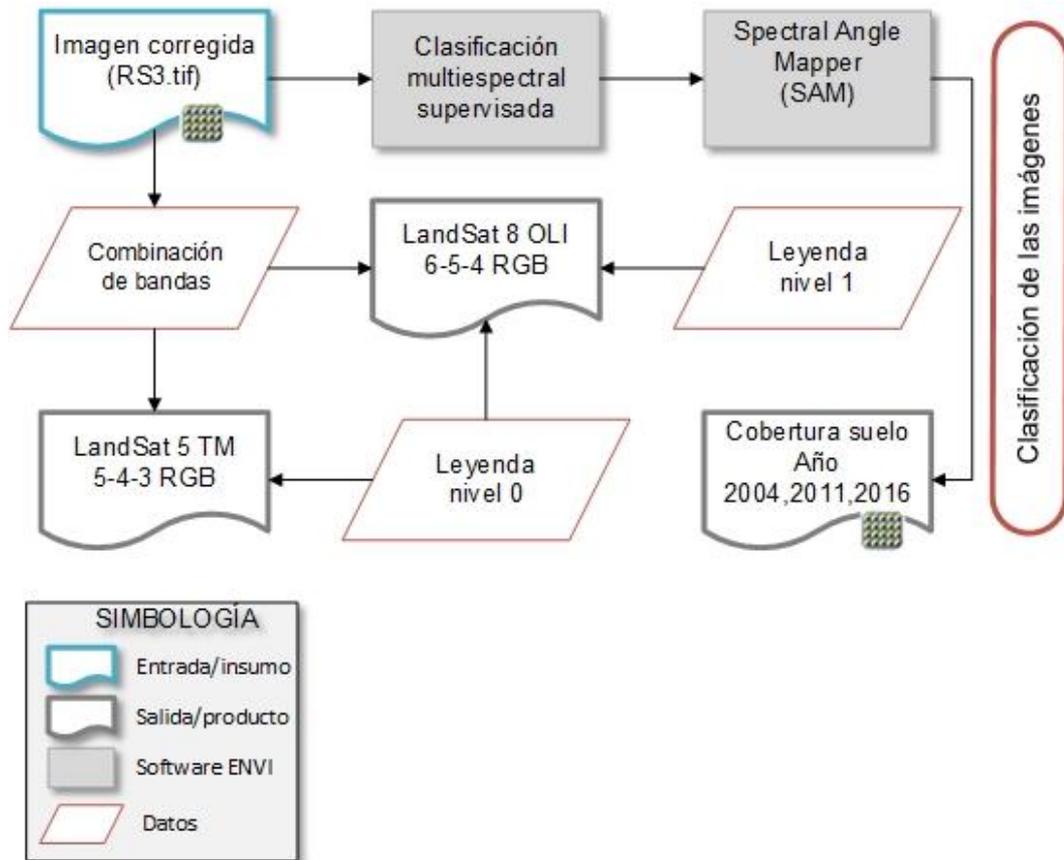


Figura 24. Proceso de Clasificación de la imagen satelital.

El algoritmo de SAM se basa en una suposición ideal de que un solo píxel de imágenes de detección remota representa un cierto material de cobertura de suelo y puede asignarse de forma única a una sola clase de cobertura de suelo, y que consiste simplemente en la medición de la similitud espectral entre dos espectros (figura 25). La semejanza espectral se puede conseguir considerando los espectros como vector en el espacio q -dimensional, en donde q representa el número de bandas. El algoritmo SAM indica la semejanza espectral entre dos espectros encontrando el ángulo entre los dos espectros, reconociendolos como vectores en un espacio dimensional al igual que el número de bandas. A través de la espectroscopia se mide la intensidad radiante y la energía de la interacción entre la materia y la luz para definir su estructura molecular. El compuesto que interactúa con la luz se comporta como un elemento pasivo, que absorbe algunos de los fotones emitidos dependiendo de su longitud de onda, para formar la llamada firma

espectral. Una vez que se obtiene el espectro de la reflectancia difusa, se debe procesar para la identificación, clasificación o discriminación del material.

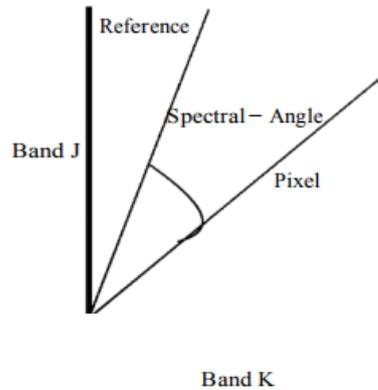


Figura 25. Representación del ángulo de referencia.

Fuente: Rashmi et al. (2014).

El algoritmo SAM generaliza esta interpretación geométrica al espacio n-dimensional, aplicando la siguiente ecuación (Rashmi, Addamani, Venkat y Ravikiran 2014):

$$\alpha = \cos^{-1} \left[\frac{\sum_{i=1}^{nb} t_i r_i}{\sqrt{\sum_{i=1}^{nb} t_i^2} \sqrt{\sum_{i=1}^{nb} r_i^2}} \right] \quad (13)$$

Donde;

nb: El número de bandas en la imagen.

t: Espectro de píxeles.

r: Espectro de referencia, y

α (alfa): Ángulo espectral.

Post-Clasificación; La Post-clasificación es el método que requiere de la rectificación y clasificación de cada imagen, para luego ser comparados píxel a píxel (Jensen, Lin, Yang, Ramsey III, Davis y Thoemke 1991; Xiuwan 2002), en el caso del estudio, muchos estudios demuestran la potencialidad para clasificar áreas de bosque, no bosque y áreas deforestadas a través de una comparación multitemporal (Angulo 2011; Bocco et al. 2001; Chuvieco et al. 2008; Mas et al. 1996). Previamente a este proceso se requirió de puntos de validación, para lo cual en el presente trabajo se realizó a través de la recolección de puntos de las áreas de entrenamiento extraídas de las diferentes zonas de áreas deforestadas en el distrito de Iberia, a través de la verificación in situ mediante del uso de GPS (Garmin Map 60 CSx, y Garmin Map 62 CSx). Posteriormente se realizó la validación a través de una matriz de confusión (cuya exactitud fue medida mediante el índice de Kappa). Concluida esta fase, se procedió a transformar los resultados a un formato vectorial para su procesamiento. El proceso de Post-clasificación de la imagen fue el siguiente (figura 26).

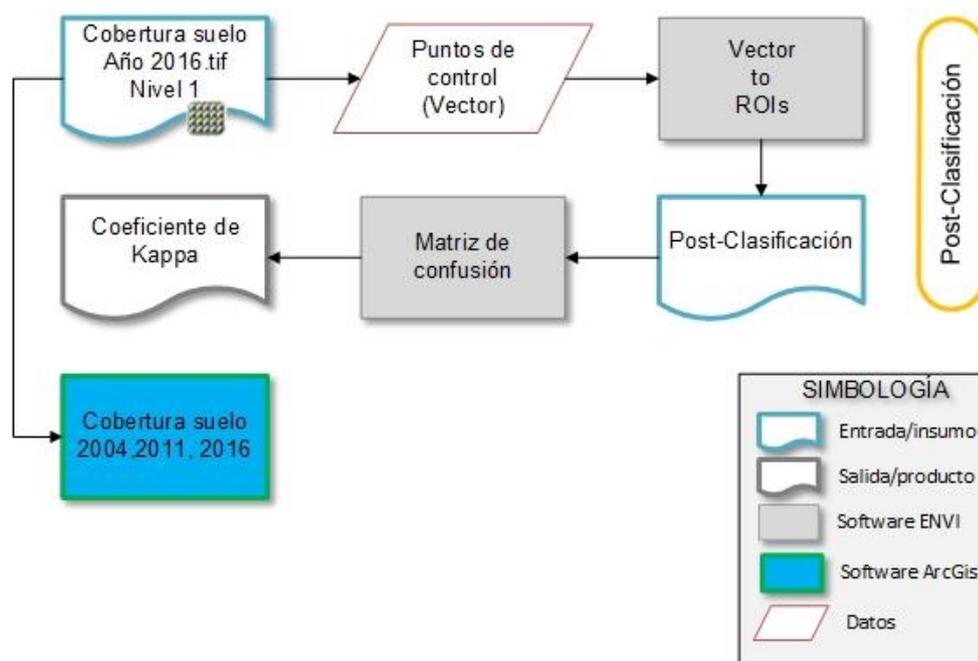


Figura 26. Proceso de Post-Clasificación de la imagen satelital.

3.8 Tratamientos de los datos

Se aplicó la matriz de confusión, test de estadística descriptiva usada para comparar una clasificación resultante con información fehaciente de terreno (Chuvieco 2002; Chuvieco y Hantson 2010; Elijah y Jensen 1996). La exactitud o precisión de este test es medido por el Índice de Kappa el cual “refleja la concordancia inter-observador y puede ser calculado en tablas de cualquier dimensión, siempre y cuando se contrasten dos observadores” (Cerde y Villarroel 2008).

El coeficiente kappa (κ) “toma valores entre -1 y +1; mientras más cercano a +1, mayor es el grado de concordancia inter-observador; por el contrario, un valor de $\kappa = 0$ refleja que la concordancia observada es precisamente la que se espera a causa exclusivamente del azar”. (Cerde y Villarroel 2008).

La interpretación del coeficiente kappa “se realiza correlacionando su valor con una escala cualitativa que incluye seis niveles de fuerza de concordancia (pobre, leve, aceptable, moderada, considerable y casi perfecta), simplificando la comprensión del mismo” (Cerde y Villarroel 2008). (tabla 14)

Tabla 14. Valoración del coeficiente kappa.

Coeficiente Kappa	Fuerza de la Concordancia
0,00	Pobre
0,01 – 0,20	Leve
0,21 – 0,40	Aceptable
0,41 – 0,60	Moderada
0,61 – 0,80	Considerable
0,81 – 1,00	Casi perfecta

Fuente:(Cerde y Villarroel 2008; Landis y Koch 1977).

Para la validación, se realizó una salida de campo con la finalidad de tomar datos del terreno y contrastar con los datos generados en gabinete a través de una Matriz de Confusión e Índice de Kappa.

Según el método de distribución binomial, donde se calculó 388 muestras de entrenamiento que han sido distribuidos por categorías de clasificación (Chuvieco 1996; Chuvieco y Salas 1996; Jensen, Lin, Yang, Ramsey III, Davis y Thoemke 1991), bajo un diseño de muestreo probabilista, criterio donde todas las unidades de muestreo que se encuentran en el mapa tuvieron una probabilidad de selección (probabilidad de inclusión). Las muestras de entrenamiento fueron distribuidas con un nivel de detalle "1": i. Áreas urbanizadas 55, ii. Áreas agrícolas 150, iii. Bosque 108, iv. Áreas con vegetación pacaes y arbustivos 75. La colección de muestras se realizó en el mes de julio del año 2017. En la colección de datos de campo se utilizó el formato del Centro para el Estudio de Instituciones, Población y Cambios en el Medio Ambiente de la Universidad de la Indiana (CIPEC).

3.9 Análisis predictivo

Duante el análisis de los cambios originados sobre la cobertura boscosa durante los años 2004 al 2011, se determinó la tendencia de cambio y así deducir el área posible de bosque a deforestación al año 2016.

La búsqueda de ambientes o modelos se basó en las dinámicas originadas en las sucesiones cronológicas de la cobertura boscosa y el estudio de condiciones físicas, bióticas y antrópicas que posiblemente contribuyan en los cambios producidos, tales como accesos viales, hidrografía, centros poblados, modelos de elevación digital, tendencias de la deforestación y otros.

Para la modelación de la deforestación al año 2016 y 2030 se aplicó el método de Cadenas de Markov, que "simula la predicción del estado en un sistema en un tiempo determinado a partir de dos estados precedentes" (t_0 y t_1), (Paegelow, Olmedo y Toribio 2002; Rodríguez y Bautista 2006). En este

caso las recientes condiciones de probabilidad y uso de los cambio en el distrito de Iberia con proyección el año 2030.

El algoritmo comprende el proceso $i \in N$ con espacios de estados E:

$$P(X_{n+1} = y | X_n = x_n, \dots, X_0 = x_0) = P(X_{n+1} = y | X_n = x_n) \quad (15)$$

Donde $x_n \in E$. “En procesos con larga memoria el valor que toma el proceso en cada paso depende de todo el pasado” (Vega 2004).

Para el análisis prospectivo se aplicó el módulo Land Change Modeler (LCM) de software TerrSet, que modeliza, describe y caracteriza las transformaciones entre las categorías (figura 27). El procedimiento fija vínculos entre variables explicativas de diferente naturaleza “drivers” con las diferentes categorías de usos del suelo, usando el método de redes neuronales.

El módulo LCM abordó la representación a futuro considerando el potencial de transición entre las categorías. Primeramente, se seleccionó las transiciones a tomar en cuenta para crear el diseño tomando en cuenta todas las transiciones reales. La selección se basa en el diseño, para excluir las transiciones con superficies pequeñas en el grupo de la imagen. “Este último es el periodo transcurrido entre la cartografía más reciente de la fase de calibración y la fecha de simulación” proyectada (Bishop 1995; Li y Yeh 2002; Parlitz y Merkwirth 2000).

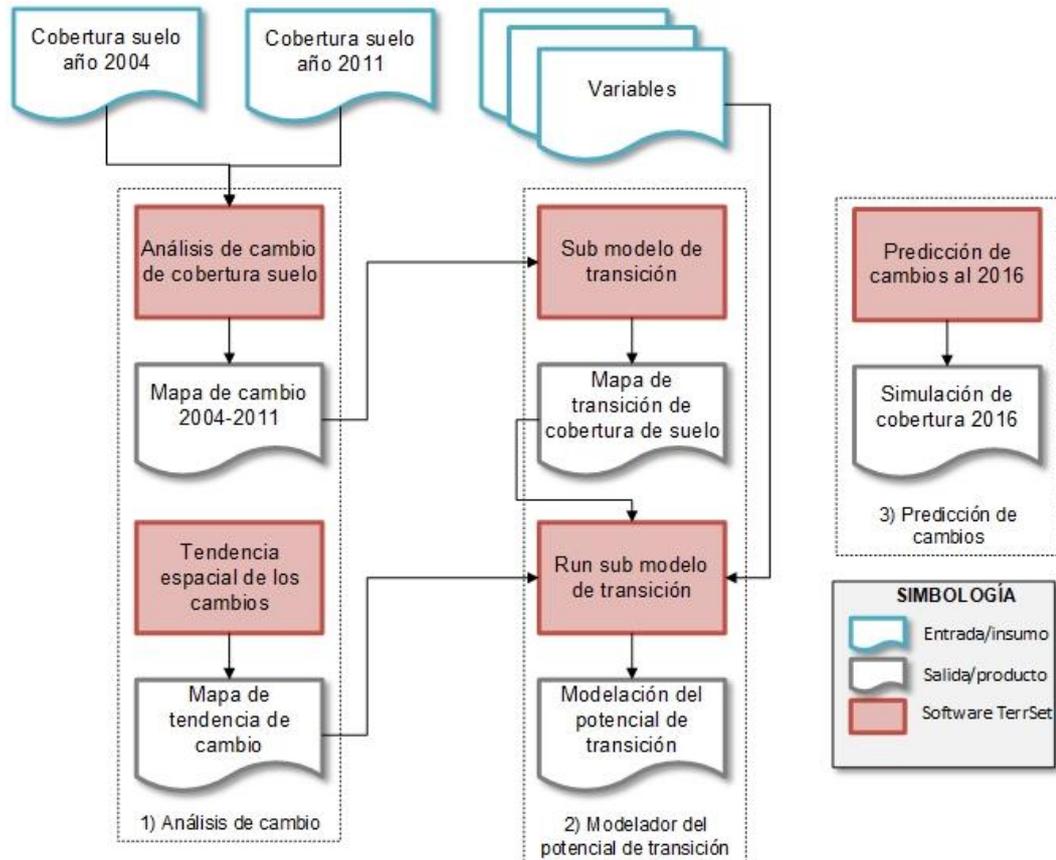


Figura 27. Proceso del módulo Land Change Modeler (LCM) del software TerrSet.

3.9.1 Análisis de cambio

Para el análisis prospectivo se aplicó el módulo Land Change Modeler (LCM) del software TerrSet, que explica, caracteriza y diseña los cambios entre las categorías. La técnica indica relaciones entre variables explicativas de distinta naturaleza “drivers” y las variables de usos del suelo, usando la técnica de las redes neuronales (figura 28). Como parte del procedimiento del LCM se relacionarán, primeramente los mapas de cobertura para los años 2004 y 2011, seguidamente, 2011 y 2016. Las categorías son: 1. Bosque, 2. Deforestación y 3. No bosque

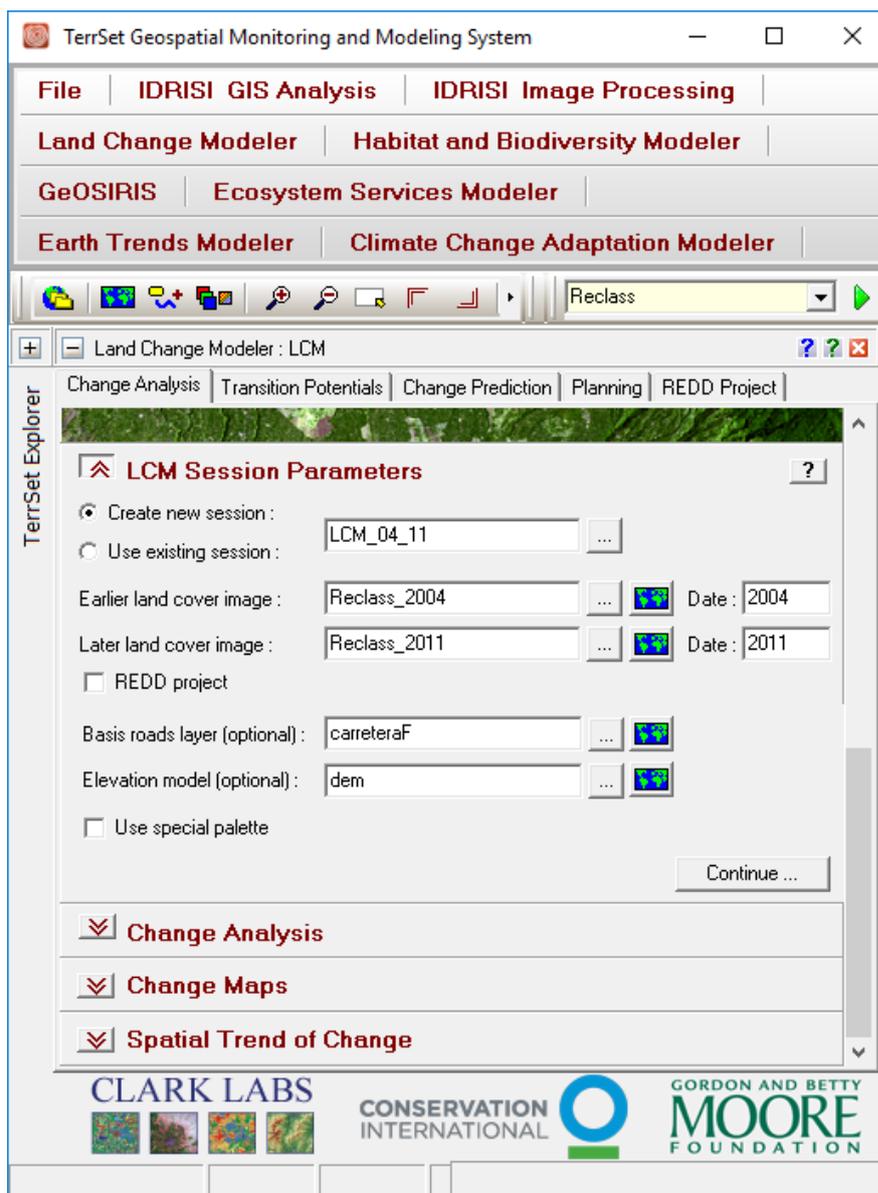


Figura 28. Parámetros para el módulo Land Change Modeler (LCM) del software TerrSet.

Para la construcción del modelo al periodo 2016 se partió de los mapas de cobertura de los años 2004 y 2011, prediciendo la probabilidad de cambio de uso del suelo (bosque a deforestación) que pueda ocurrir para el periodo determinado.

Dicha información nos permitió iniciar con el análisis de los cambios de uso del suelo. Este módulo permite hacer una evaluación gráfica de los cambios ocurridos y principalmente una evaluación cartográfica (figura 29 y 30).

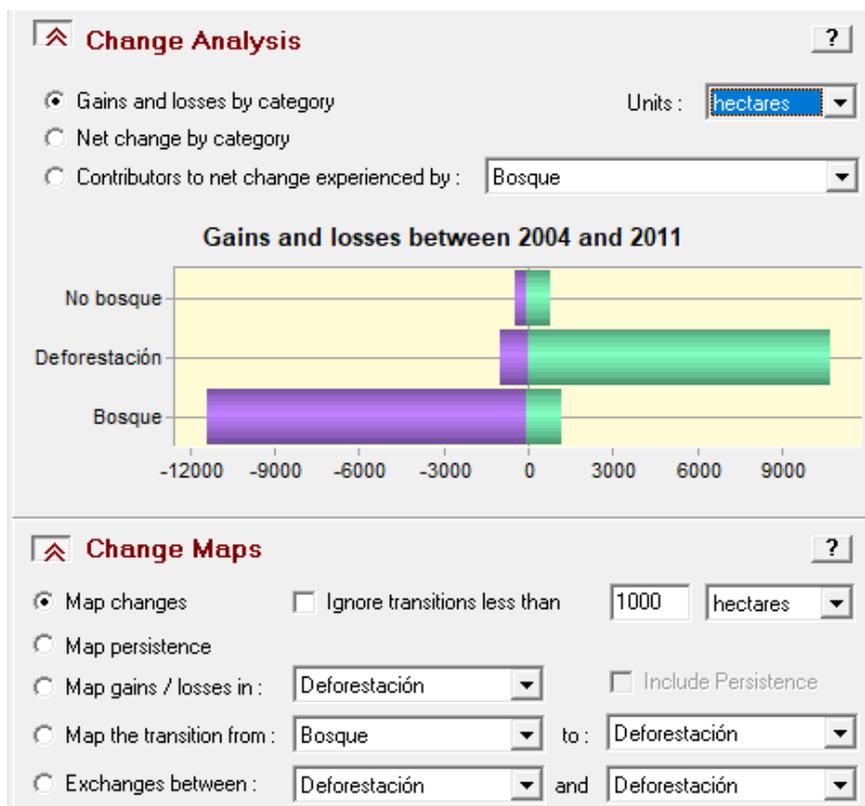


Figura 29. Herramienta ganancias y pérdidas por categoría.

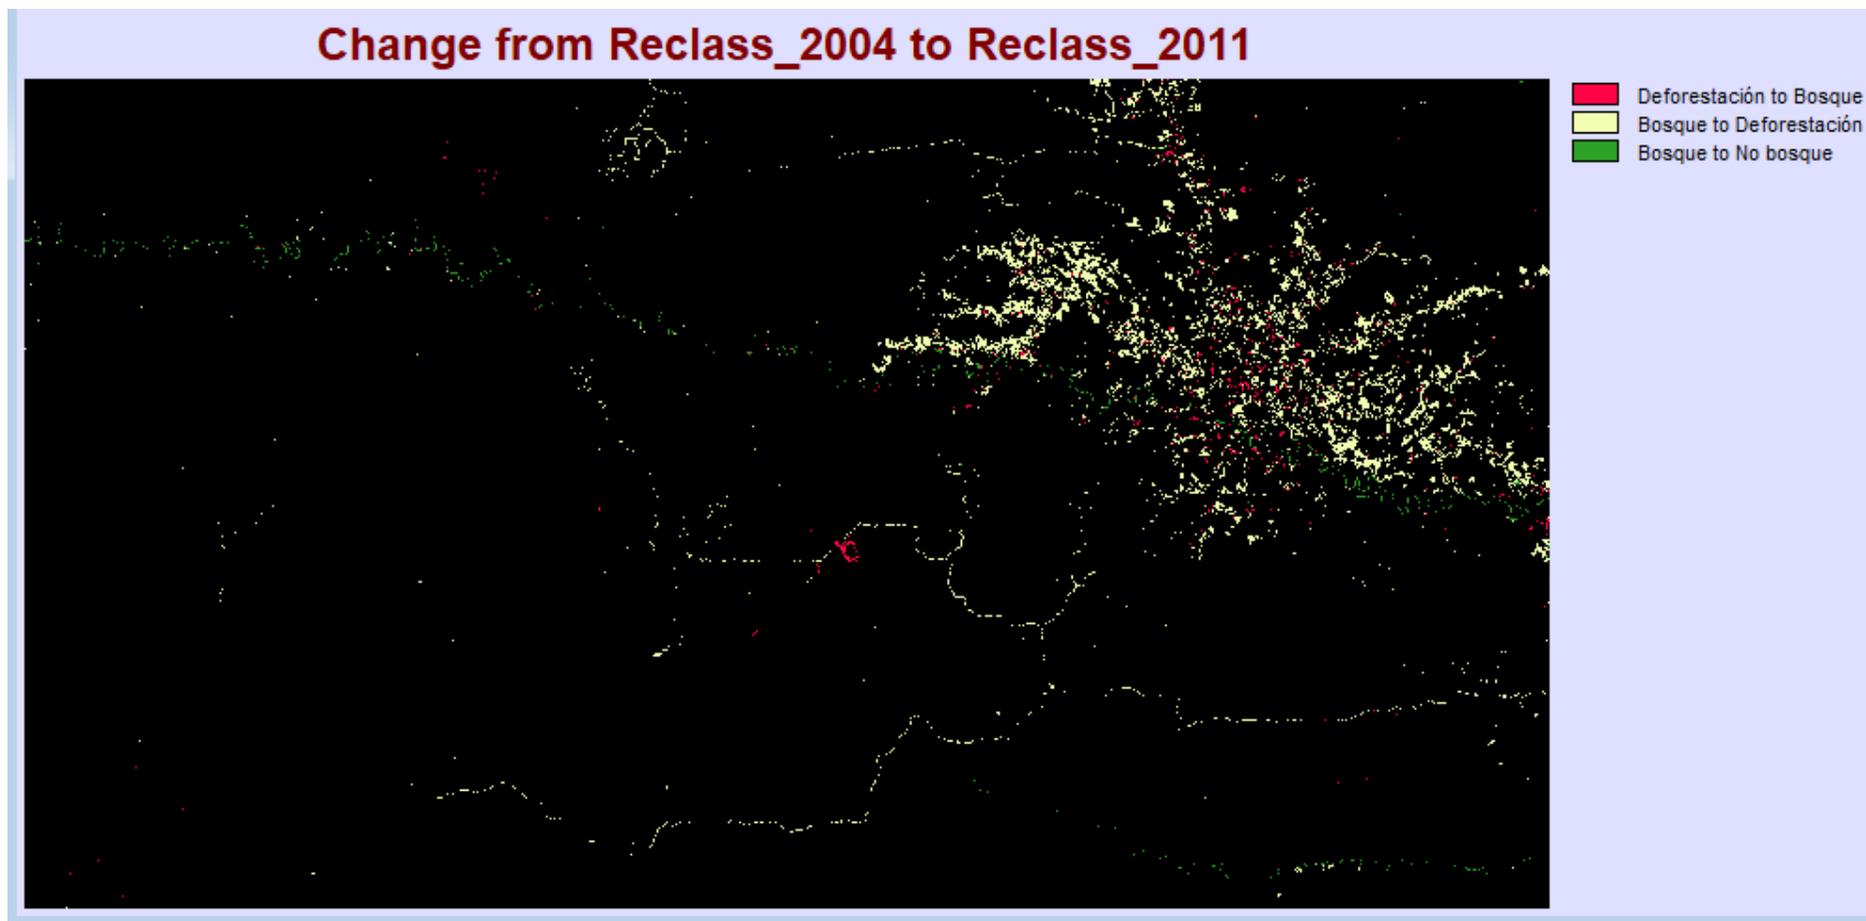


Figura 30. Mapa de cambio (ganancias y pérdidas) por categoría.

La tendencia espacial de los cambios es una opción que nos permite determinar la tendencia de los cambios de uso de suelo. En paisajes controlados por la actividad antrópica, las pautas de cambio puede ser complejas y, por tanto, difícil de interpretar.

Para facilitar la interpretación en estos contextos, se ha proporcionado una herramienta de análisis de tendencia espacial. Este es un mejor ajuste a la superficie de tendencia polinomial para los patrones de cambio. El valor por defecto es una superficie de 3^{er} orden que es bueno para tener un amplio panorama (figura 31 y 32).

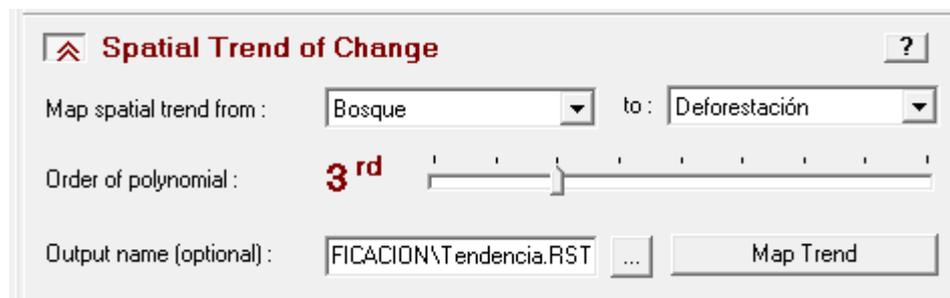


Figura 31. Herramienta tendencia polinomial de 3er orden para los patrones de cambio.

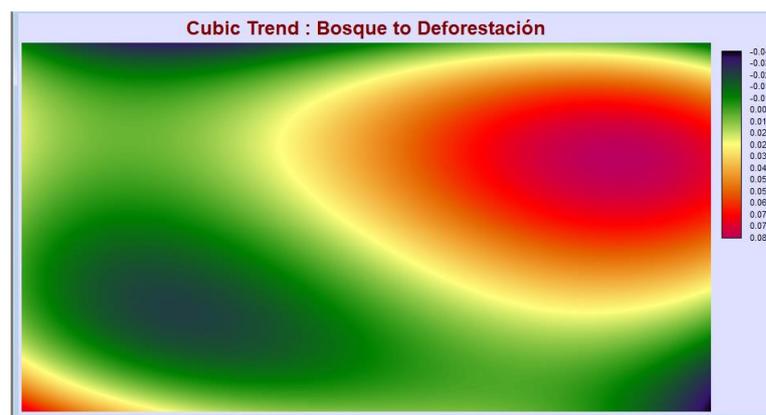


Figura 32. Mapa de tendencia polinomial de 3er orden para los patrones de cambio.

Para la construcción del modelo al periodo 2016 y posteriormente al 2030, se consideró variables ambientales (físicas) y antrópicas como accesos

viales (primaria y vecinales), centros poblados, hidrografía, modelo de elevación digital, pendiente, cambio de uso 2004-2011, y tendencia de la deforestación (figura 18). Con estos mapas de restricciones, se determinó las nuevas condiciones de uso y de probabilidad de cambio en el distrito de Iberia hacia el año 2030.

3.9.2 Potencial de transición

En este módulo se aplican dos metodologías (Redes Neuronales y Regresión Logística), el cual necesita como parámetros mínimos, las transiciones entre los diferentes usos del suelo y mínimo una variable explicativa.

Siguiendo con el proceso lógico del diseño se continúa con el cálculo probable de transición para definir los submodelos. Para el estudio se considerarán dos transiciones entre los mapas de uso en los diferentes períodos estudiados, que fueron definidos como Bosque a Deforestación y Deforestación a Bosque (figura 33 y 34).

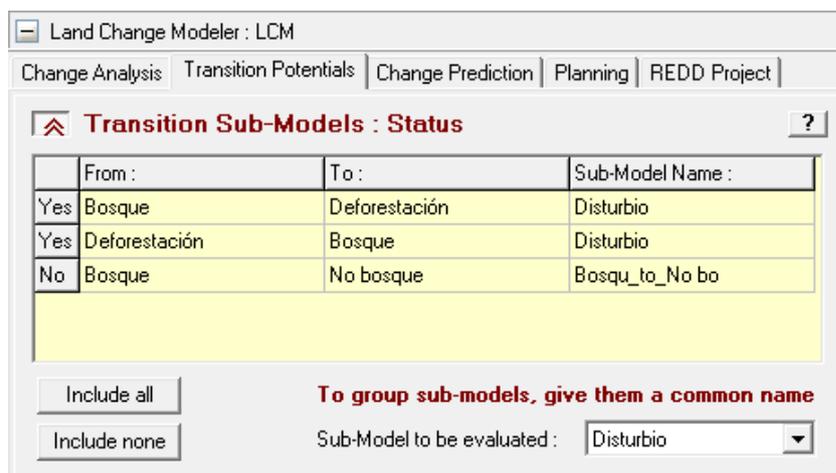


Figura 33. Herramienta de potencial de transición.

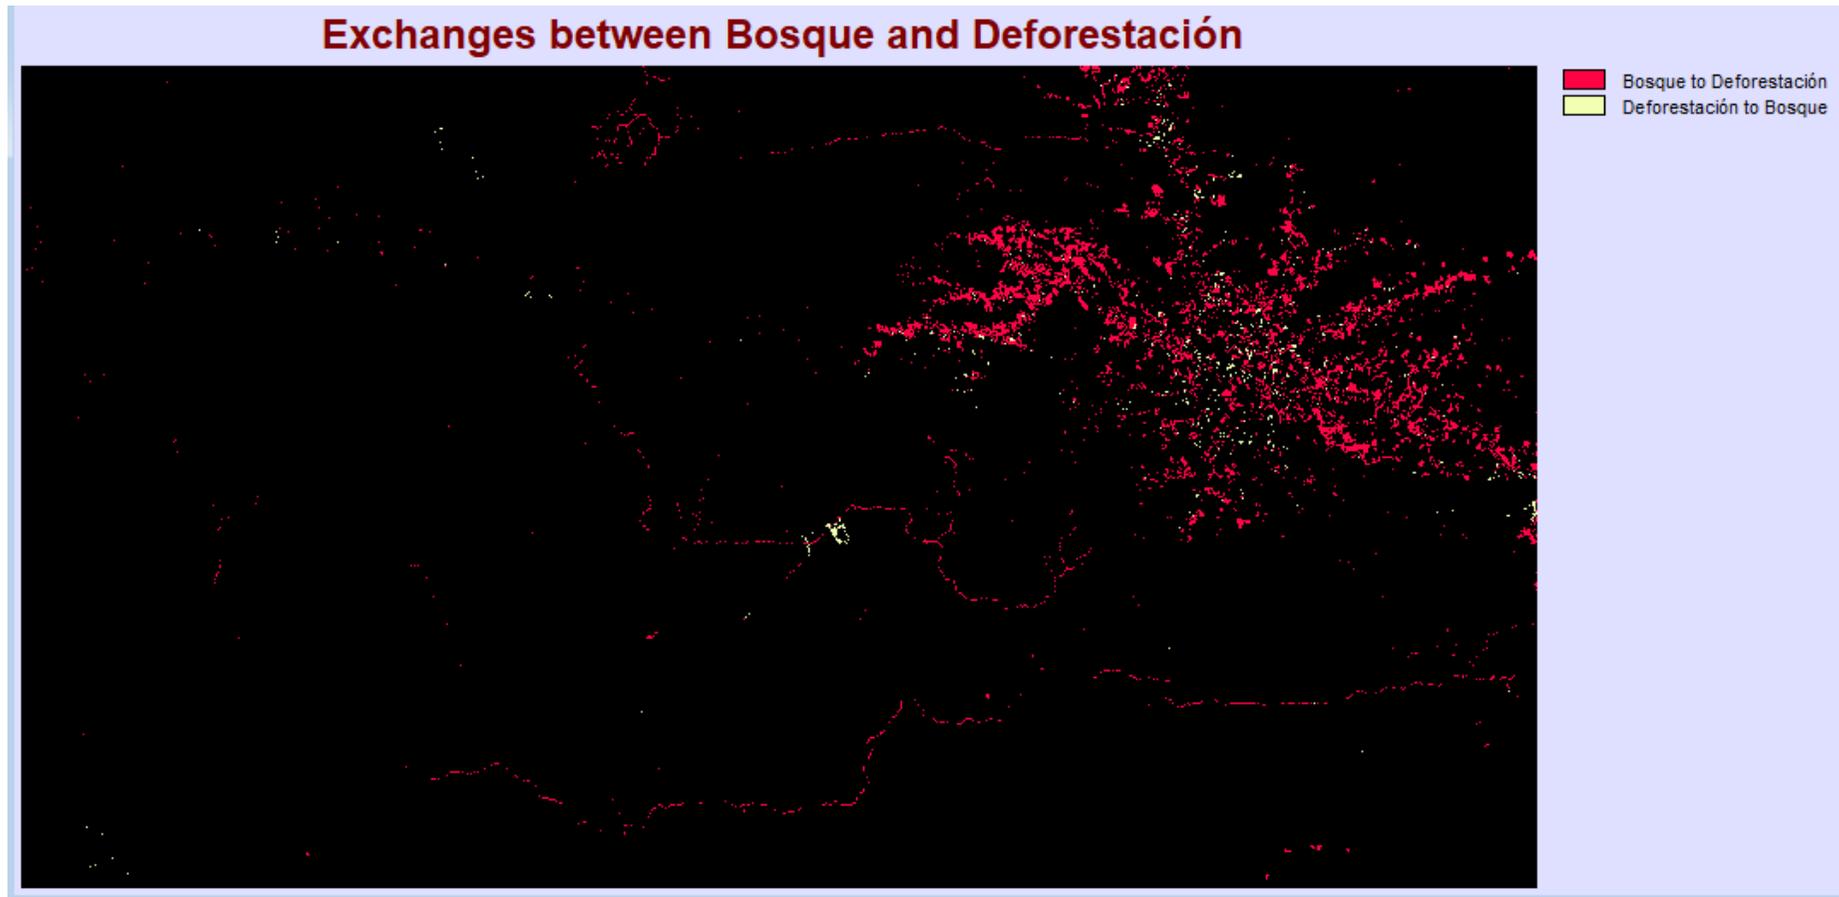


Figura 34. Mapa de cambio Bosque a Deforestacion y Deforestacion a Bosque.

Fuente: elaboración propia

Para determinar la evidencia de probabilidad de la transición se uso el mapa de cambio año 2004-2011 y la cobertura de suelo del año 2004 (figura 35 y 36).

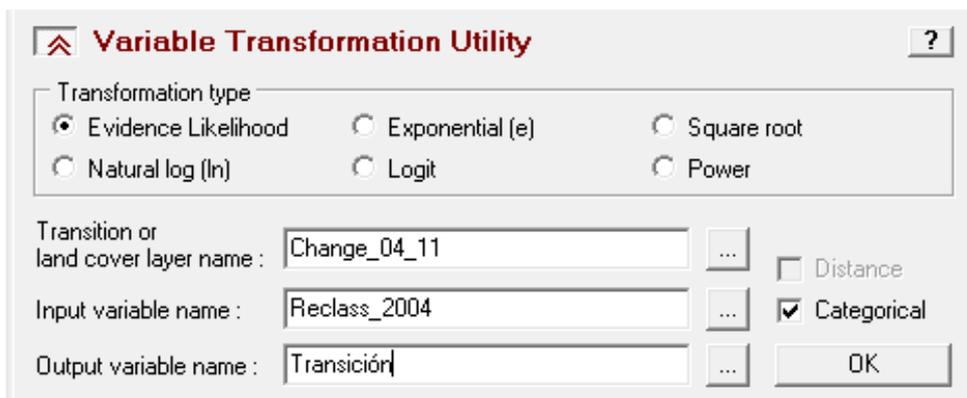


Figura 35. Herramienta transformación de variable..

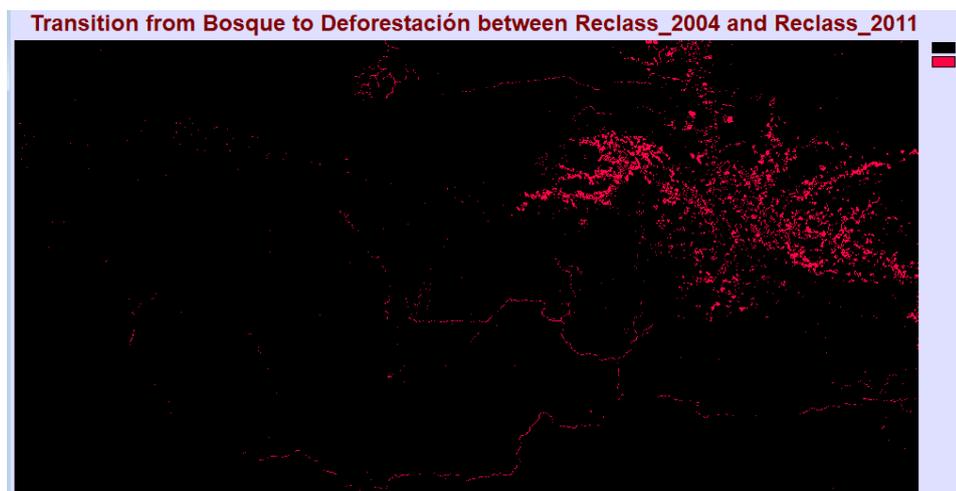


Figura 36. Mapa de la modelación de transición.

Las variables utilizadas en el modelo fueron MDT, pendiente, accesos viales (primaria, secundarias y tochas), centros poblados (urbanos y rurales) y hidrografía (figura 12,14, 15, 16, 17) respectivamente; tendencia de la deforestación y transición (figura 32 y 36) respectivamente. De ellas, las variables MDT, pendiente, accesos viales centros poblados y hidrografía fueron transformadas y ajustadas en términos comunes antes de ser usadas

en el modelo. Para ello, se aplicó el comando COST grow del software TerrSet, que permite obtener una superficie de distancia/proximidad (también conocida como superficie de costo) donde la distancia se mide como el menor costo (en términos de esfuerzo, gasto, etc.) al moverse sobre una superficie de fricción (Eastman 1987; Tomlin 1986) (figura 37).

El uso y transformación de las variables (drivers) utilizadas en el modelo, se deduce: **1. Modelo de elevación digital**, Las áreas urbanas y las actividades extractivas se ubican en las zonas media., **2. La pendiente** las zonas altas presentan difícil accesos y por esto el cambio en la cobertura es menor., **3. Distancia a accesos viales (primaria, secundarias y trochas)** para tener en cuenta la contribución los habitantes en el acceso al bosque y las actividades antrópicas puedan ocasionar cambios en la cobertura vegetal., **4. Distancia a centros poblados**, directamente relacionado con accesos viales, y que permite acceso al aprovechamiento de los recursos naturales., **5. Distancia a ríos y quebradas**, facilitan en acceso a lugares con mucha cobertura vegetal., **6. Tendencia de la deforestación**, en función a los análisis de cambios de los periodos evaluados se determinó el patrón de movilidad de la deforestación, patrón que fue incorporado en el modelo predictivo para los periodos propuestos., y

7. Transición, temática importante porque permitió incorporar la dinámica de la deforestación como base para la predicción de los periodos a evaluar.

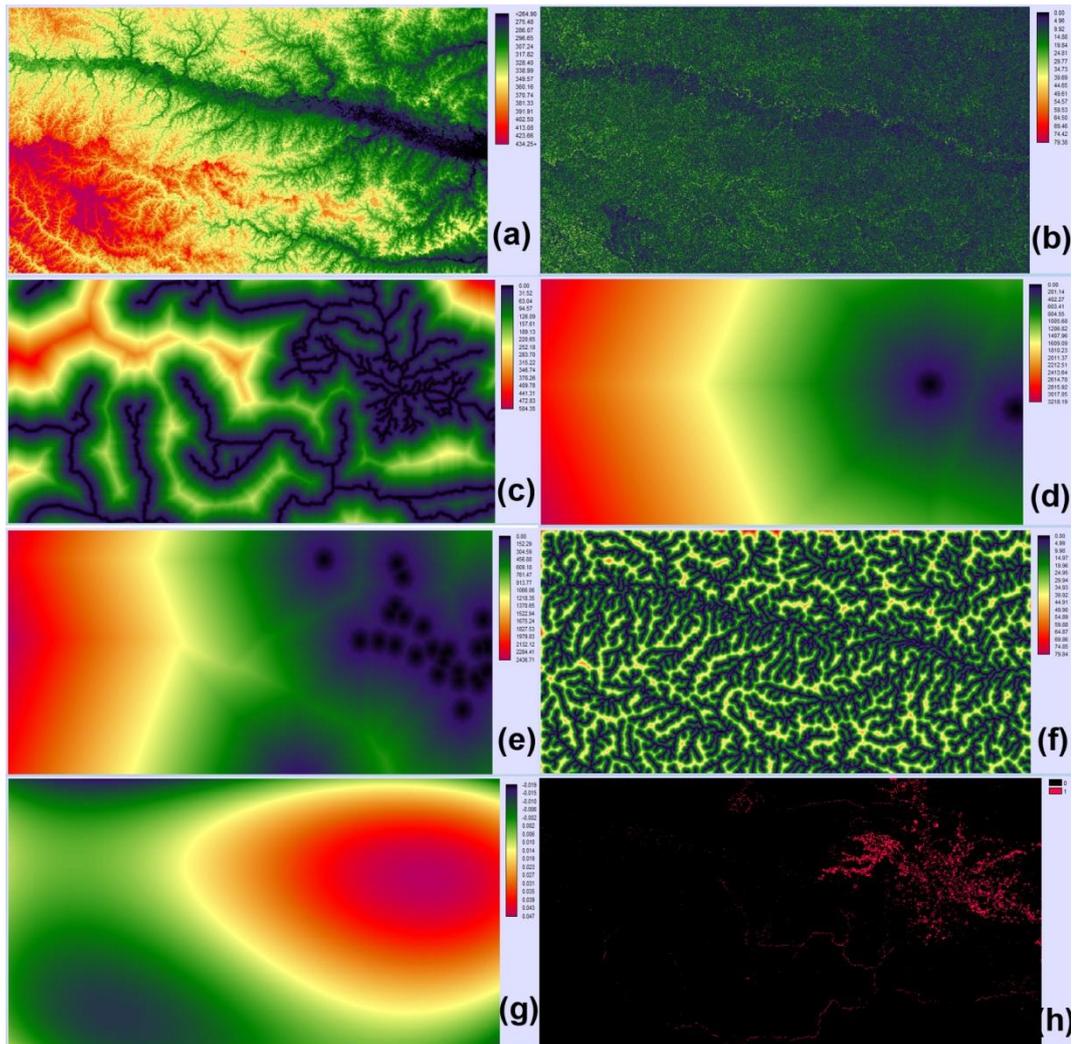


Figura 37. Variables utilizadas en el modelo prospectivo de cambio de uso del suelo, periodo 2016 y 2030. (a) Modelo de elevación digital - MDT, (b) Pendiente, (c) Red vial principal y secundaria, (d) Centros urbanos, (e) centros rurales, (f) Red hidrográfica, (g) Tendencia de la deforestación, y (h) Transición.

Fuente: elaboración propia

El submodelo se generó con MLP Neural Network, se generaron mapas de potencial transición. La precisión de cada diseño tiene que estar sobre el 75%, aunque dependerá en gran medida de la variabilidad de las variables utilizadas (Eastman 2009; Eastman 2012). En nuestro caso, el submodelo bosque a deforestación y deforestación a bosque llegó a una exactitud de 85.23% (figura 38).

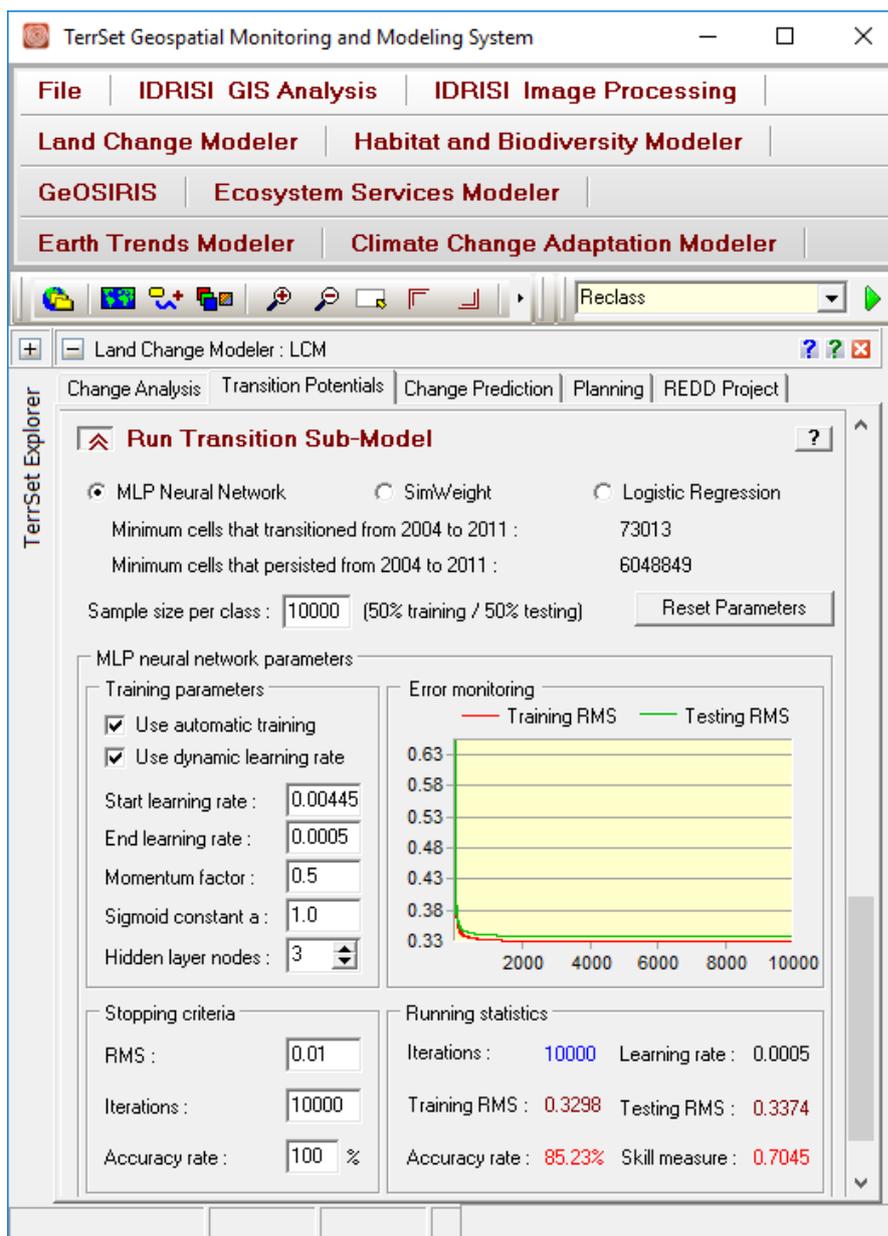


Figura 38. Sub modelo de transición del Land Change Modeler – TerrSet 2004-2011, para el periodo 2016.

En cuanto a la fiabilidad de la medida de habilidad en las categorías analizadas de transición y persistencia, se obtuvo un mejor comportamiento en la clase transición de bosque y deforestación con 87,18% y 85,14%, mientras que en menor grado en la clase persistencia de bosque a deforestación y deforestación a bosque con 83,73% y 82,85% respectivamente (tabla 15), sin embargo, los valores se encuentran por encima del mínimo requerido (75%) (Eastman 2009; Eastman 2012).

Tabla 15. Comportamiento del modelo por transición y persistencia.

Clase	Medida de habilidad
Transición : Bosque a Deforestación	0,8718
Transición : Deforestación a Bosque	0,8514
Persistencia : Bosque	0,8373
Persistencia : Deforestación	0,8285

Por otra parte, el submodelo, también permitió la contrastación de las variables por etapas (tabla 16), obteniéndose una precisión general con todas las variables de 85,23%. Asimismo se puede observar (etapa 3) que las variables distancia a accesos viales (primarios y vecinales), distancia a centros poblados, ríos, Modelo de elevación digital, pendiente y tendencia de la deforestación contribuyen en un 89,30%, ligeramente mayor al obtenido con todas las variables incluidas.

Sin embargo, en la etapa 7, el submodelo con una variable incluida (tendencia de la deforestación) aportó un 80,97%, lo que demuestra lo imprescindible que representa para el modelo prospectivo.

Tabla 16. Contrastación de variables por etapas.

Modelo	Variables incluidas	Precisión (%)	Medida de habilidad
Con todas las variables	Todas las variables	85,23	0,7060
Etapa 1: var.[7] constante	[1,2,3,4,5,6,8]	85,30	0,7060
Etapa 2: var.[7,4] constante	[1,2,3,5,6,8]	85,23	0,7046
Etapa 3: var.[7,4,6] constante	[1,2,3,5,8]	85,25	0,7050
Etapa 4: var.[7,4,6,5] constante	[1,2,3,8]	84,91	0,6982

Modelo	Variables incluidas	Precisión (%)	Medida de habilidad
Etapa 5: var.[7,4,6,5,3] constante	[1,2,8]	84,64	0,6928
Etapa 6: var.[7,4,6,5,3,2] constante	[1,8]	84,53	0,6906
Etapa 7: var.[7,4,6,5,3,2,1] constante	[8]	80,97	0,6194

*1=distancia acceso vial primario y secundario, 2=distancia centro poblado rural, 3=distancia a centro poblado urbano, 4=distancia a ríos y quebradas, 5=modelo de elevación digital, 6=pendiente, 7=Transición de cobertura 2004-2011, y 8=tendencia de la deforestacion.

El modelo MLP Neural Network se ha aplicado al submodelo de transición obteniéndose dos mapas de potencial transición, representando espacio-temporal del potencial de cambio; bosque a deforestacion y deforestacion a bosque (figura 39 y 40). Las leyendas, que se encuentran entre 0 a 1, muestra la capacidad que cada píxel tiene para modificar una categoría a otra. De todas maneras el modelo aplica todos los parámetros que el especialista ha metido a los submodelos, el LCM escoge, primeramente, los píxeles con la categoría inicial de cada transición y usa una máscara para conseguir un resultado más real.

Según los resultados, el mapa potencial de transición de bosque a deforestacion tendrá una mayor tendencia creciente en el área de influencia de acceso a la via principal, secundaria y trochas, decreciendo en las otras áreas del sector de estudio.

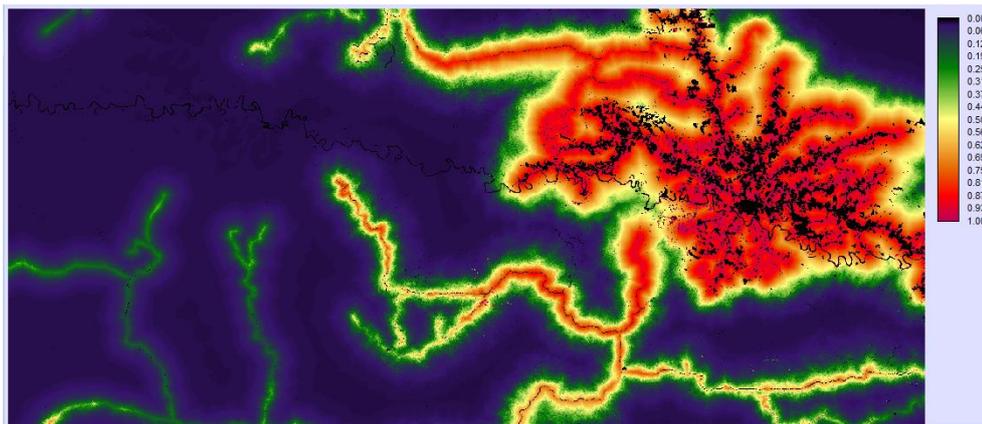


Figura 39. Potencial de transición de bosque a deforestación, modelo prospectivo 2016.

En el caso del mapa potencial de transición de bosque a deforestación, presenta un mejor comportamiento en las zonas de accesos viales (vecinal) para tener en cuenta como influye la presencia humana y el acceso que se tiene al bosque, pudiendo influir en el cambio de cobertura vegetal teniendo acceso al aprovechamiento de los recursos naturales.

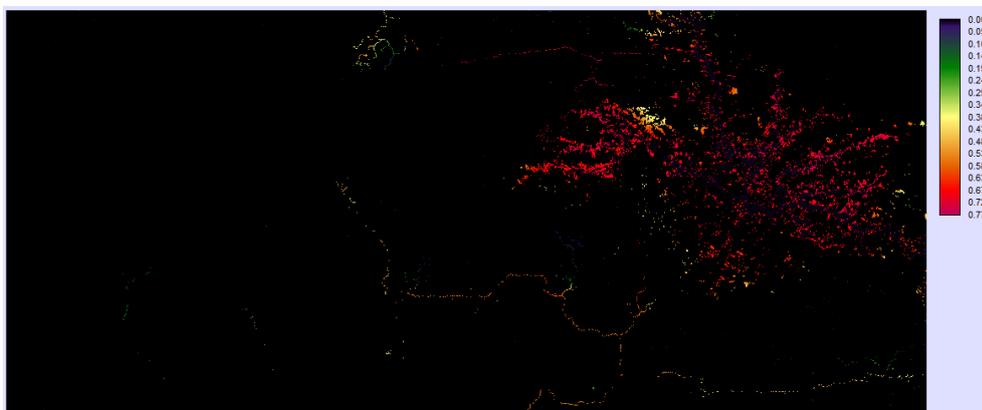


Figura 40. Potencial de transición de deforestación a bosque, modelo prospectivo 2016.

3.9.2.1 Prospectiva de cambio al año 2016 con Land Change Modeler (LCM)

En cuanto al modelo prospectivo (Change Prediction) del proceso de predicción del cambio dinámico de la cobertura de la tierra, se usó los mapas de potencial de transición creada (figura 20 y 21), la cantidad de cambio en

cada transición fue modelada con una probabilidad de cambio suave (*soft*) a través del método cadena de Markov del LCM.

La cantidad de años durante el primer mapa (2004) y el segundo mapa (2011) es de 07 años, mientras que el número de períodos de tiempo a proyectarse (2016) es de 5 años. Una vez ingresada la información al modelo se proyecta desde el año 2011 al 2016, el resultado del diseño se observa en la figura 41.

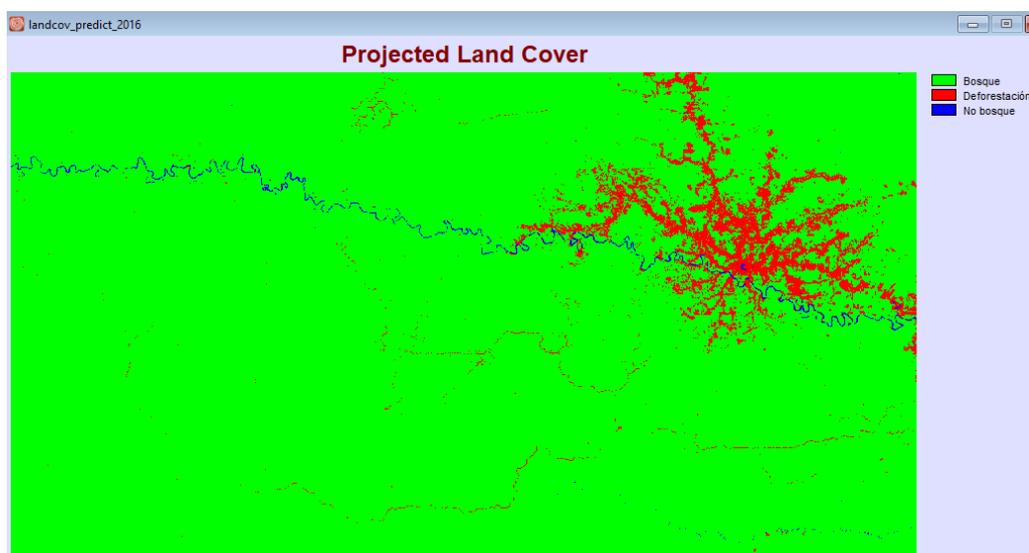


Figura 41. Prospectiva de cambio de uso: bosque a deforestación, periodo 2016.

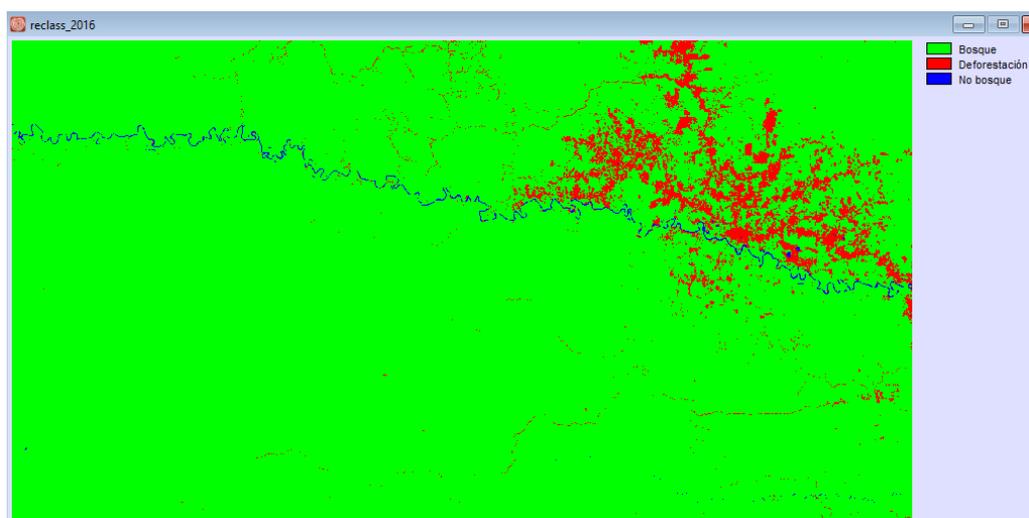


Figura 42. Cambio de uso de suelo; bosque a deforestación, periodo 2016.

La prospectiva de cambio al 2016, muestra una similitud con el resultado de la claificación de la imagen Landsat 8 OLI del periodo 2016 (figura 42), sin embargo, el modelo propectivo sobrestimo ligeramente la deforestacion en el acceso vial trochas.

3.9.3 Validación del modelo LCM

Antes de elaborar la simulación de cobertura de suelo para el año 2030 fue necesario evaluar la confiabilidad del modelo LCM y su interacción con las variables explicativas. Para esto se evaluó el error en cantidad y localización de los píxeles en el mapa simulado y la realidad. En consecuencia se desarrolló un primer modelo en donde se utilizaron las coberturas de suelo de los años 2004 y 2011 para simular al año 2016, y posteriormente comparar con la imagen observada de suelo del año 2016; por lo tanto la validación se efectuó mediante la comparación entre la imagen correspondiente a la simulación de cobertura de suelo del año 2016 y la imagen observada de cobertura de suelo del año 2016 (ver Figura 41 y 42).

El proceso de validación de la cobertura observada y la cobertura simulada se puede ver en la figura 43.

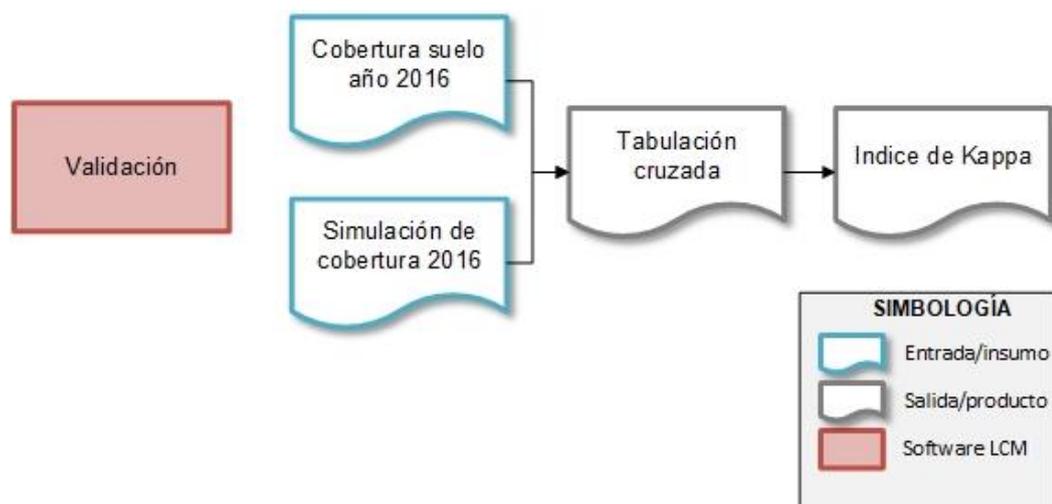


Figura 43. Proceso de validación de la cobertura observada y la cobertura simulada.

Para la validación se aplicó la herramienta “validation” (figura 44) del módulo Land Change Modeler (LCM) de software TerrSet, caracteriza, describe, y diseña las transiciones entre las categorías (figura 45).

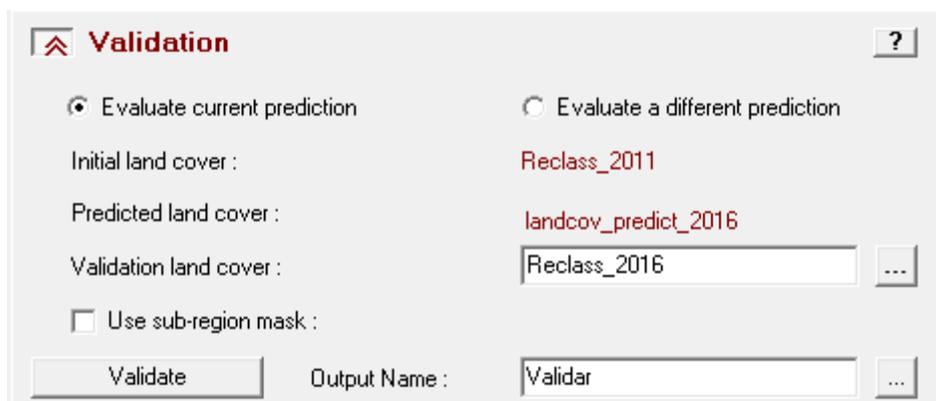


Figura 44. Herramienta de validación.

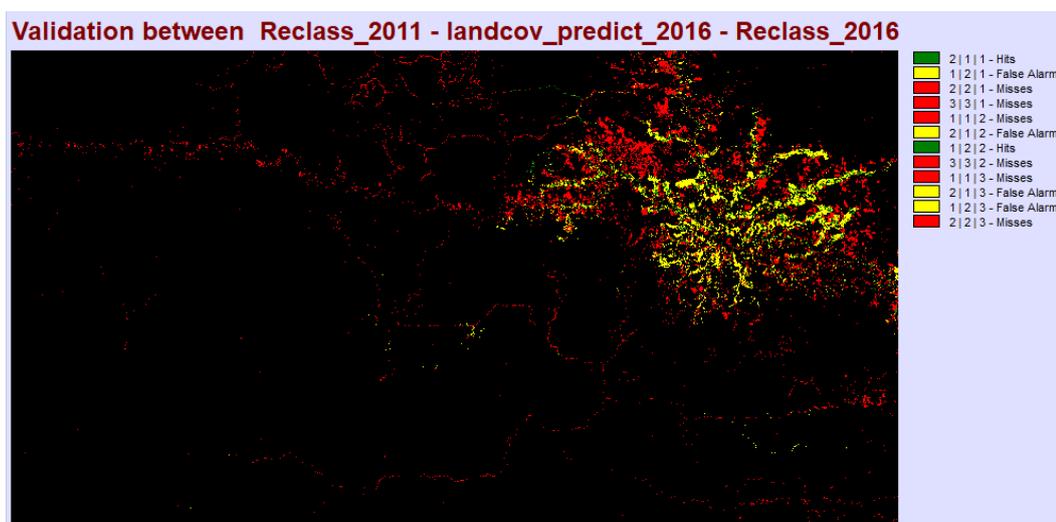


Figura 45. Modelización entre categorías.

Luego se realizó la validación con la herramienta Cross Tab del software TerrSet (figura 46).

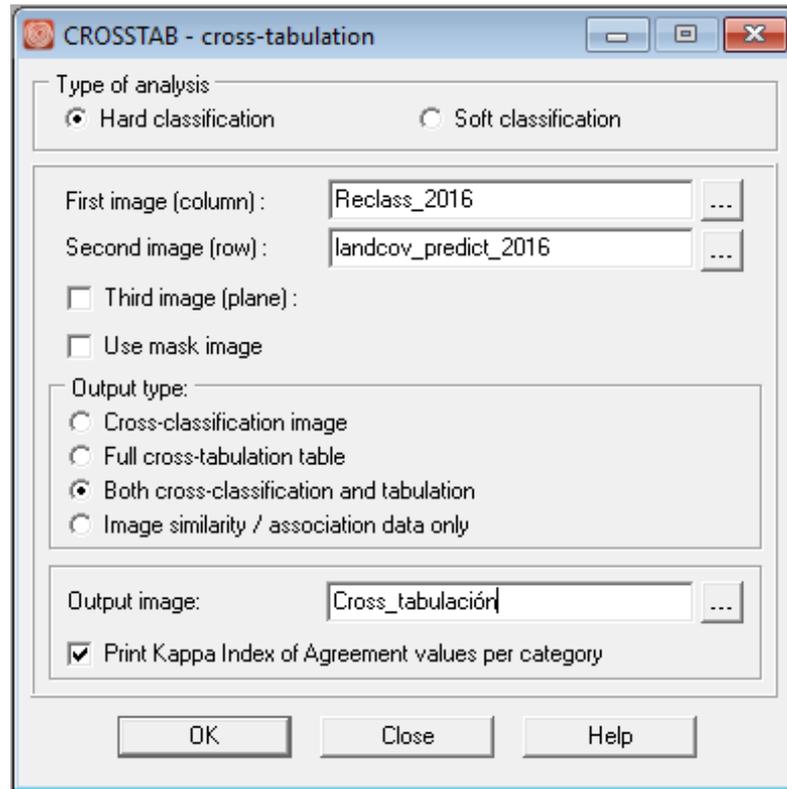


Figura 46. Herramienta Cross Tab.

LCM ofrece dos modos para la predicción de cambios: “Hard classification” una predicción dura está comprometida con un escenario específico. El resultado es un mapa de la superficie terrestre con las mismas categorías que los datos de entrada.

Donde la primera columna representa el mapa de referencia (cobertura de uso de suelo 2016) y la segunda las categoría del modelo predictico. Los datos muestran el grado de concordancia a nivel de mapa; del cual podemos determinar que existen grandes áreas en la categoria de bosque (1) y deforestacion (2) que coinciden en lo predicho y lo clasificado. Sin embargo, existe controversia en pequeñas áreas que el modelo predijo como deforestacion (3) y en realidad es bosque (1), del mismo modo, el modelo predijo áreas como bosque (1) y en realidad es deforestacion (3) (figura 47).

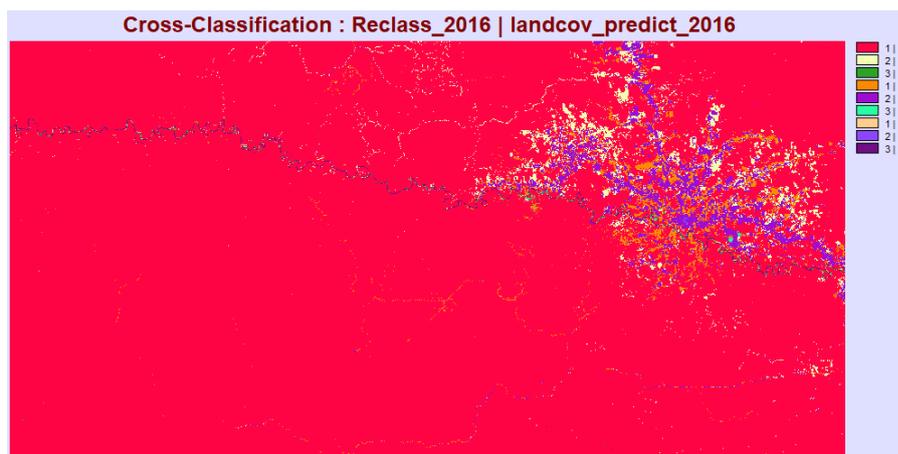


Figura 47. Clasificación cruzada; cobertura de uso de suelo 2016 y prospectiva 2016.

Bajo el mismo criterio, se analizó el reconocimiento cruzado de píxeles (cobertura de uso de suelo 2016 y prospectiva 2016). Donde 6 040 084 píxeles en la clase bosque fueron predichas correctamente, mientras 10 4701 fueron predichas como deforestación. En el caso de deforestación, 140 988 píxeles fueron predichas correctamente, y 3 643 incorrectamente como bosque (tabla 17).

Tabla 17. Reconocimiento cruzado de píxeles; cobertura de uso de suelo 2016 (columnas) y prospectiva 2016 (filas).

Clase	Bosque	Deforestación	No bosque	Total
Bosque	6 040 084	3 643	3 991	6 047 718
Deforestación	104701	140 988	3 543	249 232
No bosque	4 223	969	20 673	25 865
Total	6 149 008	145 600	28 207	6 322 815

Según los rangos del coeficiente kappa (κ) (0,9670), presenta una fuerza de concordancia casi perfecta (0,81 – 1,00), por lo que se deduce que nos encontramos ante un modelo prospectivo correcto (Cerde y Villarroel 2008).

3.9.4 Prospectiva de cambio al periodo 2030

Según los resultados y al buen ajuste del modelo prospectivo al 2016, se realizó la predicción para el periodo 2030, tomando como base la cobertura de cambio de uso de suelo de los años 2011 y 2016, es decir, 14 años a partir del periodo de referencia (2016).

En el caso del mapa potencial de transición (figura 48), y el mapa Prospectiva de cambio de uso al año 2030 (figura 49) se puede observar una tendencia creciente de conversión de bosque a deforestación en los accesos viales primarios, secundarios y en las zonas urbanas y rurales.

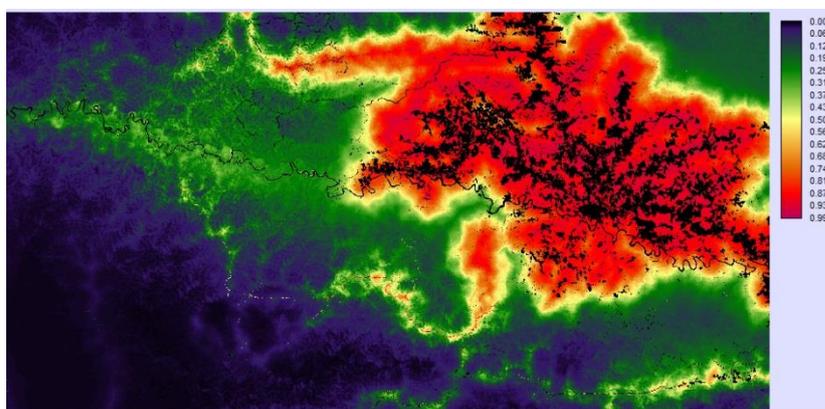


Figura 48. Potencial de transición proyectado, periodo 2030.

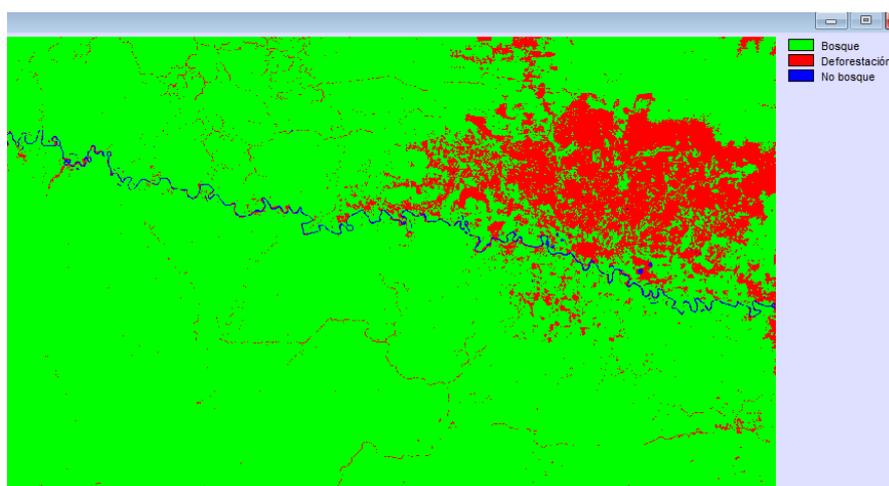


Figura 49. Prospectiva de cambio de uso: bosque a deforestación, periodo 2030.

3.10 Análisis estadístico

Para el análisis estadístico se utilizó la estadística descriptiva e inferencial, para ello se aplicó el programa Microsoft Excel, ENVI 5,3®, ArcGis 10,5® y el Modulo Land Change Modeler (LCM) del Software TerrSet.

Para el primer objetivo, sobre Analizar y cuantificar el cambio de uso del suelo (bosque a deforestación) entre 2004, 2011 y 2016 en el distrito de Iberia, Tahuamanu – Madre de Dios, se aplicó modelos predictivos para la clasificación de imágenes de satélite Landsat-8 para el año 2016, cuantificación y promedios de cambio de cobertura de bosque a deforestación, a través de una clasificación multiespectral supervisada en base al método de SAM (Spectral Angle Mapper), con la combinación de bandas 6, 5, 4 (ecuación 6) (Rashmi, Addamani, Venkat y Ravikiran 2014). Seguidamente se realizó la validación mediante una matriz de confusión (cuya exactitud fue medida mediante el índice de Kappa) (Cerdeña y Villarroel 2008; Landis y Koch 1977).

Respecto al segundo y tercer objetivo, sobre modelar y validar el proceso de deforestación para el año 2016 y 2030, se aplicó el modelo predictivo del método de Cadenas de Markov, disponible en el software TerrSet® - Clark Labs, Clark University USA (ecuación 7). Este proceso “simula la predicción del estado en un sistema en un tiempo determinado a partir de dos estados precedentes” (t_0 y t_1), en este caso las nuevas condiciones de probabilidad y uso de de cambio en el distrito de Iberia hacia el año 2030 (Paegelow, Olmedo y Toribio 2002; Rodríguez y Bautista 2006).

CAPÍTULO IV. RESULTADOS Y DISCUSIÓN

4.1 Cuantificación del cambio de uso de suelo entre 2004, 2011 y 2016 en el distrito de Iberia, Tahuamanu – Madre de Dios.

La clasificación multispectral supervisada en base al método de SAM (Spectral Angle Mapper), con la combinación de bandas 5,4,3 de la Imagen Landsat 5 TM para el periodo 2004, reporto 248 587,90 ha de bosque y 4 824,09 ha para la categoría de deforestación (tabla 18, figura 50).

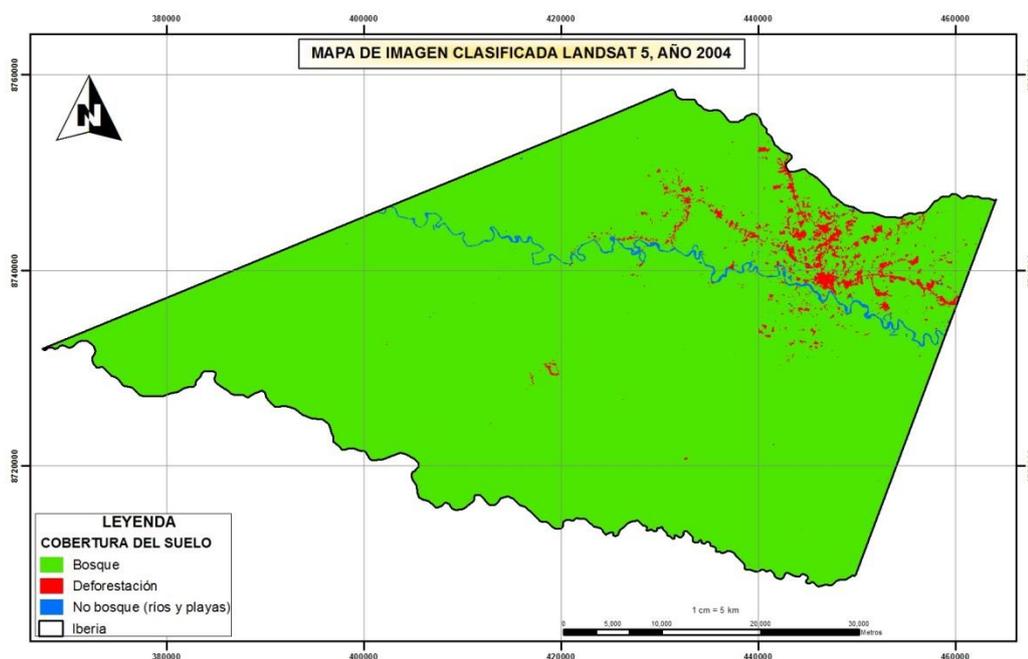


Figura 50. Imágen Landsat clasificada para el periodo 2004; cobertura de bosque y deforestación, distrito de Iberia, Tahuamanu – Madre de Dios.

La clasificación multispectral supervisada en base al método de SAM (Spectral Angle Mapper), con la combinación de bandas 5,4,3 de la Imagen Landsat 5 TM para el periodo 2011, reporto 241 151,91 ha de bosque y 12 260,08 ha para la categoría de deforestación (tabla 18, figura 51).

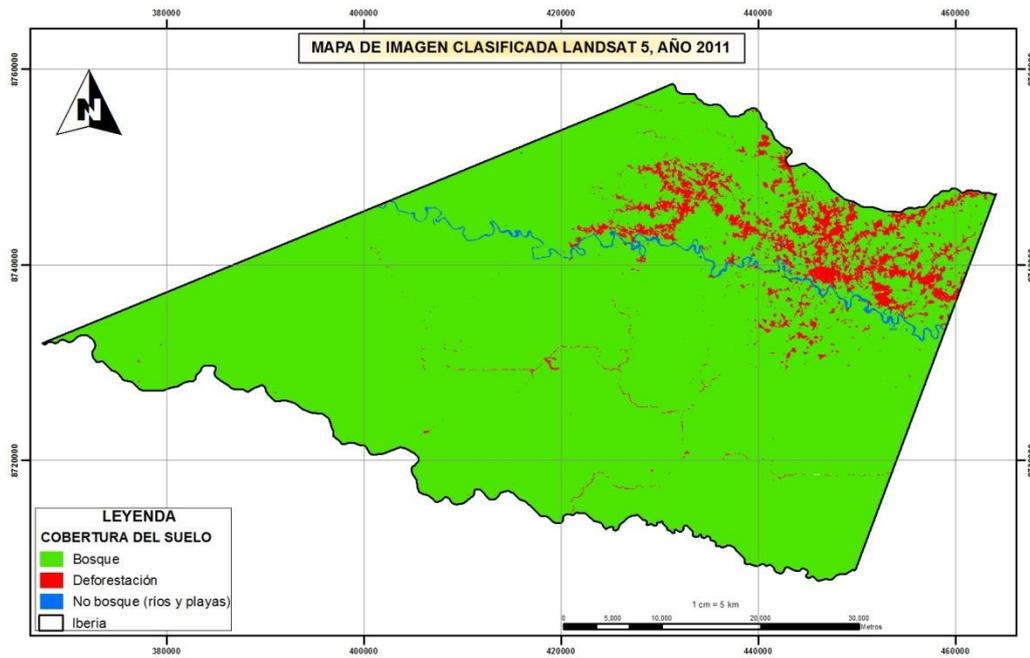


Figura 51. Imágen Landsat clasificada para el periodo 2011; cobertura de bosque y deforestación, distrito de Iberia, Tahuamanu – Madre de Dios.

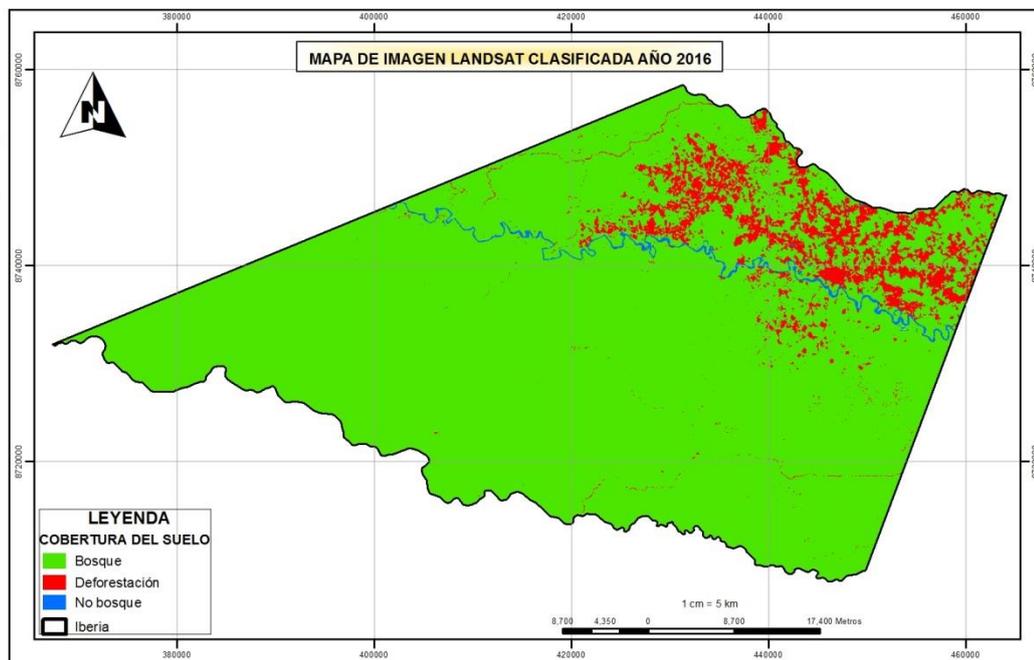


Figura 52. Imágen Landsat clasificada para el periodo 2016; cobertura de bosque y deforestación, distrito de Iberia, Tahuamanu – Madre de Dios.

La clasificación multispectral supervisada en base al método de SAM (Spectral Angle Mapper), con la combinación de bandas 6,5,4 de la Imagen Landsat 8 OLI para el periodo 2016, reporto 236 342,56 ha de bosque y 17 069,39 ha para la categoría de deforestación (tabla 18, figura 52).

Los resultados muestran una tendencia creciente en la categoría de deforestación en los periodos evaluados (2004, 2011 y 2016), (tabla 18). La dinámica de estos cambios es causada por el cambio de uso de la tierra para agricultura, ganadería y la extracción de madera. En cuanto a la deforestación por áreas agrícolas sigue una dinámica constante acorde al crecimiento de la población, centrándose en función a las áreas designada para tal fin, sean estas saneadas (tituladas) o en proceso.

Tabla 18. Reporte de clasificación supervisada del distrito de Iberia, Tahuamanu – Madre de Dios, periodos 2004, 2011 y 2016.

Áreas de cobertura de suelo						
Cobertura de suelo	Año 2004		Año 2011		Año 2016	
	Área (ha)	Área (%)	Área (ha)	Área (%)	Área (ha)	Área (%)
Bosque	248 587,90	97,34	241 151,91	94,44	236 348,27	92,55
Deforestación	4 824,09	1,89	12 260,08	4,80	17 063,72	6,68
No bosque	1 957,26	0,77	1 957,26	0,77	1 957,26	0,77
Total cobertura	255 369,25	100,00	255 369,25	100,00	255 369,25	100,00

Fuente: elaboración propia

Haciendo un análisis macro, la deforestación y sus efectos son problemas que vienen aquejando a los países de América Latina. Sus bosques se talan a un ritmo demasiado rápido y el ritmo de plantación se queda bastante atrás. La “pérdida de cobertura boscosa como consecuencia de la deforestación, provocada por la producción agropecuaria, minera, desarrollo de infraestructura y la falta de planeación urbana y territorial, representa una de las mayores amenazas para la Amazonía” (Perz et al. 2005), por otro lado estas “dinámicas de cambio de uso del suelo son complejas, las variables

que interactúan en esa relación son múltiples, y para entender cómo afecta a los recursos se deben conocer los procesos fundamentales en un contexto social, económico y espacial” (Pinos 2016; Valero 2015).

Se estima que en las últimas 3 décadas se han talado en América Latina alrededor de 2 millones de km² de bosques, siendo superior a los 50 mil km² por año la tasa actual de deforestación es "particularmente grave", en América Latina la población mas expuesta es la que se ubican en las zonas rurales. “En los países de América Latina la mayor transformación de los bosques amazónicos y subsecuente deforestación se dio en la década de 1970, impulsada por políticas gubernamentales de modernización de la infraestructura y de promoción de la expansión agrícola y minería” (Southworth et al. 2011).

Históricamente en Madre de Dios han ocurrido una serie de cambios, y los cambios en las políticas económicas generaron diferentes patrones de uso del suelo, marcada por una serie de ciclos económicos de auge y caída, como en la época del caucho, la madera y el oro. Como en otros casos de dependencia de un solo producto básico, los auges se han visto limitados por la inestabilidad de los mercados mundiales (Chavez y Perz 2013; Chávez Michaelsen et al. 2013).

Las bases para estos cambios se concretaron entre los años 2001-2006, cuando el gobierno peruano supervisó y planificó la pavimentación de la Carretera Interoceánica. La pavimentación inminente incremento el valor de las tierras y en ese contexto se produjo la expansión de cultivos y pastos, especialmente en las áreas más cercanas a la autopista (Perz et al. 2013; Southworth, Marsik, Qiu, Perz, Cumming, Stevens, Rocha, Duchelle y Barnes 2011).

Culminada la pavimentación de la vía interoceánica que se extiende a través de la región de Madre de Dios y el área de estudio, sumada al aumento del precio de la madera en el mercado internacional, se da inicio al incremento de la tasa de deforestación (Swenson et al. 2011).

Esta infraestructura ha sido desde el 2006 y actualmente es una de las principales causas de la deforestación en Madre de Dios, esta vía ha permitido la migración a la región de otras áreas del Perú y de haber contribuido al incremento de la actividad de la agricultura la explotación forestal y minera (Asner et al. 2013; Chavez 2014; Chavez y Perz 2013; Chávez et al. 2013; Perz, Qiu, Xia, Southworth, Sun, Marsik, Rocha, Passos, Rojas, Alarcón, Barnes y Baraloto 2013; Swenson, Carter, Domec y Delgado 2011)

4.1.1 Cambios de cobertura del suelo

Para indicar los resultados, se diseñó una matriz de tabulación cruzada o de cambios que se obtiene de cruzar los mapas “tiempo 1 y tiempo 2”. “En la matriz las filas indican las categorías del mapa en el tiempo 1 y las columnas las categorías del mapa en el tiempo 2” (Pontius et al. 2004) (Tabla 19). La matriz ayuda a diferenciar la transición de las diferentes variables estudiadas (figura 20) y localizar los cambios en la cobertura de suelo para su posterior análisis de las muestras reales que provocan estos cambios.

Tabla 19. Matriz de tabulación cruzada para dos mapas de diferentes fechas, basado en Pontius et al. 2004.

Año t1		Año t2			Total	Tasa de cambio (%)
		Bosque	Deforestación	No bosque		
		1	2	3		
Bosque	10	11	12	13		
Deforestación	20	21	22	23		
No bosque	30	31	32	33		
Total						

Fuente: elaboración propia

Tabla 20. Ejemplos de la dinámica del cambio de cobertura de suelo.

Se mantuvo el bosque	11
De bosque a deforestación	12
De bosque a no bosque	13
De deforestación a bosque	21
Se mantuvo la deforestación	22

De deforestación a no bosque	23
De no bosque a bosque	31
De no bosque a deforestación	32
Se mantuvo el no bosque	33

Fuente: elaboración propia

Para determinar la tasa de cambio se usó la ecuación 11, fue aplicado para la clase bosque y deforestación de tal manera que los resultados indiquen las transiciones en relación al cambio de la cobertura del suelo.

Durante el periodo de análisis de cambio de cobertura (2004–2011) (figura 53 y tabla 21); periodo (2011–2016) (figura 54 y tabla 22) y el periodo (2004–2016) (figura 55 y tabla 23), se ha demostrado una creciente modificación sobre la cobertura vegetal, estos procesos han dado origen a un cambio primordialmente de áreas de bosque a deforestación.

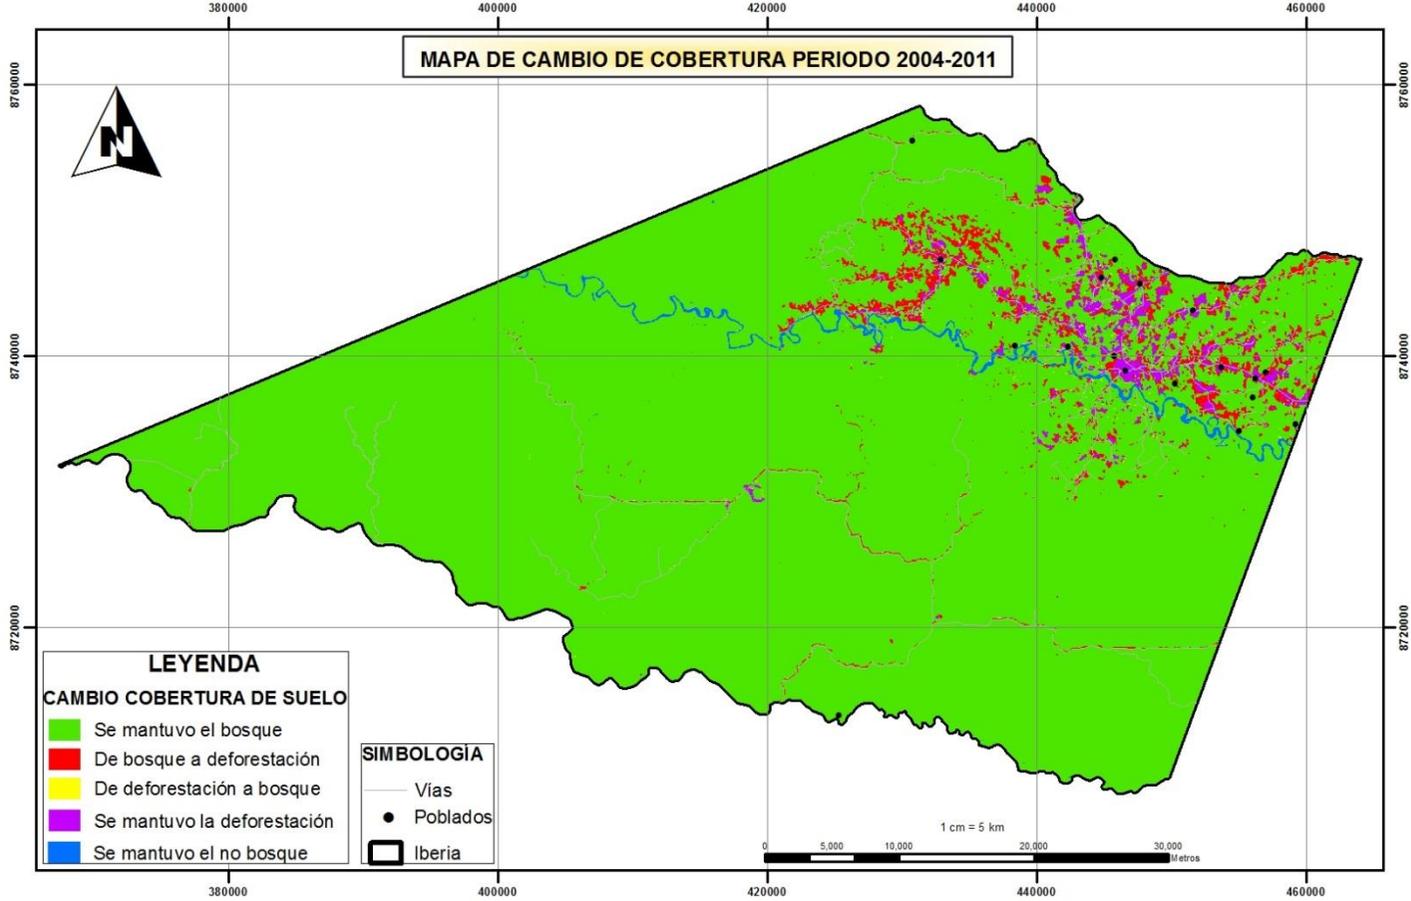


Figura 53. Cambio de cobertura 2004-2011.

Fuente: elaboración propia

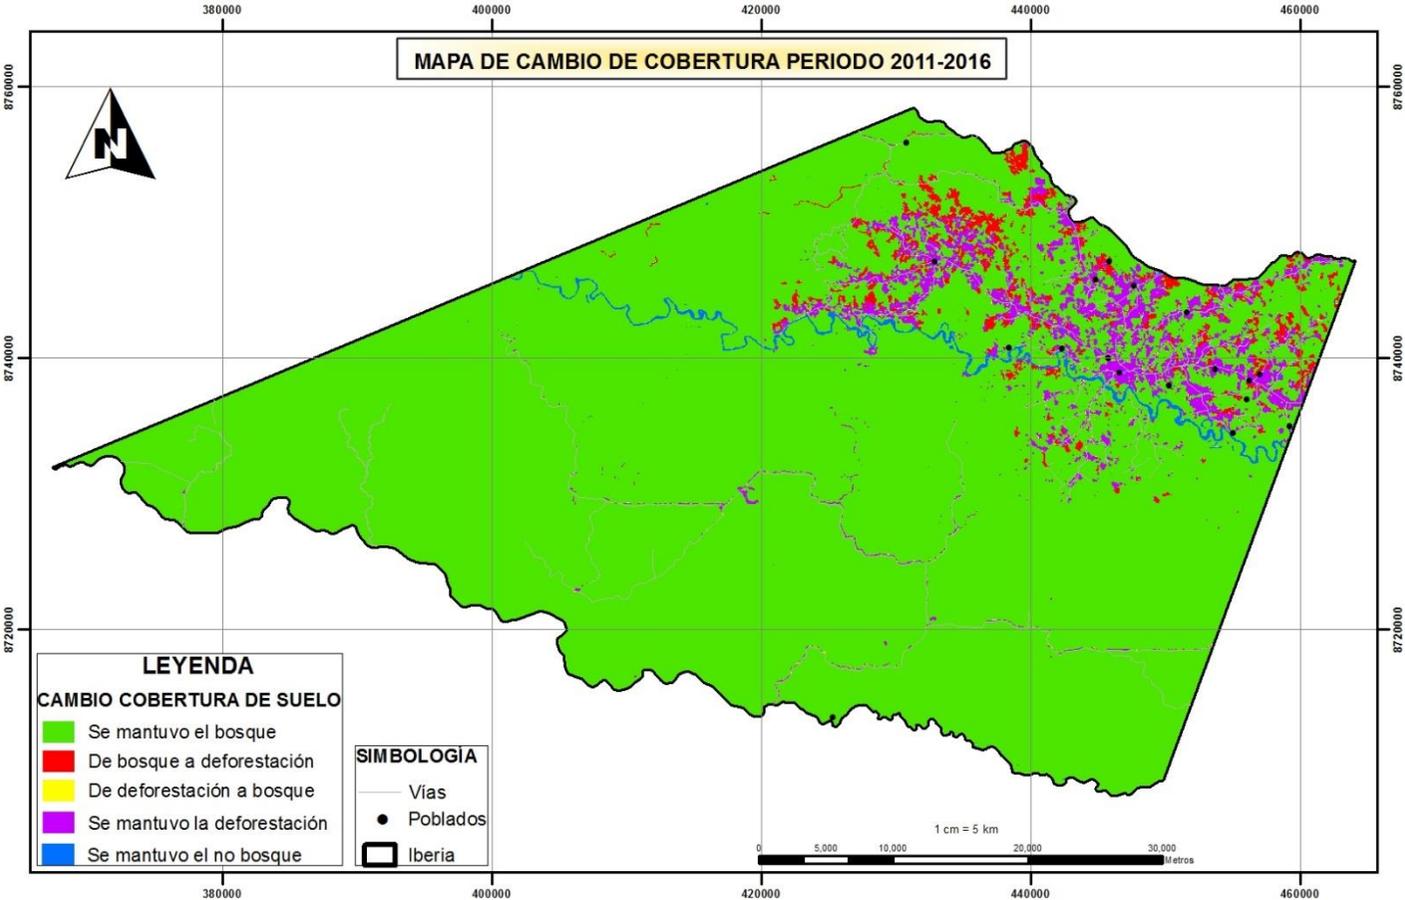


Figura 54. Cambio de cobertura 2011-2016.

Fuente: elaboración propia

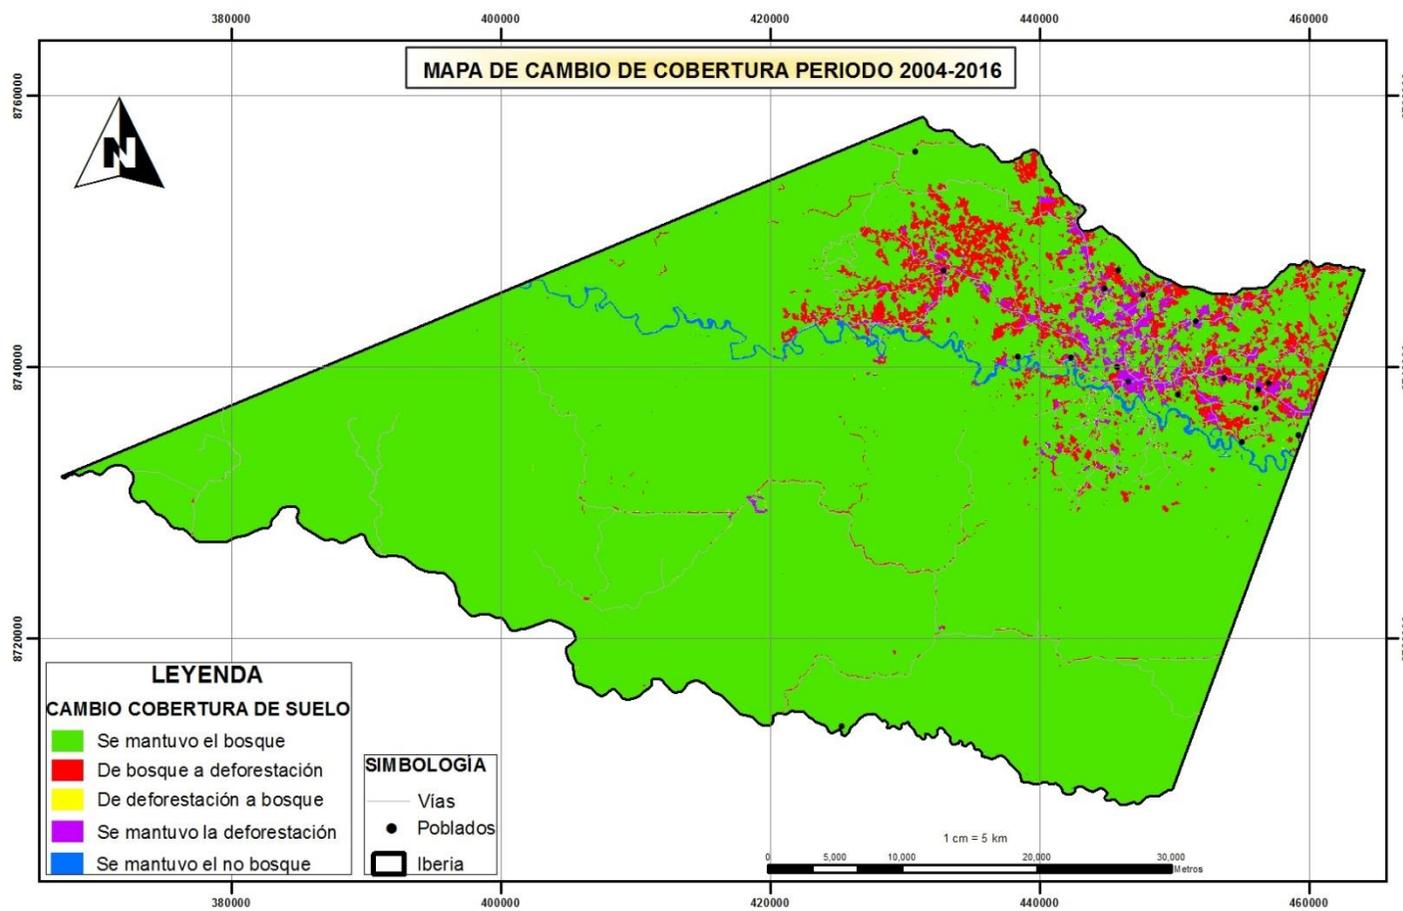


Figura 55. Cambio de cobertura 2004-2016.

Fuente: elaboración propia

Tabla 21. Matriz de tabulación cruzada y tasas de cambios entre 2004 y 2011 (datos en ha)

2004	2011			Total 2004	Tasa de cambio (%)
	Bosque	Deforestación	No bosque		
Bosque	240 820,13	7 767,78	0	248 587,90	-0,43
Deforestación	331,78	4 492,31	0	4 824,09	14,25
No bosque	0	0	1 957,26	1 957,26	0
Total 2011	241 151,91	12 260,08	1 957,26	255 369,25	

Fuente: elaboración propia

Tabla 22. Matriz de tabulación cruzada y tasas de cambios entre 2011 y 2016 (datos en ha)

2011	2016			Total 2011	Tasa de cambio (%)
	Bosque	Deforestación	No bosque		
Bosque	236 028,20	5 123,71	0	241 151,91	-0,40
Deforestación	320,07	11 940,02	0	12 260,08	6,84
No bosque	0	0	1 957,26	1 957,26	0
Total 2016	236 348,27	17 063,72	1 957,26	255 369,25	

Fuente: elaboración propia

Tabla 23. Matriz de tabulación cruzada y tasas de cambios entre 2004 y 2016 (datos en ha)

2004	2016			Total 2004	Tasa de cambio (%)
	Bosque	Deforestación	No bosque		
Bosque	236 091,51	12 496,39	0	248 587,90	-0,42
Deforestación	256,76	4 567,33	0	4 824,09	11,10
No bosque	0	0	1 957,26	1 957,26	0
Total 2016	236 348,27	1 7063,72	1 957,26	255 369,25	

Fuente: elaboración propia

El mayor cambio que se produjo fue el incremento de la deforestación entre el periodo 2004-2011 con una tasa de cambio anual de 14,25%, igualmente se pudo detectar una reducción de los bosques con una tasa de cambio

anual negativa de -0,43% que en suma asciende a una pérdida de 7 767,78 ha de bosque.

Por otro lado, si bien el objetivo no es discriminar las diferentes categorías de uso que intervienen en la deforestación, la clasificación de la imagen de satélite contemplo; áreas urbanas, áreas agrícolas, esta última asociada a la ganadería, expansión agrícola, tala de árboles y carreteras que son las que aportan en mayor grado a la conversión de bosque a deforestación en el área de estudio, no se considero la categoría "No bosque" que tiene una superficie de 1 957,26 ha.

La secuencia de mapas de bosque y deforestación producidos para los periodos del 2004 al 2016 confirma que la deforestación ha avanzado en el área de estudio (figura 56). Esta dinámica, permitió que las áreas deforestadas se incrementen constantemente desde 2004 hasta 2016. La variación espacial en la pérdida de bosques, tanto por la distancia de la vía principal y otras carreteras, cercanía a centros poblados, a los ríos, así como la tenencia de la tierra (concesiones forestales, maderables, de reforestación, agricultura) proporciona un mayor detalle en la comprensión de cómo afecta la accesibilidad en el incremento de la deforestación en el distrito de Iberia.

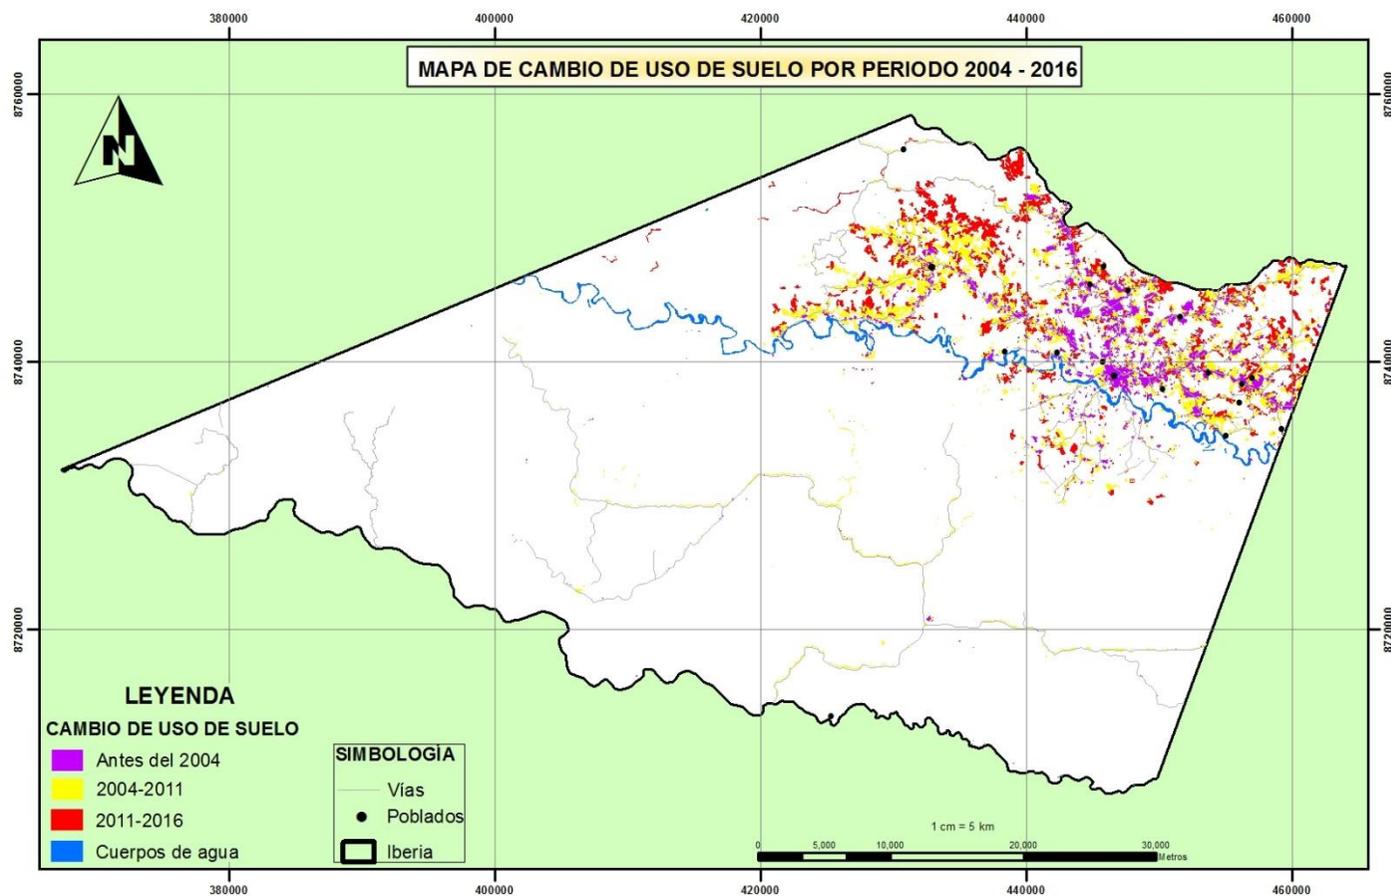


Figura 56. Cambio de cobertura de uso del suelo, periodo 2004 al 2016, distrito de Iberia, Tahuamanu - Madre de Dios.

Fuente: Elaboración propia

Al comparar los resultados con el estudio, podemos inducir que para el año 2004-2011-2016 muestran un total de 4 824,09 ha, 12 260,08 ha, y 17 063,72 ha deforestadas respectivamente. A nivel de cambios entre 2004-2011; 7 767,78 ha de bosque pasaron a ser deforestadas, mientras en el periodo 2011-2016; 5 123,71 ha de bosque pasaron a ser deforestadas y en el periodo 2004-2016; 12 496,39 ha de bosque pasaron a ser deforestadas.

4.2 Evaluación de precisión de clasificación

La evaluación de la precisión de la clasificación de la imagen Landsat 8 OLI del año 2016, reporta un 96,9072% de precisión global, mientras que el coeficiente Kappa muestra una clasificación total del área de estudio de 0,9608 (figura 57) .

Según los rangos del coeficiente kappa (κ) (0,9608), presenta una fuerza de concordancia casi perfecta (0,81 – 1,00) (tabla 14), por lo que se deduce que nos encontramos ante una correcta clasificación de las categorías, y que simplifica la comprensión del área de estudio (Cerdeja y Villarreal 2008).

Confusion Matrix: C:\ASTER IBERIA\POST CLASIFICACION\MMA2016						
Overall Accuracy = (376/388) 96.9072%						
Kappa Coefficient = 0.9608						
Ground Truth (Percent)						
Class	EVF: Layer:	PEVF: Layer:	PEVF: Layer:	PEVF: Layer:	PEVF: Layer:	P
Unclassified	0.00	0.00	0.00	0.00	0.00	0.00
URBANA	96.36	0.00	0.00	0.00	0.00	0.00
AGRICULTURA	0.00	98.00	0.00	0.00	0.00	1.33
BOSQUE	0.00	0.00	97.00	0.00	1.72	0.00
BOSQUE HUMEDO	3.64	2.00	3.00	1.98	94.83	1.33
BOSQUE MIXTO	0.00	0.00	0.00	8.63	3.45	97.33
Total	100.00	100.00	100.00	100.00	100.00	100.00
Ground Truth (Percent)						
Class	Total					
Unclassified	0.00					
URBANA	13.66					
AGRICULTURA	25.52					
BOSQUE	25.26					
BOSQUE HUMEDO	16.24					
BOSQUE MIXTO	19.33					
Total	100.00					
Commission Omission						
Class	Commission (Percent)	Omission (Percent)	Commission (Pixels)	Omission (Pixels)		
URBANA	0.00	3.64	0/53	2/55		
AGRICULTURA	1.01	2.00	1/99	2/100		
BOSQUE	1.02	3.00	1/98	3/100		
BOSQUE HUMEDO	12.70	5.17	8/63	3/58		
BOSQUE MIXTO	2.67	2.67	2/75	2/75		
Prod. Acc. User Acc.						
Class	Prod. Acc. (Percent)	User Acc. (Percent)	Prod. Acc. (Pixels)	User Acc. (Pixels)		
URBANA	96.36	100.00	53/55	53/53		
AGRICULTURA	98.00	98.99	98/100	98/99		
BOSQUE	97.00	98.98	97/100	97/98		
BOSQUE HUMEDO	94.83	87.30	55/58	55/63		
BOSQUE MIXTO	97.33	97.33	73/75	73/75		

Figura 57. Matriz de confusión.

“Los errores de omisión y comisión expresan dos enfoques del mismo problema; los primeros se refieren a una definición imperfecta de la categoría y los segundos, a una delimitación excesivamente amplia, la primera está en relación inversa con los errores de omisión, mientras la segunda lo está con los de comisión” (Barandela 1987; Cortijo y erez de la Blanca 1996). En nuestro caso, se determinó el número de puntos que correctamente la clasificación concedió, lo correcto para cada una de las clases (tabla 24); para el caso de la categoría área urbana se utilizaron 55 puntos de muestreo, de las cuales 53 fueron clasificadas correctamente y 2 fueron confundidas con bosque húmedo. La categoría áreas agrícolas se utilizaron 100 puntos de muestreo, de las cuales 98 fueron clasificadas correctamente y 2 fueron confundidas con bosque húmedo. La categoría bosque utilizo 100 puntos de muestreo, de ellas 97 fueron clasificadas correctamente y 3 confundidas con bosque húmedo. La categoría bosque húmedo utilizo 58 puntos de muestreo, de ellas 55 fueron clasificadas correctamente y 2 confundidas con área vegetación pacionales y arbustivas y 1 con bosque. Para el caso de la categoría área con vegetación pacionales y arbustivas utilizo 75 puntos de muestreo, de ellas 73 fueron clasificadas correctamente y 2 confundidas con bosque húmedo.

Tabla 24. Precisión de resultados, imagen periodo 2016.

Nivel de clasificación		Referencia Totales	Clasificados Totales	Número Correcto	Productores (omisión) Precisión	Usuarios (comisión) Precisión
Deforestación	Áreas urbanas	55	53	53	96,36%	100,00%
	Áreas agrícolas	100	98	98	98,00%	98,99%
Bosque	Bosque	100	98	97	97,00%	98,98%
	Bosque húmedo	58	63	55	94,83%	87,30%

Nivel de clasificación		Referencia Totales	Clasificados Totales	Número Correcto	Productores (omisión) Precisión	Usuarios (comisión) Precisión
	Áreas con vegetación pacaes y arbustivas	75	76	73	97,33%	97,33%
Totales		388	388	376		

Fuente: Elaboración propia.

Según Hudson (1987), el Índice de Kappa o coeficiente de conformidad de capa, es una medida de la exactitud de la clasificación y su varianza es usada en la comunidad de teledetección, para realizar pruebas estadísticas de diferencias significativas, cuando la efectividad global es elevada se corresponde con un valor elevado del Índice de Kappa, aunque no es una relación lineal muestra un elevado grado de concordancia, en nuestro caso muestra una concordancia casi perfecta (0,9608), por lo que determina que las fases de muestreo, de pre-procesamiento de las muestras de aprendizaje/control, la fase del entrenamiento y método de clasificación han sido certeros (Hart 1968; Pontius 2000; Preparata y Shamos 1985).

4.2.1 Validación del modelo

Cualquier modelo de predicción de cobertura del suelo, pasa por conocer la calidad del modelo y así poder usarlo en las predicciones para escenarios futuros. La validación del modelo se efectuó utilizando el índice de kappa, al comparar el mapa de referencia 2016 (figura 57) con el modelo prospectivo para el año 2016 (figura 58) usando la herramienta Cross Tab del software TerrSet (figura 46).

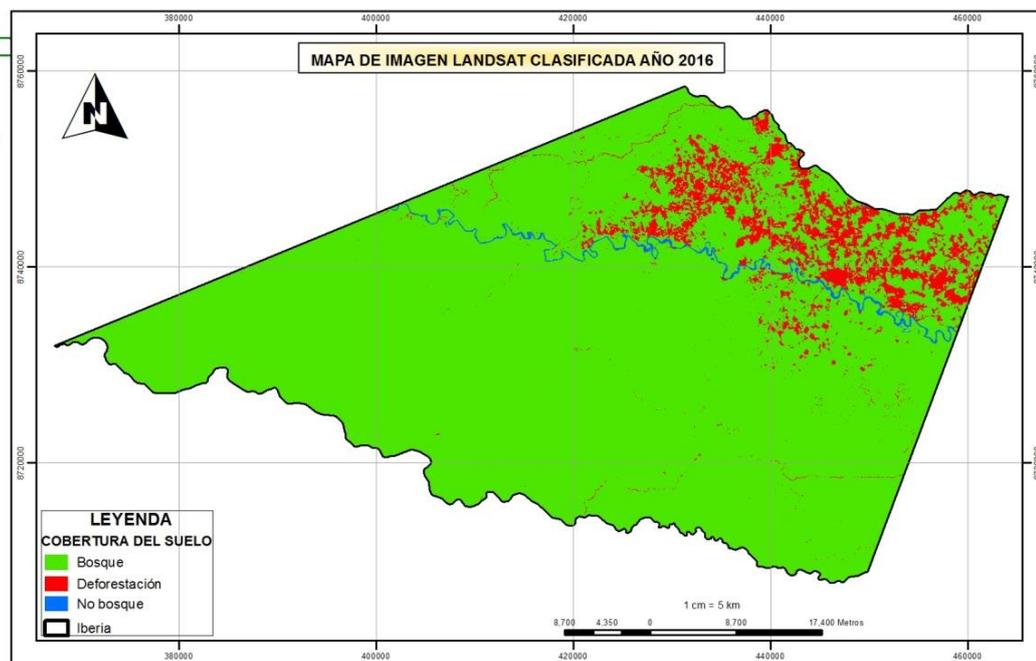


Figura 57. Cambio de uso de suelo; bosque a deforestación, periodo 2016.

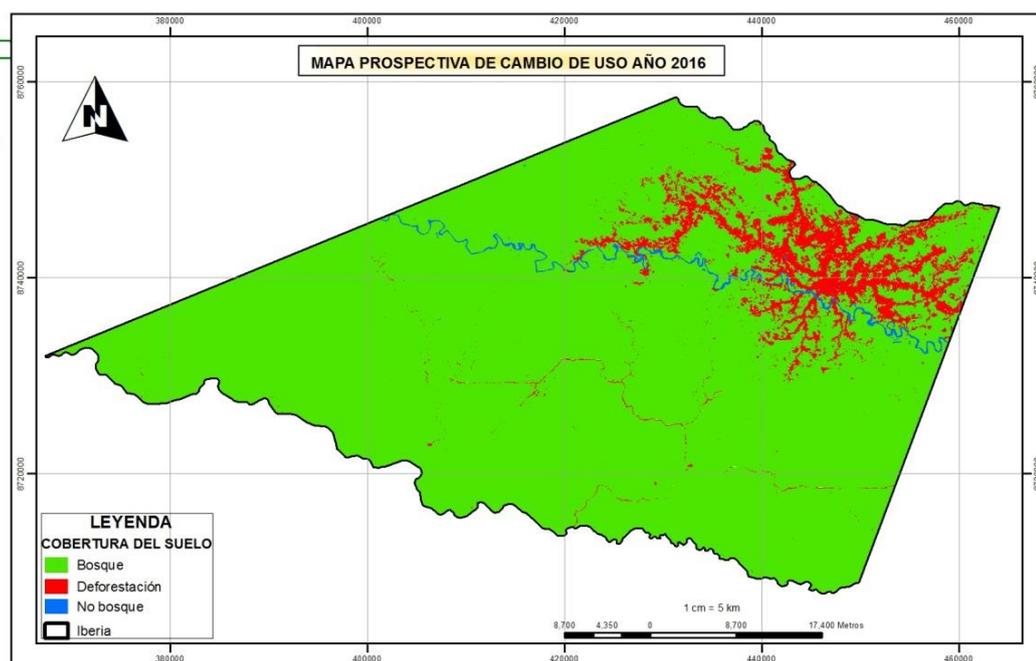


Figura 58. Prospectiva de cambio de uso: bosque a deforestación, periodo 2016.

La prospectiva de cambio al 2016, muestra una similitud con el resultado de la clasificación de la imagen Landsat 8 OLI del periodo 2016, sin embargo, el modelo propectivo sobrestimo ligeramente la deforestacion en el acceso vial trocha.

Landis y Koch (1977), realizaron una caracterización de diferentes rangos de valores para el índice kappa de acuerdo al grado de ajuste existente (tabla 25)

Tabla 25. Calidad de ajuste de acuerdo al índice de Kappa.

Valor de Kappa (%)	Calidad
0	Pésima
0 - 20	Mala
20 - 40	Razonable
40 - 60	Buena
60 - 80	Muy Buena
80 - 100	Excelente

Fuente: Landis y Koch (1977)

De acuerdo al índice de Kappa usando la prospectiva de cambio de uso de suelo (imagen 58), el índice de Kappa para la cobertura de deforestación (categoría 2), es 67,27% (figura59); y de acuerdo a la caracterización descrita anteriormente el ajuste fue muy buena.

De acuerdo al índice de Kappa usando el mapa de referencia (figura 57), el índice de Kappa para la cobertura de deforestación (categoría 2), es 96,75% (figura59); y de acuerdo a la caracterización descrita anteriormente el ajuste fue excelente.

El ajuste global del modelo se expresa mediante el índice de Kappa para el que se obtuvo un valor de 79,06% (figura59); y de acuerdo a la caracterización descrita anteriormente el ajuste fue muy buena.

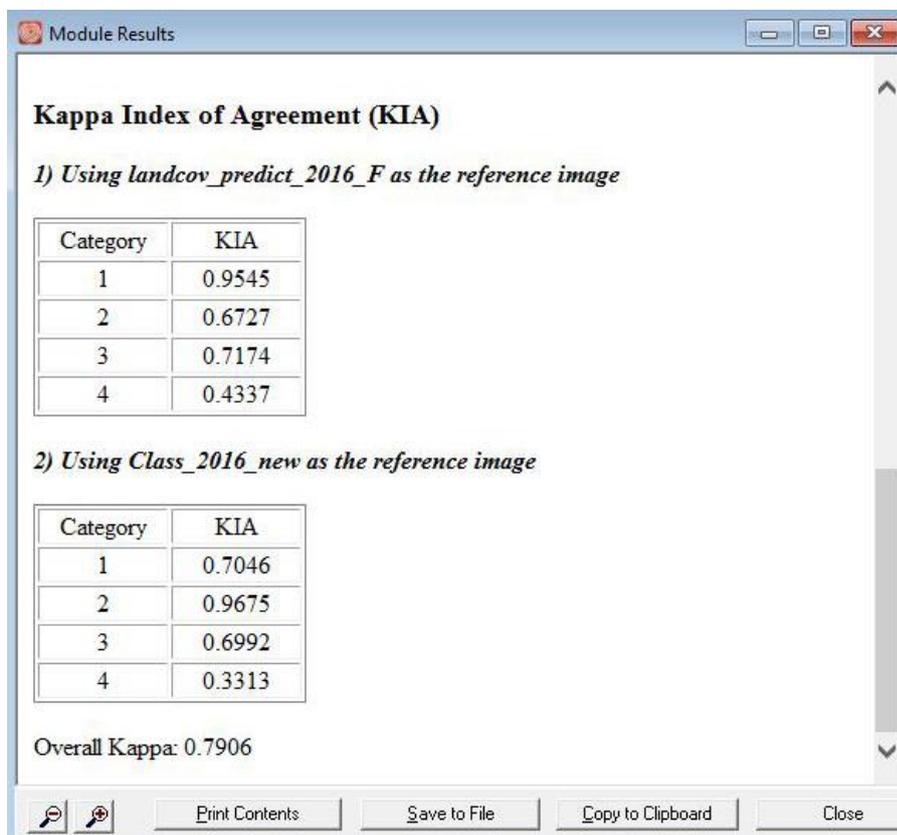


Figura 59. Resultados de la validación usando la herramienta Cross Tab del software TerrSet.

Analizando los resultados obtenidos se determinó que la validación del modelo simula muy bien la cobertura de suelo. De acuerdo a la cantidad de pixeles presentes en cada clase, el ajuste obtenido fue muy bueno (79%); sin embargo, es conveniente analizar cuáles fueron las coberturas con mayor acuerdo. En la tabla 26, se describen las superficies en ha. Por cada clase de uso observada y simulado. Se encontró que las coberturas: bosque y deforestación tiene una diferencia muy baja con un error de 95,31 ha. Esta diferencia es explicada por las bajas tasas de cambio y el gran tiempo que requieren estas modificaciones.

Tabla 26. Áreas de coberturas de suelo observadas vs prospectiva.

Áreas de cobertura de suelo					
Cobertura de suelo	Año 2016 (observada)		Año 2016 (prospectiva)		Diferencia (ha) 2016-2016P
	Área (ha)	Área (%)	Área (ha)	Área (%)	
Bosque	236 348,27	92,55	236 247,25	92,51	-101,02
Deforestación	17 063,72	6,68	17 164,74	6,72	101,02
No bosque	1 957,26	0,77	1 957,26	0,77	0
Total cobertura	255 369,50	100,00	255 369,25	100,00	

Fuente: elaboración propia

4.3. Prospectiva de cambio al periodo 2030

Según los resultados y al buen ajuste del modelo prospectivo al 2016, se realizó la predicción para el periodo 2030, tomando como base la cobertura de cambio de uso de suelo de los años 2011 y 2016, es decir, 14 años a partir del periodo de referencia (2016).

El modelo prospectivo reportó 228 272,49 ha de bosque y 25 139,51 ha para la categoría de deforestación (tabla 27 y figura 60).

Tabla 27. Reporte de Prospectiva de cambio de uso: bosque a deforestación, periodo 2030.

Años	Clases	
	Bosque (ha)	Deforestación (ha)
2030	228 272,49	25 139,51

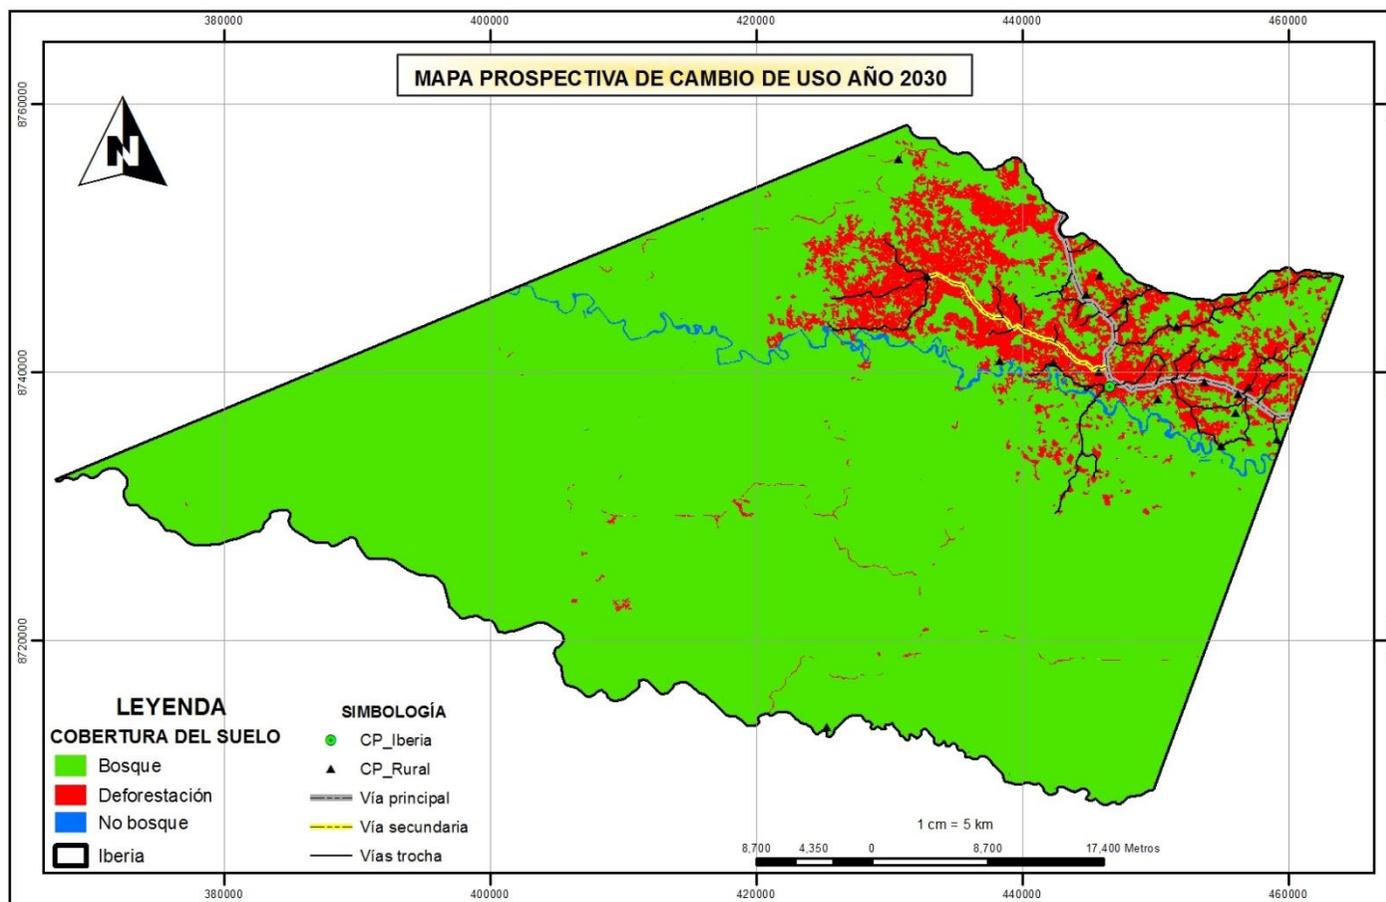


Figura 60. Prospectiva de cambio de uso: bosque a deforestación, periodo 2030.

Fuente: elaboración propia

En la tabla 28 la deforestación entre el año referencia 2016 y la prospectiva al año 2030 se incremento en 8 071,58 ha., al igual que en años anteriores se sufrirán cambios significativos en cuanto a la pérdida de vegetación y posterior conversión a uso agrícola, ganadero, pastizales.

Tabla 28. Reporte de clasificación año de referencia 2016 y prospectiva al año 2030.

Áreas de cobertura de suelo				
Cobertura de suelo	Año 2016		Prospectiva Año 2030	
	Área (ha)	Área (%)	Área (ha)	Área (%)
Bosque	236 348,27	92,55	228 272,49	89,39
Deforestación	17 063,72	6,68	25 139,51	9,84
No bosque	1 957,26	0,77	1 957,26	0,77
Total cobertura	255 369,25	100,00	255 369,25	100,00

Fuente: elaboración propia

4.3.1 Cambio de cobertura del suelo con el modelo prospectivo al 2030

Durante el periodo de análisis (2004–2016), se ha evidenciado una creciente transformación sobre la cobertura vegetal, estos procesos han dado paso a la transformación principalmente de áreas de bosque a deforestación. La detección de áreas de cambio a través de imágenes de diferenciación periodo 2016-2030 se muestra en la (figura 61 y tabla 29) y la diferenciación periodo 2004-2030 en la (figura 62 y tabla 30).

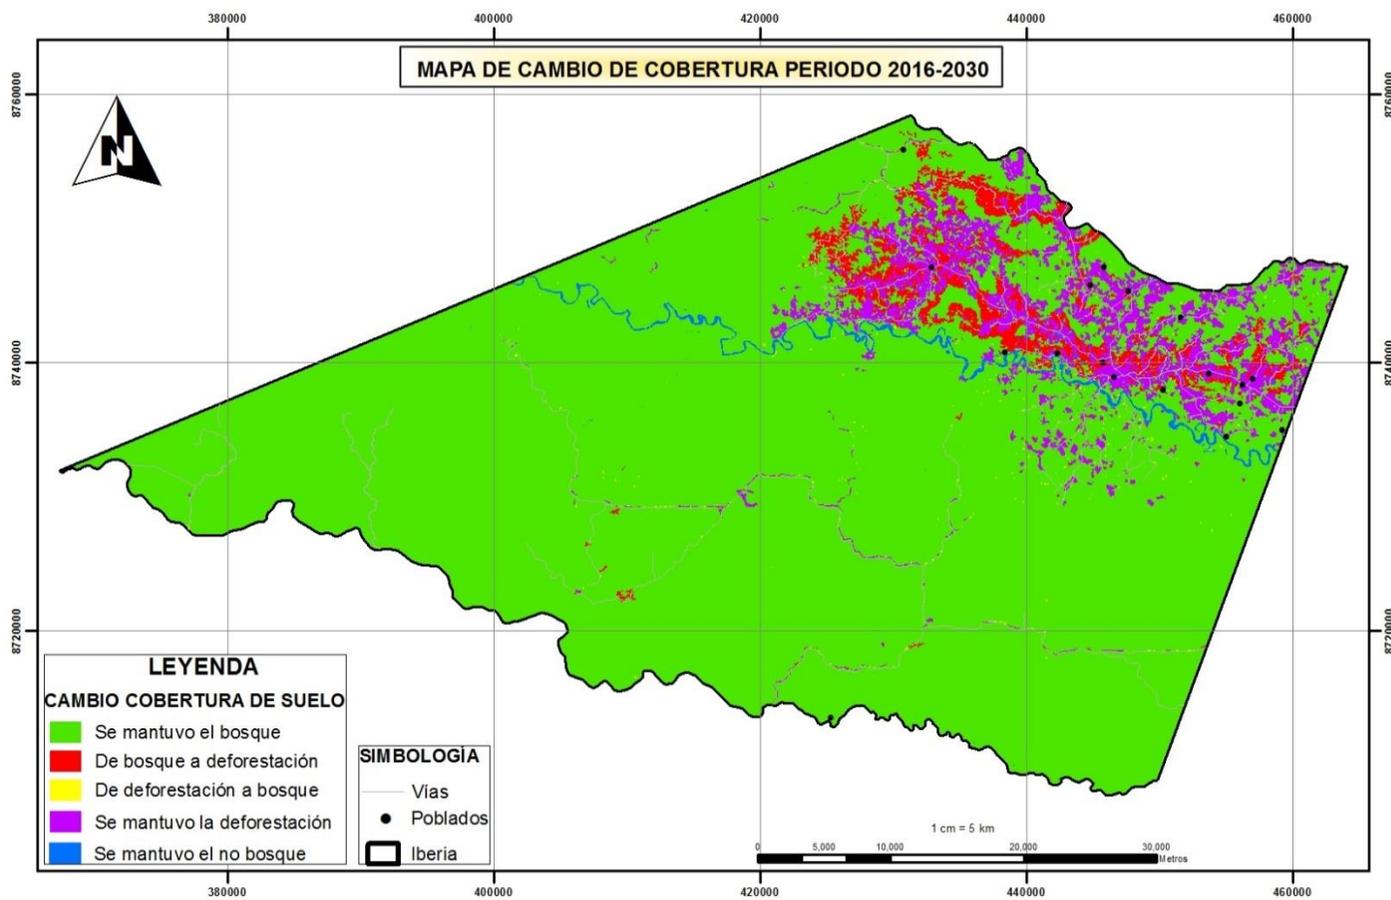


Figura 61. Cambio de cobertura 2016-2030.

Fuente: elaboración propia

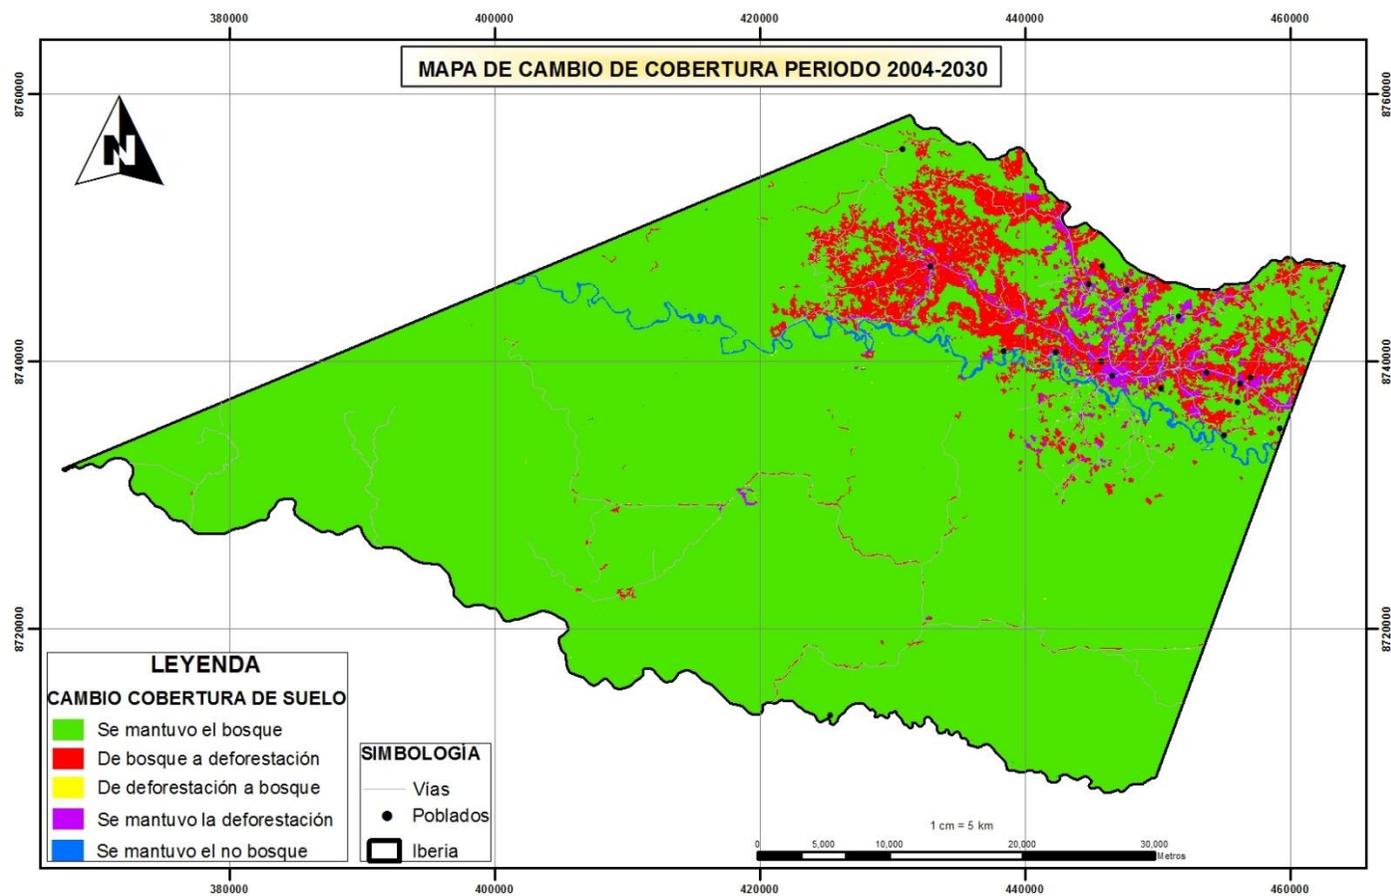


Figura 62. Cambio de cobertura 2004-2030.

Fuente: elaboración propia

Tabla 29. Matriz de tabulación cruzada y tasas de cambios entre 2016 y 2030 (datos en ha).

2016	2030			Total 2016	Tasa de cambio (%)
	Bosque	Deforestación	No bosque		
Bosque	227 887,82	8 460,45	0	236 348,27	-0,25
Deforestación	384,67	16 679,06	0	17 063,72	2,81
No bosque	0	0	1 957,26	1 957,26	0
Total 2030	228 272,49	25 139,51	1 957,26	255 369,25	

Fuente: elaboración propia

Tabla 30. Matriz de tabulación cruzada y tasas de cambios entre 2004 y 2030 (datos en ha).

2004	2030			Total 2004	Tasa de cambio (%)
	Bosque	Deforestación	No bosque		
Bosque	228 092,79	20 495,11	0	248 587,90	-0,33
Deforestación	179,70	4 644,39	0	4 824,09	6,56
No bosque	0	0	1 957,26	1 957,26	0
Total 2030	228 272,49	25 139,51	1 957,26	255 369,25	

Fuente: elaboración propia

La evolución general del cambio de uso de suelo periodo 2004-2030 presento una tasa de cambio anual de 6,56%, igualmente se pudo detectar una evolución general de la reducción de los bosques con una tasa de cambio anual negativa de -0,33% que en suma asciende a una pérdida de 20 495,11 ha de bosque.

El resultado de la matriz de tabulación cruzada de áreas de cambio de cobertura de suelo a través de imágenes de diferenciación se resume en la tabla 31.

Tabla 31. Cambio de cobertura del suelo (bosque – deforestación) en el distrito de Iberia, Tahuamanu – Madre de Dios, periodo 2004-2030.

Cambio de Cobertura					
Años calculados	Años	Persistencia de bosque (ha)	Persistencia deforestación (ha)	Bosque a Deforestación (ha)	Deforestación a vegetación (ha)
7	2004-2011	240 820,13	4 492,31	7 767,78	331,78
5	2011-2016	236 028,20	11 940,02	5 123,71	320,07
12	2004-2016	236 091,51	4 567,33	12 496,39	256,76
14	2016-2030	227 887,82	16 679,06	8 460,45	384,67
26	2004-2030	228 092,79	4 644,39	20 495,11	179,70

Fuente: elaboración propia

En la tabla 32 se hace un análisis de la cobertura deforestación y la tasa anual de cambio en porcentaje de los diferentes periodos estudiados que comprende desde el año 2004 hasta el año 2030.

Tabla 32. Tasa de la deforestación y tasa anual de cambio en el distrito de Iberia, Tahuamanu – Madre de Dios, periodo 2004 al 2030.

periodo	Tiempo de análisis	Áreas Deforestadas (ha)	Tasa de deforestación ha/año	Tasa anual de cambio (%)
2004 2011	7	4 824,09 12 260,08	1 062.28	14.25
2011 2016	5	12 260,08 17 063,72	960.73	6.84
2004 2016	12	4 824,09 17 063,72	1 019.97	11.10
2016 2030	14	17 063,72 25 139,51	576.84	2.81
2004 2030	26	4 824,09 25 139,51	781.36	6.56

Fuente: elaboración propia

El periodo comprendido de 2004-2011, presenta la mayor tasa de deforestación con 1 062,28 ha/año y con una tasa anual de cambio de 14,25%; seguido del periodo 2011-2016 con una tasa de deforestación de

960,73 ha/año y una tasa anual de cambio de 6,84%; luego se muestra una tendencia a disminuir la deforestación con una tasa de deforestación de 576,84 ha/año y una tasa anual de cambio de 2,81% en el periodo 2016-2030. En general el cambio de cobertura de bosque a deforestación en el rango de periodo de estudio 2004-2030 la tasa de deforestación es de 781,36 ha/año y una tasa anual de cambio de 6,56%.

La secuencia de mapas de bosque y deforestación producidos para los periodos 2004, 2011, 2016 y predicho al 2030, confirman que la deforestación ha avanzado mucho mas hacia la comunidad de Pacahuara y seguirá avanzando en el área de estudio (figura 63).

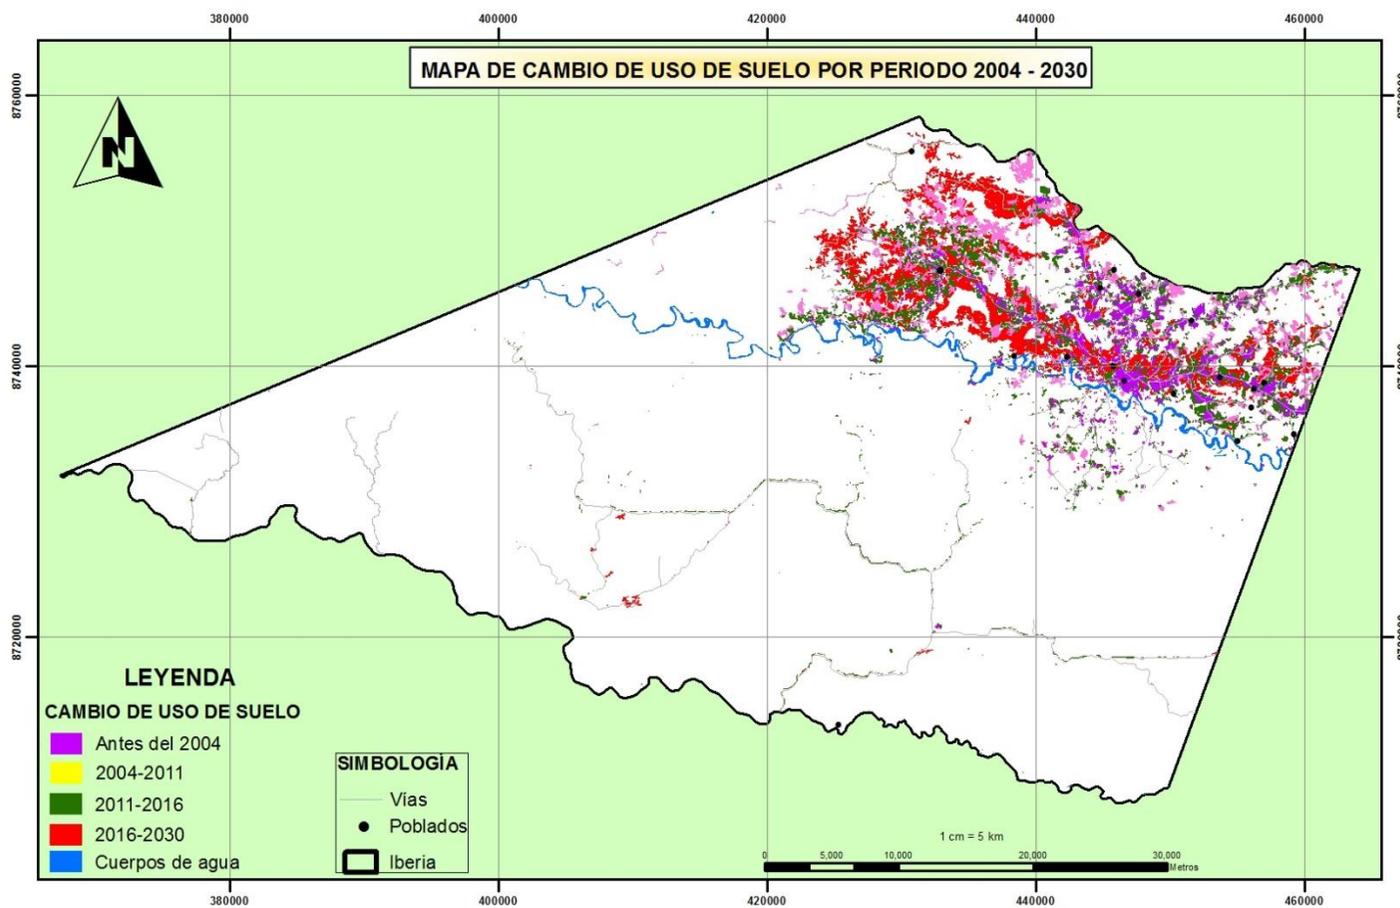


Figura 63. Cambio de cobertura de uso del suelo, periodo 2004 al 2030, distrito de Iberia, Tahuamanu - Madre de Dios.

Fuente: elaboración propia

CONCLUSIONES

El análisis espacial para el periodo 2004 determinó que el área de estudio estuvo constituida en casi en su totalidad por la categoría bosque, 4 824,09 ha deforestadas de 248 587,90 ha, de bosque; período en el que la intervención antrópica estaba enfocado básicamente en la actividad agrícola, ganadera y forestal. Mientras que para 2011 (7 años después) la categoría de deforestación llegó 12 260,08 ha. El bosque cambio continuamente, debido al aumento demográfico y la construcción de infraestructura de carreteras. Esta tendencia fue incrementándose constantemente, y en el año 2016 el área deforestada reporto 17 063,72 ha.

El cambio de cobertura de suelo muestra que en un lapso de 12 años (2004-2016) en el distrito de Iberia se perdió 12 496,39 ha, de bosque, dándose con mayor intensidad en el periodo 2004-2011 (7 años) con 7 767,78 ha, mayor al periodo 2011-2016 (5 años) con 5 123,71 ha, adicionalmente la superficie de bosques deforestados principalmente por actividades agrícolas, han sufrido un proceso de cambio de uso del suelo. Estos cambios indican que el área de estudio atraviesa por una etapa sin precedentes en la pérdida de cobertura boscosa y cambio de uso del suelo, que sin duda repercute en un problema ambiental.

La construcción de escenarios y/o prospectivas de cambios de usos de suelo es un complejo proceso que discrepa fuertemente en lo que se denomina práctica y teoría. En este contexto, el método de Cadenas de Markov representa una gran ayuda para la predicción de modelos a partir de dos estados precedentes (t_0 y t_1). Con esta consideración, el resultado de la proyección tendencial al 2016, tomando como base los periodos 2004-2011 presento una alta concordancia con el mapa de cambio de cobertura de suelo 2016 (referencia), discrepando en la ganancia de la deforestación en el área de influencia de acceso vial trocha. Tomando como referencia los resultados de la prospectiva restrictiva se determinó el modelo predictivo

para el periodo 2030, mostrando la tendencia del incremento de la deforestación en el acceso vial primario, secundario y trocha.

La cuantificación del modelo propectivo al periodo 2030 reporta que la deforestación se incrementara a 25 139,51 ha, 8 075,78 ha, más con respecto al 2016 (14 años). A nivel de cambios de cobertura del suelo presenta como la más grande conversión de bosque a deforestación al periodo 2004-2011 (7 años) con una tasa de deforestación de 1 062,28 ha/año y una tasa de cambio anual de 14,25%;, seguida del periodo 2011-2016 (5 años) con 960,73 ha/año. En cuanto a cambios globales de 2004-2016 y 2016-2030, la primera presenta una mayor conversión de bosque a deforestación (1 019,97 ha/año), contribuyendo para tal fin el incremento de la frontera agrícola.

La expansión ganadera, la agricultura de subsistencia y los proyectos de infraestructura como los más importantes motores que conllevan a la deforestación.

RECOMENDACIONES

La deforestación es un problema global y como tal debe ser afrontada con responsabilidad y políticas públicas claras. El monitoreo de la deforestación a través de tecnologías de teledetección y sistemas de información geográfica resulta oportuno y prescindible para su identificación y ubicación, por lo que el gobierno en sus diferentes niveles, instituciones académicas y científicas deben implementarlo.

La planificación del territorio resulta compleja, y para ello es necesario determinar modelos prospectivos; tendenciales, deseables y consensuados, que brinden información lo más cercana posible a la realidad para la gestión y desarrollo del territorio. En ese sentido los softwares con capacidad predictiva juegan un rol importante.

El software TerrSet de Clark Labs, Clark University – USA, es un programa académico y de fácil acceso diseñada para modelamiento del paisaje a través del método Cadenas de Markov del módulo Land Change Modeler, y que la Universidad Nacional Amazónica de Madre de Dios debe adquirirlas para el desarrollo de asignaturas de la carrera profesional de Ingeniería Forestal y Medio Ambiente.

BIBLIOGRAFÍA CONSULTADA

ACHARD F., DEFRIES R., EVA H., HANSEN M., MAYAUX P., y STIBIG H., 2007. Pan-tropical monitoring of deforestation. *Environmental Research Letters*, 2(4), 045022.

AGUILERA F., 2006. Predicción del crecimiento urbano mediante sistemas de información geográfica y modelos basados en autómatas celulares. *GeoFocus. Revista Internacional de Ciencia y Tecnología de la Información Geográfica*, (6), 81-112.

AIDE T. M., CLARK M. L., GRAU H. R., LÓPEZ-CARR D., LEVY M. A., REDO D. MUÑIZ M., 2013. Deforestation and reforestation of Latin America y the Caribbean (2001–2010). *Biotropica*, 45(2), 262-271.

ALARCÓN G., DÍAZ J., VELA M., GARCÍA M., Y GUTIÉRREZ J., 2016. Deforestación en el sureste de la amazonia del Perú entre los años 1999-2013; caso Regional de Madre de Dios (Puerto Maldonado–Inambari). *Revista Investigaciones Altoandinas*, 18(3), 319-330.

ALARCÓN G., FRISANCHO R., CORREA G., ULLOA J., VELA M., DÍAZ J., VÁSQUEZ J., 2011. Detección de cambios de cobertura boscosa a través del análisis multitemporal de imágenes satelitales en el distrito de Inambari. *Biodiversidad Amazonica*. ISSN: 2075-8081, 3, 9.

ALVAREZ-BERRÍOS N. L. y AIDE T. M., 2015. Global demand for gold is another threat for tropical forests. *Environmental Research Letters*, 10(1), 014006.

ANAYA J. A., Y CHUVIECO E., 2010. Validación para Colombia de la estimación de área quemada del producto L3JRC en el periodo 2001-2007/Validation of the L3JRC burned area product estimation in Colombia from 2001 to 2007. *Actualidades Biológicas*, 32(92), 29.

ANGULO C., 2011. Dinámica de la deforestación en Venezuela: análisis de los cambios a partir de mapas históricos. *Interciencia*, 36(8), 578-586.

ARGANY M., Y SARADJIAN M. R., 2015. Digital change detection y expansion monitoring of urban areas using satellite images by means of classification methods.

ARIZA A., 2013. Descripción y Corrección de Productos Landsat 8 LDCM (Landsat Data Continuity Mission). Bogotá: Instituto Geográfico Agustín Codazzi.

ARONOFF S. CLASSIFICATION ACCURACY-A USER APPROACH., 1982. Photogrammetric Engineering and Remote Sensing, 48(8), 1299-1307.

ASNER G. P., LLACTAYO W., TUPAYACHI R. y LUNA E. R., 2013. Elevated rates of gold mining in the Amazon revealed through high-resolution monitoring. Proceedings of the National Academy of Sciences, 110(46), 18454-18459.

AVERY T. E., Y BERLIN G. L., 1992. Fundamentals of remote sensing and airphoto interpretation.

BARAY H. L. Á., 2006. *Introducción a la metodología de la investigación*: Juan Carlos Martínez Coll, ISBN 8469019996.

BISHOP C. M., 1995. *Neural networks for pattern recognition*: Oxford university press, ISBN 0198538642.

BOARDMAN J. W. y KRUSE, F. A., 1994. Automated spectral analysis: A geologic example using AVIRIS data, north Grapevine Mountains, Nevada: in Proceedings, Tenth Thematic Conference on Geologic Remote Sensing, Environmental Research Institute of Michigan, Ann Arbor, MI, p. I-407 - I-418.

BOCA T. y RODRÍGUEZ G., 2012. Métodos estadísticos de la evaluación de la exactitud de productos derivados de sensores remotos. Instituto de Clima y Agua, INTA Castelar.

BOCCO G., MENDOZA M., Y MASERA O. R., 2011. La dinámica del cambio del uso del suelo en Michoacán: Una propuesta metodológica para el estudio de los procesos de deforestación. Investigaciones geográficas, (44), 18-36.

CABRAL P., y ZAMYATIN A., 2006. Three land change models for urban dynamics analysis in Sintra-Cascais area. Paper presented at the

Proceedings of First Workshop of the EARSEL SIG on Urban Remote Sensing: Challenges and solutions.

CAI Y., LIU Y., YU Z., y PETER H. V., 2004. Progress in spatial simulation of land use change-CLUE-s model and its application. *Progress in Geography*, 4, 007.

CASTRO F., 2003. El proceso de investigación y su esquema de elaboración. Caracas ,Editorial Uyapar.

CAZAU P. Introducción a la investigación en ciencias sociales. Lima. Editorial Universidad Ricardo Palma, 2006.

CEBALLOS A., LÓPEZ J., TRUJILLO A. y GUTIERREZ A., 2005. Cartografía del riesgo de erosión en el consejo popular punta de la sierra mediante el empleo de SIG. Tlaxcala. Recuperado de <http://www.convenciontropicalcuba.com/CIETA/Aplicacion de Sig y de la Percepción Remota a Estudios Territoriales.PDF>

CERDA J., y VILLARROEL L., 2008. Evaluación de la concordancia inter-observador en investigación pediátrica: Coeficiente de Kappa. *Revista chilena de pediatría*, 79(1), 54-58.

CHAVEZ A., 2014. Landscape dynamics of Amazonian deforestation between 1986 and 2007 in southeastern Peru: policy drivers y road implications. *Journal of Land Use Science*, 9(4), 414-437.

CHÁVEZ A., BÉJAR N., FERNÁNDEZ R., HUAMANÍ L., VALERA F., 2012. Reporte de estudios de áreas deforestadas en la provincia de Tahuamanu 2008-2010, 31 pp.

CHAVEZ A., y PERZ S., 2013. Path dependency y contingent causation in policy adoption and land use plans: The case of Southeastern Peru. *Geoforum*, 50, 138-148.

CHÁVEZ MICHAELSEN A., HUAMANI BRICEÑO L., FERNANDEZ MENIS R., BEJAR CHURA N., 2013. Regional Deforestation Trends within Local Realities: Land-Cover Change in Southeastern Peru 1996–2011. *Land*, 2(2), 131.

CHOWDHURY R., 2006. Driving forces of tropical deforestation: The role of remote sensing y spatial models Singapore Journal of Tropical Geography, 27(1): 82-101.

CHUVIECO E., 1996. Empleo de imágenes de satélite para medir la estructura del paisaje: análisis cuantitativo y representación cartográfica. Serie Geográfica, 6, 131-147.

CHUVIECO E., 2008. Teledetección ambiental. La observación de la tierra desde el espacio. (3.^a ed.). Barcelona: Editorial Ariel, S.A.

CHUVIECO E., 2002. Teledetección espacial: la observación de la Tierra desde el espacio..

CHUVIECO E., GIGLIO L., y JUSTICE C., 2008. Global characterization of fire activity: toward defining fire regimes from Earth observation data. Global Change Biology, 14(7), 1488-1502.

CHUVIECO E., y HANTSON S., 2010. Procesamiento estándar de imágenes Landsat. Documento técnico de algoritmos a aplicar. Version1. Plan Nacional de Teledetección. Instituto Geográfico Nacional. On line. http://www.ign.es/PNT/pdf/especificacionestecnicas-pnt-mediad-landsat_v2-2010. Pdf.

CHUVIECO E., y SALAS J., 1996. Mapping the spatial distribution of forest fire danger using GIS. International Journal of Geographical Information Science, 10(3), 333-345.

CONGALTON R. G., 1998. A comparison of sampling schemes used in generating error matrices for assessing the accuracy of maps generated from remotely sensed data. Photogrammetric engineering and remote sensing (USA).

CONGALTON R. G., 1991. A review of assessing the accuracy of classifications of remotely sensed data. Remote sensing of environment, 37(1), 35-46.

CORONADO-CHACÓN L., 2001. Comprobación de técnicas de procesamiento de imágenes del sensor remoto ETM+ de Landsat 7, en la

identificación de Bosques Secundarios en la Región Huetar Norte de Costa Rica.

DIAZ F., y PARDI M., 2009. Clasificación utilizando el modelo lineal de mezcla espectral para la determinación de áreas deforestadas en la Amazonía Peruana. Simpósio Brasileiro de Sensoriamento Remoto, pp. 6149-6156.

DURÁN-MEDINA E., MAS J.-F., y VELÁZQUEZ A., 2007. Cambios en las coberturas de vegetación y usos del suelo en regiones con manejo forestal comunitario y áreas naturales protegidas de México. Los bosques comunitarios de México. Manejo sustentable de paisajes forestales. Instituto Nacional de Ecología-Secretaría de Medio Ambiente y Recursos Naturales y Consejo Civil Mexicano para la Silvicultura Sostenible. México, DF México, 267-299.

ELIJAH R., y JENSEN J. R., 1996. Remote sensing of mangrove wetlands: relating canopy spectra to site-specific data.

ENVI – HELP Versión 5.0, 2011. file:///C:/Program%20Files/Exelis/envi5.0/help/ENVIHelp.htm#PreprocessImagery/QUAC_FLAAASH/AboutAtmosphericCorrectionModule.htm%3FTocPath%3DPreprocess%7CAtmospheric%20Correction%20Module%7C_0.

ENVI., 2005. Edition Atmospheric Correction Module Version 4.7 August, https://www.exelisvis.com/portals/0/pdfs/envi/Flaash_Module.pdf, 2009.

FAO Evaluación de los recursos forestales mundiales 2005. México. Informe nacional núm. 189. Roma, 68 p.

FAO., 2016. Los bosques y el cambio climático en el Perú. Bosques y cambio climático. Documento de trabajo N° 14.

FINER M. y NOVOA S., 2015. La Deforestación por la Minería Aurífera Continúa su Expansión en La Pampa (Madre de Dios, Perú). MAAP: Imagen #1. En el enlace: <http://maaproject.org/2015/03/se-expande-deforestacion-en-la-amazonia-peruana-por-mineria-de-oro/>, 2015b.

FINER M. y NOVOA S., 2017. Patrones y drivers de deforestación en la Amazonía Peruana. MAAP: Síntesis #2. En el enlace: <http://maaproject.org/2017/maap-sintesis2/>.

FINER M. y NOVOA S., 2015. Patrones y Drivers de la Deforestación en la Amazonía Peruana. MAAP Síntesis #1. En el enlace: <http://maaproject.org/2015/09/maap-sintesis1/>, 2015a.

FINER M., OLEXY T. y NOVOA S., 2016. La Minería aurífera deforestó 12 500 hectáreas en la amazonía peruana sur en los últimos 4 años. MAAP: 50, 2016a.

FINER M., OLEXY T. y NOVOA S., 2016. La minería ilegal dentro de la RNT supera las 450 hectáreas. MAAP: 46, 2016b.

FITZPATRICK-LINS K., 1981. Comparison of sampling procedures and data analysis for a land-use and land-cover map. *Photogrammetric Engineering and Remote Sensing*, 47, 343-351.

FRANÇOIS-MAS J., REYES DÍAZ-GALLEGOS J. y PÉREZ-VEGA A., 2003. Evaluación de la confiabilidad temática de mapas o de imágenes clasificadas: una revisión. *Investigaciones geográficas*, (51), 53-72.

GEIST H. y LAMBIN E., 2004. Dynamic causal patterns of desertification. *BioScience*, 54(9), 817-829.

GEIST H. y LAMBIN E., 2002. Proximate causes and underlying driving forces of tropical deforestation: Tropical forests are disappearing as the result of many pressures, both local and regional, acting in various combinations in different geographical locations. *BioScience*, 52(2), 143-150.

GOEL N. y NORMAN J., 1992. Biospheric models, measurements and remote sensing of vegetation. *ISPRS journal of photogrammetry and remote sensing*, 47(2-3), 163-188.

GÓMEZ M. y BARREDO J., 2006. Sistemas de información geográfica y evaluación multicriterio en la ordenación del territorio.

GONZÁLEZ P., BENAVENTE, F. y DELGADO M., 2012. Propuesta de un análisis de sensibilidad para validar modelos prospectivos de simulación de

crecimiento urbano basados en autómatas celulares. *GeoFocus. Revista Internacional de Ciencia y Tecnología de la Información Geográfica* (12), 303-328.

GOREMAD G.R.D.M.D.D.-. y IIAP I.D.I.D.L.A.P., 2009. Macro Zonificación Ecológica Económica de Madre de Dios. In., p. 208.

HAMMOND T. y VERBYLA D., 1996. Optimistic bias in classification accuracy assessment. *International Journal of Remote Sensing*, 17(6), 1261-1266.

HENRÍQUEZ C. y AZÓCAR G., 2006. Cambio de uso del suelo y escorrentía superficial: aplicación de un modelo de simulación espacial en Los Ángeles, VIII Región del Biobío, Chile. *Revista de Geografía Norte Grande*, (36), 61-74.

HERNÁNDEZ R., FERNÁNDEZ C. y BAPTISTA P., 2010. Metodología de la Investigación (Quinta edición ed.).(J. Mares Chacón, Ed.) Mexico, México DF: McGraw-Hill/Interamericana Editores, SA de CV.

HUDSON W. D., 1987. Correct formulation of the kappa coefficient of agreement. *Photogrammetric Engineering and Remote Sensing*, 53(4), 421-422.

HURTADO J., 2014. Análisis, modelamiento y simulación espacial del cambio de cobertura del suelo, entre las áreas naturales y las de origen antrópico en la provincia de Napo (Ecuador), para el período 1990-2020. Facultad de Ingeniería.

IDEAM I. D. H. M. Y. E. A., 2010. Leyenda nacional de coberturas de la tierra. Metodología CORINE Land Cover adaptada para Colombia escala 1: 100.000. In.: Instituto de Hidrología Meteorología y Estudios Ambientales (IDEAM), Instituto Geográfico Agustín Codazzi (IGAC), and Corporación Autónoma Regional del Magdalena (CORMAGDALENA), Bogotá, Colombia.

IIAP, I.D.I.D.L.A.P., 2001. Madre de Dios camino al desarrollo sostenible, propuesta de zonificación ecológica económica como base para el ordenamiento territorial, Perú, p. 153.

IPCC (Intergovernmental Panel of Climate Change, us), 2000. Land use, land use change and forestry articulo científico: 377.

IRWIN E. G. y BOCKSTAEL N. E., 2001. The problem of identifying land use spillovers: measuring the effects of open space on residential property values. *American journal of agricultural economics*, 83(3), 698-704.

IRWIN E. G. y GEOGHEGAN J., 2001. Theory, data, methods: developing spatially explicit economic models of land use change. *Agriculture, Ecosystems & Environment*, 85(1), 7-24.

JENSEN J., LIN H., YANG X., RAMSEY III E., 1991. The measurement of mangrove characteristics in southwest Florida using SPOT multispectral data. *Geocarto International*, 6(2), 13-21.

KRUSE F.A., 2004. Comparison of ATREM, ACORN, and FLAASH atmospheric corrections using low-altitude AVIRIS data of Boulder, CO.

LAMBIN E., TURNER B., GEIST H., AGBOLA S., 2001. The causes of land-use and land-cover change: moving beyond the myths. *Global environmental change*, 11(4), 261-269.

LANDIS R. y KOCH G., 1977. The measurement of observer agreement for categorical data. *Biometrics*. *Biometrics*, 1977, 33(1), 159 - 174.

LI P., JIANG L. y FENG Z., 2013. Cross-comparison of vegetation indices derived from Landsat-7 enhanced thematic mapper plus (ETM+) and Landsat-8 operational land imager (OLI) sensors. *Remote Sensing*, 6(1), 310-329.

LI X. y YEH A. G.-O., 2002. Neural-network-based cellular automata for simulating multiple land use changes using GIS. *International Journal of Geographical Information Science*, 16(4), 323-343.

LILLESAND T. M. y KIEFER R. W., 1994. Remote sensing and photo interpretation. John Wiley and Sons: New York, 750.

LU D., MAUSEL P., BATISTELLA M. y MORAN E., 2005. Land-cover binary change detection methods for use in the moist tropical region of the Amazon:

a comparative study *International Journal of Remote Sensing*, 26(1): 101-114.

MALHI Y., PHILLIPS O., 2004. Tropical forests and global atmospheric change: a synthesis *Philosophical Transactions of the Royal Society of London. Series B: Biological Sciences*, 359(1443): 549-555.

MAS J. F., SORANI V. y ALVAREZ R., 1996. Elaboración de un modelo de simulación del proceso de deforestación. *Investigaciones Geográficas (Mx)*, (Es5), 43-57.

MAS J.-F., VELÁZQUEZ A., DÍAZ-GALLEGOS J. R., MAYORGA-SAUCEDO R., 2004. Assessing land use/cover changes: a nationwide multivariate spatial database for Mexico. *International Journal of Applied Earth Observation and Geoinformation*, 5(4), 249-261.

MAYAUX W., ERIK L., RÉMI D., 2012. *Global Forest Land-Use Change 1990-2005*, 20-25.

MEANS J. E., ACKER S. A., HARDING D. J., BLAIR J. B., 1999. Use of large-footprint scanning airborne lidar to estimate forest stand characteristics in the Western Cascades of Oregon. *Remote sensing of environment*, 67(3), 298-308.

MENDOZA J. R. y ALARCÓN G., 2014. Determinación de áreas deforestadas por actividades humanas en la zona de amortiguamiento de la reserva nacional Tambopata y el parque nacional Bahuaja Sonene Madre de Dios. *Biodiversidad Amazonica*. ISSN: 2075-8081, 4.

MINAM., 2015. Ministerio del Ambiente. Cuantificación y análisis de la deforestación en la Amazonía Peruana en el periodo 2010 – 2011 – 2013 – 2014. Dirección General de Ordenamiento Territorial.

MISHRA V. N., RAI P. K. y MOHAN K., 2014. Prediction of land use changes based on land change modeler (LCM) using remote sensing: a case study of Muzaffarpur (Bihar), India. *Journal of the Geographical Institute "Jovan Cvijic"*, SASA, 64(1), 111-127.

MOLERO E., GRINDLA A. L. y ASENSIO J. J., 2007. "Escenarios de aptitud y modelización cartográfica del crecimiento urbano mediante técnicas de evaluación multicriterio. *GeoFocus. Revista Internacional de Ciencia y Tecnología de la Información Geográfica*, (7), 120-147.

MORTON D. C., DEFRIES R. S., SHIMABUKURO Y. E., ANDERSON L. O., 2006. Cropland expansion changes deforestation dynamics in the southern Brazilian Amazon. *Proceedings of the National Academy of Sciences*, 103(39), 14637-14641.

MSAR M. D. S. A. Y. R., 2013. Implementación del mecanismo para Reducción de Emisiones por Deforestación y Degradación - REDD+ en Madre de Dios. In.

MÜLLER J. y BRANDL R., 2009. Assessing biodiversity by remote sensing in mountainous terrain: the potential of LiDAR to predict forest beetle assemblages. *Journal of Applied Ecology*, 46(4), 897-905.

MÜLLER R., LARREA D., CUÉLLAR S. y ESPINOZA S., 2014. Causas directas de la deforestación reciente (2000-2010) y modelado de dos escenarios futuros en las tierras bajas de Bolivia. *Ecología en Bolivia*, 49(1), 20-34.

OEA, 2008. Organización de los Estados Americanos. Programa de Desarrollo Integrado de las Comunidades Fronterizas Peruano-Brasileñas. Disponible en: <http://www.oas.org/dsd/publications/Unit/oea09s/begin.htm#Contens> Acceso:

OLMEDO M. C., MELGAREJO E. M. y PAEGELOW M., 2010. Modelos geomáticos aplicados a la simulación de cambios de usos del suelo. Evaluación del potencial de cambio. In.: Universidad de Sevilla.

ONERN., 1997. Oficina Nacional de Evaluación de Recursos Naturales. Inventario, evaluación e integración de los recursos naturales de la zona Iberia-Iñapari. p. 418.

OSORIO L. P., MAS J.-F., GUERRA F. y MAASS M., 2015. Análisis y modelación de los procesos de deforestación: un caso de estudio en la

cuenca del río Coyuquilla, Guerrero, México. Investigaciones geográficas, (88), 60-74.

PACHECO C., AGUADO I. y MOLLICONE D., 2011. Las causas de la deforestación en Venezuela: un estudio retrospectivo. Biollania, 10, 281-292.

PADILLA M., STEHMAN S. V., RAMO R., CORTI D., 2015. Comparing the accuracies of remote sensing global burned area products using stratified random sampling and estimation. Remote sensing of environment, 160, 114-121.

PAEGELOW M., OLMEDO M. C. y TORIBIO J. M., 2002. Modelización prospectiva del paisaje mediante Sistemas de Información Geográfica. In X Congreso de Métodos Cuantitativos, sistemas de información geográfica y teledetección. Universidad de Valladolid, p. CD.

PARLITZ U. y MERKWIRTH C., 2000. Prediction of spatiotemporal time series based on reconstructed local states. Physical review letters, 84(9), 1890.

PENA P. A. G., 2009. Nuevos modelos de redes neuronales evolutivas y regresión logística generalizada utilizando funciones de base. Aplicaciones. Universidad de Granada.

PIDAL J. H., 2003. Modelización de cambio de cobertura del suelo en la provincia de Napo para el período 1990 – 2000, utilizando regresión logística y maxente, 1-13.

PINOS N. J., 2016. Prospectiva del uso del suelo y cobertura vegetal en el ordenamiento territorial-Caso cantón Cuenca. Estoa. Revista de la Facultad de arquitectura y Urbanismo de la Universidad de Cuenca, (9), 7-18.

PLA L. E., 1986. Análisis multivariado: método de componentes principales. Edición ed.: Secretaría General de la Organización de los Estados Americanos, Programa Regional de Desarrollo Científico y Tecnológico, ISBN 0827024517.

PONTIUS G. R. y MALANSON J., 2005. Comparison of the structure and accuracy of two land change models. *International Journal of Geographical Information Science*, 19(2), 243-265.

PONTIUS JR R. G. y CHEN H., 2006. Land change modeling with GEOMOD. Clark University.

PONTIUS R. G., 2000. Quantification error versus location error in comparison of categorical maps. *Photogrammetric Engineering and Remote Sensing*, 66(8), 1011-1016.

QI Y. y WU J., 1996. Effects of changing spatial resolution on the results of landscape pattern analysis using spatial autocorrelation indices. *Landscape ecology*, 11(1), 39-49.

QUINTERO-ANGEL M. y CARVAJAL-ESCOBAR., 2010. Adaptación o mitigación al cambio climático: consideraciones en el contexto latinoamericano *Revista Investigación, Biodiversidad y Desarrollo*, 29(2).

RASHMI S., ADDAMANI S., VENKAT S. y RAVIKIRAN S., 2014. Spectral Angle Mapper Algorithm for Remote Sensing Image Classification. *IJISSET–International Journal of Innovative Science, Engineering & Technology*, 50(4), 201-205.

Recuperado de http://www.w.hgimaging.com/PDF/Kruse-JPL2004_ATM_Compare.pdf, 2004.

RÍOS J. R., LAGUADO W., TRUJILLO C. y SÁNCHEZ P., 2012. Análisis y modelación de deforestación para los años 1990, 2000 y 2010 en el corredor Manu - Amaraakaeri.

RODRÍGUEZ F. y BAUTISTA S., 2006. Modelos ocultos de Markov para el análisis de patrones espaciales. *Revista Ecosistemas*, 15(3).

ROY D. P., WULDER M., LOVELAND T., WOODCOCK C., 2014. Landsat-8: Science and product vision for terrestrial global change research. *Remote sensing of environment*, 145, 154-172.

ROY D. P., WULDER M., LOVELAND T., WOODCOCK C., 2014. Landsat-8: Science and product vision for terrestrial global change research. *Remote sensing of environment*, 145, 154-172.

SALA O.E., CHAPIN F.S., ARMESTO J.J., BERLOW E., 2000. Global biodiversity scenarios for the year 2100 *science*, 287(5459): 1770-1774.

SALINERO C., SALINERO E. C., VIOLA A. B. B. V., MACLEAN A. S. A. S., 2006. *Teledetección ambiental: la observación de la Tierra desde el espacio*. Edtion ed.: Ariel, 2006. ISBN 8434480727.

SANDOVAL V. y OYARZUN V., 2004. Modelamiento y prognosis espacial del cambio en el uso del suelo. *Quebracho*, 11, 9-21.

SANG L., ZHANG C., YANG J., ZHU D., 2011. Simulation of land use spatial pattern of towns and villages based on CA–Markov model. *Mathematical and Computer Modelling*, 54(3), 938-943.

SIGTIERRAS., 2011. Valoración de tierras rurales cantón Santa Cruz. Quito, Recuperado de http://www.santacruz.bob.ec/gadsantacruz2/gmscdocs/2012/sectecnia/ANEXO_01_MEMORIAS_TECNICAS.pdf

SINGH A. y HARRISON A., 1985. Standardized principal components. *International Journal of Remote Sensing*, 6(6), 883-896.

SOARES-FILHO, B.; ALENCAR, A.; NEPSTAD, D.; CERQUEIRA, G.; Diaz, V.; del CARMEN, M.; Rivero, S.; Solórzano, L.; Voll, E., 2004. Simulating the response of land-cover changes to road paving and governance along a major Amazon highway: the Santarém–Cuiabá corridor *Global Change Biology* 10(5): 745-764.

SOKENG V.-C. J., KOUAMÉ F., N'DA H. D., TANKOANO B., 2016. Cartographie de l'occupation de sol des Hauts Plateaux de l'Ouest Cameroun par réseaux de neurones appliqués à une image LANDSAT 8 OLI [Mapping land cover in Western Cameroon Highlands using neural networks applied to a Landsat 8 OLI image].

SOUTHWORTH J., MARSIK M., QIU Y., PERZ S., 2011. Roads as Drivers of Change: Trajectories across the Tri-National Frontier in MAP, the Southwestern Amazon. *Remote Sensing*, 3(5), 1047-1066.

STEHMAN S. V., 2000. Practical implications of design-based sampling inference for thematic map accuracy assessment. *Remote sensing of environment*, 72(1), 35-45.

STEHMAN S. V., 1997. Selecting and interpreting measures of thematic classification accuracy. *Remote sensing of environment*, 62(1), 77-89.

STEHMAN S. V. y CZAPLEWSKI R. L., 1998. Design and analysis for thematic map accuracy assessment: fundamental principles. *Remote sensing of environment*, 64(3), 331-344.

STEPHEN G., PERZA, YOULIANG Q., YIBIN X., 2013. Trans-boundary infrastructure and land cover change: Highway paving and community-level deforestation in a tri-national frontier in the Amazon.

SWENSON J. J., CARTER C. E., DOMEK J.-C. y DELGADO C. I., 2011. Gold mining in the Peruvian Amazon: global prices, deforestation, and mercury imports. *PloS one*, 6(4), e18875.

UNFCCC., 2001. Decision 5/CP.6, Implementation of the Buenos Aires Plan of Action. UNFCCC Document FCCC/CP/2001/L.7.

USGS., 2017. United States Geological Survey. Earth Explore with imagery gallery Landsat. In., vol. 2017, p. Descarga de imágenes de satélite Landsat.

VALENZUELA L. M., AGUILERA F., SORIA J. A. y MOLERO E., 2008. Designing and assessing of development scenarios for metropolitan patterns. *Modelling Environmental Dynamics*, Ed Springer-Verlag, Berlín.

VALERO J. L., 2015. Estudio multitemporal y análisis prospectivo del cambio de uso de suelo y cobertura vegetal en la microcuenca del río Cristal mediante el uso de autómatas celulares.

VEGA M. V., 2004. Cadenas de Markov de tiempo continuo y aplicaciones. Monografía. Licenciatura en matemática. Universidad de la República de Uruguay.

VELÁZQUEZ A., MAS J., GALLEGOS J., SAUCEDO R., ALCÁNTARA P., CASTRO R., EZCURRA E., 2001. Patrones y tasas de cambio de uso del suelo en México, (62), 28-29, México DF.

VELDKAMP A. y FRESCO L. CLUE: 1996. A conceptual model to study the conversion of land use and its effects. *Ecological modelling*, 85(2-3), 253-270.

XIUWAN C., 2002. Using remote sensing and GIS to analyse land cover change and its impacts on regional sustainable development. *International Journal of Remote Sensing*, 23(1), 107-124.

YAGOUB Y. E., BO Z., DING-MIN J., JAHELNABI A. E., 2015. Land Use and Land Cover Change in Northeast Gadarif State: Case of El Rawashda Forest, Sudan. *Journal of Geographic Information System*, 7(02), 140.

ZHOU G. y LIEBHOLD A. M., 1995. Forecasting the spatial dynamics of gypsy moth outbreaks using cellular transition models. *Landscape ecology*, 10(3), 177-189.

ANEXOS

Anexo 1. Matriz de consistencia prospectiva del cambio de uso de suelo en el distrito de Iberia, Tahuamanu – Madre de Dios, periodo 2004-2030

PLANTEAMIENTO DEL PROBLEMA	OBJETIVOS DE LA INVESTIGACIÓN	HIPÓTESIS DE INVESTIGACIÓN	VARIABLES DE ESTUDIO	INDICADORES	METODOLOGIA DE LA INVESTIGACIÓN
<p>PROBLEMA GENERAL</p> <p>¿Cuál es la tendencia de cambio de uso de suelo en el distrito de Iberia, Tahuamanu – Madre de Dios en los periodos 2004, 2011 y 2016, como base para modelar los cambios de uso</p>	<p>OBJETIVO GENERAL</p> <p>Analizar y modelar el cambio de uso de suelo en el distrito de Iberia, Tahuamanu – Madre de Dios, para los periodos 2004, 2011, 2016 y 2030.</p>	<p>HIPÓTESIS GENERAL</p> <p>Es posible Analizar y modelar el cambio de uso de suelo en el distrito de Iberia, Tahuamanu – Madre de Dios en los periodos 2004, 2011 y 2016, como base para determinar la</p>	<p>Variable Dependiente:</p> <p>Cambio en la cobertura vegetal.</p> <p>Variable Independiente:</p> <p>Comportamiento del objeto en función de la unidad mínima de</p>	<p>Ganadería</p> <p>Expansión agrícola</p> <p>Tala y quema de árboles</p> <p>Construcción de carreteras y caminos vecinales</p> <p>Escala ha.</p>	<p>Tipo de investigación</p> <p>Es una investigación No experimental por que no habrá manipulación de alguna variable, de tipo Correlacional o explicativa</p> <p>Nivel de investigación</p> <p>De nivel Descriptivo, correlacional y predictivo</p> <p>Diseño de Investigación</p>

PLANTEAMIENTO DEL PROBLEMA	OBJETIVOS DE LA INVESTIGACIÓN	HIPÓTESIS DE INVESTIGACIÓN	VARIABLES DE ESTUDIO	INDICADORES	METODOLOGIA DE LA INVESTIGACIÓN
<p>de suelo al año 2030?</p> <p>PROBLEMAS ESPECÍFICOS</p> <p>P1. ¿Cuál fue el cambio de uso de suelo entre 2004, 2011 y 2016 en el distrito de Iberia, Tahuamanu – Madre de Dios?</p> <p>P2. ¿Se podrá modelar y validar el proceso de cambio de uso de suelo para el año 2016, a partir del mapa de</p>	<p>OBJETIVOS ESPECÍFICOS</p> <p>O1. Cuantificar el cambio de uso de suelo entre 2004, 2011 y 2016 en el distrito de Iberia, Tahuamanu – Madre de Dios.</p> <p>O2. Modelar y validar el cambio de uso de suelo para el año 2016, a partir del mapa de uso de suelo del año 2016.</p>	<p>prospectiva de cambio de uso de suelo al año 2030.</p> <p>HIPÓTESIS ESPECÍFICAS</p> <p>He1: La cuantificación del cambio de uso de suelo entre el año 2004, 2011 y 2016 en el distrito de Iberia, Tahuamanu – Madre de Dios, sigue una dinámica con tendencia creciente.</p> <p>He2: La prospectiva</p>	<p>la imagen (píxel), según los diferentes tipos de usos de suelo.</p>		<p>Descriptiva y observacional, Prospectiva (por el tiempo cronológico), transversal y longitudinales de tendencia o trend, ya que se analiza, se cuantifica los cambios de cobertura y modela las áreas deforestadas en periodos determinados (2004, 2011 y 2016)</p> <p>Población</p> <p>Se utilizará la distribución binomial de probabilidad, calculándose el tamaño</p>

PLANTEAMIENTO DEL PROBLEMA	OBJETIVOS DE LA INVESTIGACIÓN	HIPÓTESIS DE INVESTIGACIÓN	VARIABLES DE ESTUDIO	INDICADORES	METODOLOGIA DE LA INVESTIGACIÓN
<p>uso de suelo del año 2016 generado a partir de sensores remotos?</p> <p>P3. ¿Se podrá modelar el proceso de cambio de uso de suelo para el año 2030, a partir del modelo de cambio de uso de suelo?</p>	<p>O3. Modelar el proceso de cambio de uso de suelo para el año 2030, a partir del modelo de cambio de cobertura del suelo.</p>	<p>y validación del cambio de uso de suelo para el año 2016, a partir del mapa de uso de suelo del año 2016, es estadísticamente significativa.</p> <p>He3: La prospectiva de cambio de uso de suelo para el año 2030, a partir del modelo de cambio de cobertura del suelo sigue una dinámica con tendencia creciente.</p>			<p>de muestra mediante la siguiente fórmula:</p> $n = \frac{Z^2 pq}{E^2}$ <p>Muestra</p> <p>Imágenes satelitales, trabajo de campo.</p> <p>Técnicas de análisis de datos e Instrumentos</p> <p>Se aplicara la matriz de confusión, test de estadística descriptiva usada para comparar una clasificación resultante</p>

PLANTEAMIENTO DEL PROBLEMA	OBJETIVOS DE LA INVESTIGACIÓN	HIPÓTESIS DE INVESTIGACIÓN	VARIABLES DE ESTUDIO	INDICADORES	METODOLOGIA DE LA INVESTIGACIÓN
					<p>con información fehaciente de terreno, la exactitud o precisión de este test es medido por el Índice de Kappa.</p> <p>GPS Garmin Map 60 CSx, Brújula, Cámara digital fotográfica</p> <p>Técnicas de Procesamientos de datos:</p> <p>Software TerrSet , ArcGis v.10.3, Envi 5.3, Microsoft Word 2013, Excel 2013.</p>

Anexo 2. Coberturas de deforestación del distrito de Iberia.

**Pasto seco****Cultivos****Quema****Pasto Bracharia****Caminos vecinales****Áreas urbanas discontinuas****Ganaderías****Potrero**