



FACULTAD DE CIENCIAS NATURALES Y MATEMÁTICA

MONITOREO DE LA DEFORESTACIÓN EN EL DEPARTAMENTO DE SAN MARTÍN

MEDIANTE TELEDETECCIÓN PERIODO 1987 – 2017

Línea de investigación:

Física nuclear y ambiental

Tesis para optar el Título Profesional de Licenciada en Física

Autora:

Quispe Mancco, Cynthia Antonia

Asesora:

Tirado Rengifo, Arminda

(ORCID: 0000-0002-2582-7181)

Jurado:

Guzmán Calcina, Carmen Sandra

Velesvilla Velezvia, Twiggy Miosotty

Mejía Cordero, Bernabé Alonso

Lima - Perú

2023



MONITOREO DE LA DEFORESTACIÓN EN EL DEPARTAMENTO DE SAN MARTÍN MEDIANTE TELEDETECCIÓN PERIODO 1987 - 2017

INFORME DE ORIGINALIDAD

22%

INDICE DE SIMILITUD

20%

FUENTES DE INTERNET

4%

PUBLICACIONES

8%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	hdl.handle.net Fuente de Internet	1%
2	repositorio.unfv.edu.pe Fuente de Internet	1%
3	docplayer.es Fuente de Internet	1%
4	idoc.pub Fuente de Internet	1%
5	williamlucasarango.blogspot.com Fuente de Internet	1%
6	kipdf.com Fuente de Internet	1%
7	repositorio.upct.es Fuente de Internet	1%
8	vsip.info Fuente de Internet	1%



Universidad Nacional
Federico Villarreal

VRIN | VICERRECTORADO
DE INVESTIGACIÓN

FACULTAD DE CIENCIAS NATURALES Y MATEMÁTICA

MONITOREO DE LA DEFORESTACIÓN EN EL DEPARTAMENTO DE SAN MARTÍN MEDIANTE

TELEDETECCIÓN PERIODO 1987 – 2017

Línea de investigación:

Física Nuclear y Ambiental

Tesis para optar el Título Profesional de Licenciada en Física

Autora:

Quispe Mancco, Cynthia Antonia

Asesora:

Tirado Rengifo, Arminda

(ORCID: 0000-0002-25827181)

Jurado:

Guzmán Calcina, Carmen Sandra

Velesvilla Velezvia, Twiggy Miosotty

Mejía Cordero, Bernabé Alonso

Lima – Perú

2023

Dedicatoria

A mis queridos padres: Sr. Julián Quispe y Sra. Evangelina Mancco, por su amor incondicional, apoyo constante y sacrificio incansable a lo largo de mi educación. A mis hermanas: Sara y María del Carmen, quienes han sido mi fuente constante de alegría y motivación a lo largo de este viaje.

Agradecimiento

A la Universidad Nacional Federico Villarreal - Facultad de Ciencias Naturales y Matemáticas en especial mi asesora de tesis, la Dra. Arminda Tirado Rengifo, por su orientación, sabiduría y paciencia. Sus valiosas sugerencias y consejos fueron fundamentales en el desarrollo de esta investigación.

A la Comisión Nacional de Investigación y Desarrollo Aeroespacial (CONIDA), por patrocinar y brindarme la oportunidad de llevar a cabo esta investigación en sus instalaciones. Agradezco al equipo de investigación de la Dirección de Aplicaciones Satelitales y Geomática, por su asistencia y orientación durante este proceso, su experiencia y conocimientos compartidos han enriquecido enormemente esta investigación.

A mis apreciados amig@s y colegas por ser excelentes profesionales que con sus sabios consejos alientan permanentemente mi formación profesional.

ÍNDICE

RESUMEN.....	12
ABSTRACT.....	13
I. INTRODUCCIÓN.....	1
1.1 Descripción y formulación del problema.....	3
1.2 Antecedentes.....	5
1.3 Objetivos.....	9
1.4 Justificación.....	9
II. MARCO TEÓRICO.....	11
2.1 Bases teóricas sobre el tema de investigación.....	11
2.2 Tipos de sensores.....	19
2.3 Satélites de observación.....	21
2.4 Plataformas de descarga.....	25
2.5 Fundamentos físicos.....	26
2.6 Firmas espectrales de la vegetación.....	33
2.7 Pre procesamiento de imágenes de satélite.....	34
2.8 Monitoreo del cambio de cobertura.....	40
2.9 Detección y mapeo del cambio de cobertura.....	40
2.10 Técnicas de análisis multitemporal.....	41

2.11	Técnicas de clasificación.....	42
2.12	El clasificador support vector machines (SVM)	43
2.13	Matriz de confusión.....	46
2.14	Índices globales.....	48
2.15	Tasa de deforestación	50
III. MÉTODO.....		51
3.1	Tipo de investigación	51
3.2	Ámbito temporal y espacial.....	51
3.3	Variables.....	51
3.4	Población y muestra	51
3.5	Instrumentos	52
3.5.1	Equipos y software	52
3.5.2	Materiales	53
3.6	Procedimiento.....	55
3.6.1	Etapa descarga de imágenes	55
3.6.2	Etapa de procesamiento	57
3.6.3	Etapa clasificación supervisada	86
3.6.3.1	Precisión de la clasificación.	90
3.6.3.2	Imagen clasificada.....	95
3.7	Análisis de datos.....	98

IV. RESULTADOS	99
V. DISCUSIÓN DE RESULTADOS	115
VI. CONCLUSIONES	119
VII. RECOMENDACIONES	121
VIII. REFERENCIAS	122
IX. ANEXOS	127
Anexo A. código de distribución de dos clases en SVM	128
Anexo B. Lista de imágenes satelitales landsat descargadas	129
Anexo C. Lista de imágenes master descargadas.....	131
Anexo D. mapa de deforestación año 1987.....	132
Anexo E. mapa de deforestación año 1997	133
Anexo F. mapa de deforestación año 2007	134
Anexo G. Mapa de Deforestación Año 2017	135
Anexo H. Mapa de Cambio de Cobertura del Suelo – Periodo (1987 – 1997).....	136
Anexo I. Mapa de Cambio de Cobertura del Suelo – Periodo (1997 – 2007)	137
Anexo J. Mapa de Cambio de Cobertura del Suelo – Periodo (2007 – 2017)	138

ÍNDICE DE TABLAS

Tabla 1 Áreas deforestadas hasta el año 2000 en diferentes departamentos	8
Tabla 2 Satélites de observación de la tierra.....	22
Tabla 3 Magnitudes radiométricas.....	28
Tabla 4 Valoración de índice kappa.....	50
Tabla 5 Cartografía de la zona de estudio.....	54
Tabla 6 Lista de sensores landsat descargados	56
Tabla 7 Resultado del RMSE para la imagen master y área porcentual según path/row	61
Tabla 8 Resultados del correregistro (imagen master – imagen esclava).....	65
Tabla 9 Resultado del RMSE total de la corrección geométrica	67
Tabla 10 Resultado del RMSE total de la corrección geométrica por año	69
Tabla 11 Resultado de la media y la desviación estándar total de la corrección geométrica	69
Tabla 12 Distribución de correcciones radiométricas.....	72
Tabla 13 Ecuaciones Lineales para el Cálculo de la Variable Radiancia	77
Tabla 14 Ecuaciones para el cálculo de la variable reflectancia por banda.....	79
Tabla 15 Ecuaciones para el cálculo de la corrección atmosférica.....	83
Tabla 16 Distribución de corrección atmosférica	84
Tabla 17 Clases identificadas en el área de estudio	89
Tabla 18 Matriz de confusión de la escena 8_66 del año 2007 con índice kappa de 0.99%	92
Tabla 19 Resultados de la exactitud global de la clasificación.....	94
Tabla 20 Precisión del productor	94
Tabla 21 Precisión del usuario	95
Tabla 22 Reporte de clasificación de mapa de deforestación - año 1987.....	100

Tabla 23 Reporte de clasificación de mapa de deforestación año 1997	101
Tabla 24 Reporte de clasificación de mapa de deforestación año 2007	102
Tabla 25 Reporte de clasificación de mapa de deforestación año 2017	103
Tabla 26 Reporte de la reclasificación de mapa bosque y no bosque.....	107
Tabla 27 Interpretación de las nuevas clases resultantes	110
Tabla 28 Reporte de la matriz de cambio	111

ÍNDICE DE FIGURAS

Figura 1 Evolución del área deforestada total (1960 - 2004) - Departamento de San Martín	7
Figura 2 Proceso de la teledetección.....	12
Figura 3 Formas de adquirir información a partir de un sensor remoto	14
Figura 4 Esquema de una onda electromagnética.....	15
Figura 5 Relación entre la temperatura y la radiación electromagnética emitida.....	16
Figura 6 Espectro electromagnético.....	17
Figura 7 Ilustración del funcionamiento de un sensor	19
Figura 8 Órbitas de los satélites.....	22
Figura 9 Escena landsat para path 8 / row 66	26
Figura 10 Relación entre el flujo incidente y reflejado.....	31
Figura 11 Respuestas espectrales.....	33
Figura 12 Comportamiento espectral de la vegetación.....	34
Figura 13 Componentes de una imagen satelital digital	36
Figura 14 Esquema de funcionamiento del clasificador SVM	44
Figura 15 Grafica de puntos generados en el plano (x, y)	45
Figura 16 Grafica de la estimación del método SVM con kernel lineal.....	45
Figura 17 Esquema general de la matriz de confusión	48
Figura 18 Cobertura espacial de las escenas de las imágenes landsat	56
Figura 19 Distribución de imágenes descargadas para el periodo de estudio.....	57
Figura 20 Identificación de los puntos de control.....	59
Figura 21 Distribución homogénea de los puntos de control imagen – vector.....	59
Figura 22 Distribución del RMSE	62

Figura 23 Selección de puntos de control usando el interfaz.....	63
Figura 24 Compilación del interfaz	64
Figura 25 representación gráfica de la distribución del RMSE	66
Figura 26 Representación gráfica de la distribución del RMSE total.....	68
Figura 27 Barras de error con desviación estándar	70
Figura 28 Interfaz de calibración radiométrica de radiancia y reflectancia.....	73
Figura 29 Resultados de la variable física reflectancia usando (Modelo A)	73
Figura 30 Resultados erróneos de la reflectancia usando (modelo A).....	74
Figura 31 Desviación de posición de la imagen	75
Figura 32 Constantes predeterminadas	76
Figura 33 Resultado del valor de la radiancia.....	78
Figura 34 Plantilla excel	79
Figura 35 Resultados de la variable física reflectancia.....	80
Figura 36 Comparación de modelos en la distribución de la reflectancia TOA.....	81
Figura 37 Comportamiento espectral de la superficie	82
Figura 38 Método del objeto oscuro, desarrollado por Chávez, J. (1988).....	83
Figura 39 Comparación de los resultados de la corrección atmosférica.....	85
Figura 40 Comparación de las imágenes landsat8 composición en color natural RGB	86
Figura 41 Combinación de bandas en falso color - RGB	87
Figura 42 Secuencia de generación de la máscara para la escena 8_66 del año 1987.....	88
Figura 43 Vectorización de las imágenes landsat	89
Figura 44 Distribución del índice kappa por escena y año	91
Figura 45 Distribución total de los roi's generados por clase.....	93

Figura 46 Comparación de áreas clasificadas	96
Figura 47 Identificación de coberturas nubosas.....	97
Figura 48 Mapas de deforestación del departamento de San Martín.....	99
Figura 49 Tendencia de la deforestación para el departamento de san martin	104
Figura 50 Eliminación de nubes y sombras	105
Figura 51 Mapas de bosque y no bosque del departamento de San Martin.....	106
Figura 52 Cantidad de cobertura nubosa y sombra.....	108
Figura 53 Mapas de cambio de cobertura del suelo.....	109
Figura 54 Ilustración esquemática del cambio de cobertura del suelo	113
Figura 55 Tasa de deforestación	114

RESUMEN

La presente investigación tiene como **objetivo** principal el monitoreo de la deforestación en el Departamento de San Martín, Perú, durante tres décadas, desde 1987 hasta 2017, mediante técnicas de teledetección. **Método:** Para alcanzar este objetivo, se recopilaron y procesaron imágenes satelitales Landsat 5 TM y Landsat 8 OLI correspondientes a los años 1987, 1997, 2007 y 2017. Se aplicó corrección geométrica y atmosférica a las imágenes utilizando el software ENVI. Posteriormente, se llevó a cabo una clasificación supervisada utilizando el algoritmo de aprendizaje automático Máquinas de Vectores de Soporte (SVM) mediante la caja de herramientas de Orfeo ToolBox (OTB) en el software QGIS. **Resultado:** Este enfoque permitió un análisis detallado y preciso de las imágenes satelitales, facilitando la identificación y categorización precisa de las áreas afectadas por la deforestación. Se generaron diversos mapas, como los de deforestación y los de bosque y no bosque, utilizando el software ARCGIS. Estos mapas posibilitaron la creación de mapas de cambio de cobertura del suelo para los períodos 1987 – 1997, 1997 – 2007 y 2007 – 2017, ilustrando las transformaciones en la cobertura del suelo a lo largo del tiempo. **Conclusión:** Los resultados obtenidos revelan un aumento constante en la deforestación a lo largo del período estudiado, con un incremento significativo en el periodo 2007 - 2017.

Palabras clave: teledetección, corrección geométrica, corrección atmosférica, SVM, cambio de cobertura del suelo, deforestación.

ABSTRACT

The main **objective** of this research is to monitor deforestation in the Department of San Martín, Peru, for three decades, from 1987 to 2017, using remote sensing techniques. **Method:** To achieve this objective, Landsat 5 TM and Landsat 8 OLI satellite images corresponding to the years 1987, 1997, 2007 and 2017 were collected and processed. Geometric and atmospheric correction was applied to the images using the ENVI software. Subsequently, supervised classification was carried out using the Support Vector Machines (SVM) machine learning algorithm using the Orfeo ToolBox (OTB) in QGIS software. **Result:** This approach allowed for detailed and accurate analysis of satellite images, facilitating the accurate identification and categorization of areas affected by deforestation. Various maps were generated, such as those of deforestation and those of forest and non-forest, using the ARCGIS software. These maps made it possible to create maps of land cover change for the periods 1987 – 1997, 1997 – 2007 and 2007 – 2017, illustrating the transformations in land cover over time. **Conclusion:** The results obtained reveal a constant increase in deforestation throughout the period studied, with a significant increase in the period 2007 - 2017.

Keywords: remote sensing, geometric correction, atmospheric correction, SVM, land cover change, deforestation

I. INTRODUCCIÓN

Cada vez se valora más la relevancia de los bosques en la lucha contra la pobreza y en la preservación del medio ambiente (FAO, 2001). A pesar de esto, el índice de deforestación a nivel mundial sigue siendo alarmante (FAO, 2003).

En el contexto peruano, el desarrollo socioeconómico y el proceso de deforestación en la selva amazónica se han caracterizado por períodos marcados, impulsados principalmente por la explotación de recursos naturales. En la actualidad, actividades humanas como la agricultura, ganadería, minería y tala están provocando la pérdida anual de vastas áreas boscosas. Este fenómeno representa una preocupación significativa debido a sus impactos no solo en la biodiversidad local, sino también en el equilibrio ecológico a nivel global. Es precisamente por estas razones que el Estado Peruano ha intensificado sus esfuerzos para proteger la salud humana, prevenir la contaminación ambiental y conservar el patrimonio nacional. En este sentido, se han implementado medidas robustas para fortalecer la prevención y el monitoreo de la deforestación y degradación de la selva amazónica. Para el monitoreo de la deforestación, se propone utilizar la tecnología satelital, que proporciona un conocimiento global de cualquier región de la superficie terrestre a través de imágenes capturadas por sensores a bordo de satélites. Estas imágenes son accesibles para cualquier persona o institución interesada. Esta tecnología ofrece rapidez y cierta precisión en los estudios ambientales, facilitando el levantamiento, evaluación, análisis, toma de decisiones y ejecución de proyectos en áreas económicamente desfavorecidas o amenazadas desde el punto de vista ecológico (Chuvieco, 2002).

La teledetección se erige como una herramienta esencial en el monitoreo de la deforestación. Al proporcionar datos precisos y actualizados, esta tecnología ofrece una visión detallada de las transformaciones en la cobertura forestal a lo largo del tiempo y en vastas extensiones geográficas. Al combinar la teledetección con técnicas de procesamiento de imágenes y aprendizaje automático, es posible

desarrollar modelos y algoritmos que facilitan la detección y el monitoreo de la deforestación de manera eficiente y precisa. Estos modelos pueden identificar cambios en los patrones de vegetación, distinguir entre deforestación y reforestación, y generar mapas actualizados de la cobertura forestal.

El empleo de la teledetección para el monitoreo de la deforestación consiste en utilizar imágenes y datos obtenidos por satélites para identificar, medir y analizar los cambios en la cobertura forestal a lo largo del tiempo y en áreas geográficas.

En este estudio, se empleó información proveniente de los satélites Landsat, los cuales proporcionan datos fundamentales para el monitoreo de la deforestación. La utilidad clave de Landsat en este contexto radica en su alta resolución espacial y temporal, su sensibilidad espectral y su extensa historia de adquisición de datos. Estas características lo convierten en una fuente invaluable de información para investigaciones orientadas al estudio y conservación de los bosques en el departamento de San Martín durante el período 1987-2017.

Este estudio se enfoca específicamente en el uso de imágenes de satélite Landsat para investigaciones forestales en el departamento de San Martín. El objetivo principal es cuantificar y analizar la variación en la deforestación durante el período de 1987 a 2017 en este departamento. Esto se logra mediante la creación de mapas detallados que representan los cambios en la cobertura del suelo. Este análisis contribuye significativamente a la conservación y preservación del medio ambiente, fomentando un enfoque sostenible y autosuficiente en la gestión forestal de la región.

La síntesis de esta investigación, contribuye con la filosofía de trabajo gubernamental de la Comisión Nacional de Investigación y Desarrollo Aeroespacial – Dirección de Geomática, en su tarea principal de aplicación y desarrollo de metodologías usando las geo-tecnologías.

Esta investigación está constituida por los siguientes capítulos:

En el capítulo I, se presenta la introducción, se detalla la descripción y formulación del problema de área de estudio, los antecedentes, objetivos generales y específicos del estudio de investigación y la justificación.

El capítulo II, comprende el marco teórico donde se detalla la fundamentación teórica de las herramientas y metodologías utilizadas en este estudio.

En el capítulo III, se presenta en detalle la metodología empleada en este estudio. Se especifica el tipo de investigación, el alcance temporal y espacial, así como las variables consideradas. Además, se detalla la población y muestra estudiada, se ofrece una descripción pormenorizada de los instrumentos utilizados y se explican las etapas del proceso de investigación. Además, se proporciona información sobre los métodos empleados para analizar los datos recolectados.

En los capítulos IV y V, se exponen los resultados obtenidos y se realiza un análisis detallado de los mismos. Esta sección presenta los datos de forma objetiva, utilizando gráficos y tablas que facilitan la comprensión de los resultados de manera visual y estructurada. Asimismo, en el capítulo de conclusiones se presentan los resultados claves que se vinculan con los objetivos del estudio, también se detalla las recomendaciones donde se ofrece orientación sobre las acciones o medidas a utilizar.

En la parte final del presente estudio de investigación se encuentran las referencias bibliográficas utilizadas, así como también se anexos con información complementaria que respaldar el estudio de investigación y los mapas generados.

1.1 Descripción y formulación del problema

1.1.1 Descripción del problema

El presente trabajo de investigación se enfoca en el monitoreo de la deforestación en el Departamento de San Martín, ubicado en la región nororiental de Perú, durante un período que abarca desde 1987 hasta 2017. La deforestación, entendida como la pérdida de la cubierta forestal natural, es un problema

ambiental crítico en esta región y tiene implicaciones significativas en términos de biodiversidad, cambio climático y calidad de vida de las comunidades locales.

La deforestación por tala ilegal y cambio de uso del suelo es el causante del 47 % de emisiones de Gases de Efecto Invernadero (GEI) que producimos como país, la región de San Martín ha experimentado de manera significativa los efectos del proceso migratorio, resultando en una explotación excesiva de los recursos naturales. Esta sobreexplotación se manifiesta a través de prácticas como la deforestación, la degradación de los bosques y del suelo, así como la contaminación de cuerpos de agua, entre otros impactos ambientales negativos causados por la actividad humana. Estas acciones han llevado a la emisión considerable de gases de efecto invernadero, principalmente dióxido de carbono (CO₂), con consecuencias perjudiciales a medio y largo plazo. Este fenómeno no está limitado solo a San Martín, sino que se observa en toda la región amazónica. (Ministerio del Ambiente, 2012).

Es crucial tener en cuenta que la deforestación en esta área, al igual que en toda la Amazonía, no solo ha implicado la pérdida de especies maderables de valor comercial, sino también la desaparición de sistemas ecológicos completos que operaban en armonía y de manera eficaz en la naturaleza. Aunque la recuperación de estos ecosistemas es un proceso lento y costoso, es evidente que el desafío radica en la conservación cuidadosa de las áreas boscosas que aún quedan en el territorio de San Martín. (Servicio Nacional Forestal y de Fauna Silvestre, 2012).

La comprensión completa de la dinámica de la deforestación en el Departamento de San Martín es esencial para diseñar estrategias efectivas de conservación y manejo sostenible de los recursos naturales en la región. Además, se requiere un seguimiento constante de los cambios en la cobertura forestal para evaluar el impacto de las políticas y acciones implementadas en la zona. Para la detección de cambios de cobertura

forestal se analizarán imágenes multispectrales de satélite óptico, utilizando técnicas de teledetección con el fin de cuantificar y analizar cómo ha variado la cobertura forestal desde una perspectiva espacio-temporal en el departamento de San Martín en el periodo 1987 – 2017.

1.1.2 *Formulación del problema*

¿Cómo ha evolucionado la deforestación en el Departamento de San Martín durante el período de 1987 a 2017, y cuáles son las causas de estos cambios en la cobertura forestal?

1.2 Antecedentes

1.2.1 *Investigaciones realizadas sobre deforestación en el departamento de San Martín*

Layza Castañeda et al., 2018, llevó a cabo una investigación sobre la deforestación y el cambio climático en la provincia de San Martín durante el período de 1973 a 2014. En este estudio, se calcularon las áreas deforestadas acumuladas y se recopilaron datos sobre variables climáticas como la temperatura máxima y mínima, la humedad relativa y la precipitación. Estos datos se organizaron en períodos de cinco años y se proyectaron utilizando técnicas de regresión lineal. De esta manera, se estableció una correlación entre las áreas deforestadas acumuladas y las condiciones climáticas, incluyendo la temperatura promedio, la humedad relativa y la precipitación. Los resultados obtenidos por el autor revelaron que los principales agentes de deforestación fueron agricultores, ganaderos, empresas agroindustriales y concesiones forestales para la explotación de madera. En relación al comportamiento proyectado por las variables deduce que la deforestación vs la temperatura promedio obedecen a un comportamiento directamente proporcional con un grado de asociación de 66,28%, mientras que la deforestación vs humedad relativa, deforestación vs precipitación obedecen a un comportamiento inversamente proporcional con grado de asociación de 68,71% y 63,39% respectivamente. El autor llega a la conclusión de que la deforestación ha impactado en el cambio climático al disminuir la retención de calor en las capas cercanas a la superficie terrestre. Esto se debe a la

reducción en la absorción de energía solar, la cual normalmente ocurre a través de la evaporación del agua presente en las hojas de los árboles.


El Ministerio del Ambiente ha publicado un informe que presenta resultados sobre la cuantificación y análisis de la pérdida de bosques debido a la deforestación. Este análisis abarca el período de 2010 a 2014 e incluye diversas áreas geográficas y categorías de uso dentro del ámbito amazónico. Los resultados indican que los departamentos con la mayor superficie deforestada durante el periodo 2010-2014 fueron San Martín, Loreto, Ucayali, Huánuco y Madre de Dios. Esta tendencia se ha mantenido relativamente constante desde el año 2000. En conjunto, estos departamentos representan el 86% de la superficie deforestada durante este período, según el informe del Ministerio del Ambiente en 2015.

El Instituto de Investigaciones de la Amazonía Peruana trabajó en conjunto con el Gobierno Regional de San Martín para llevar a cabo una investigación que revela que uno de los efectos más evidentes de la presencia humana en el departamento de San Martín es la rápida deforestación y cambio en el entorno natural. Se señala que antes de 1940, a pesar de la existencia de haciendas y fincas dedicadas a la producción agrícola, gran parte de los valles del Huallaga y del Mayo aún mantenían su cobertura boscosa con vegetación natural. Según las estimaciones basadas en el análisis de imágenes satelitales del proyecto ZEE-San Martín, la deforestación total alcanzó las 1,421,874 hectáreas para el año 2000. Esto implica que aproximadamente 1,125,000 hectáreas de bosque natural se perdieron en el departamento de San Martín durante el período de 1960 a 2000. En la **Figura 1**, el momento de mayor intensidad en la deforestación ocurrió hasta los primeros años de la década de 1980. Durante esta década, se registró una desaceleración en el ritmo de deforestación con un saldo neto de recuperación de bosques secundarios. No obstante, a finales de los años 80, el auge del narcotráfico llevó a una expansión rápida de los cultivos de coca,

resultando en la tala de áreas periféricas y la contaminación de cuerpos de agua. (Instituto de Investigaciones de la Amazonía Peruana, 2009).

Figura 1

Evolución del área deforestada total (1960 - 2004) - Departamento de San Martín



Nota. La figura representa el período de deforestación más intenso, que se prolongó hasta los primeros años de la década de 1980. Tomado del Instituto Nacional de Estadística e Informática - INEI, 2000.

El Instituto Nacional de Recursos Naturales ha preparado un informe detallado que resume los estudios previos sobre la deforestación a nivel local y nacional. Este informe proporciona información sobre las áreas deforestadas identificadas en varios estudios, así como los métodos utilizados para recopilar estos datos. Se ofrece una descripción minuciosa de la metodología empleada para crear el mapa de deforestación. Esto incluye el procesamiento digital de las imágenes satelitales, el proceso de interpretación detallado, que abarca los criterios, elementos y consideraciones utilizados en este proceso. También se detalla la validación

estadística de esta interpretación, así como los ajustes y ediciones realizados para obtener el mapa final de deforestación en la Amazonia peruana para el año 2000.

En el ámbito departamental, San Martín se distingue por su extensa área de deforestación, abarcando 1,327,736.15 hectáreas, lo que constituye el 18.51% del total, según se muestra en la Tabla 1 (Instituto Nacional de Recursos Naturales, 2005).

Tabla 1

Áreas deforestadas hasta el año 2000 en diferentes departamentos

Departamento	Superficie deforestada (ha)	Contribución a la deforestación total (%)
San Martín	1 327 736,15	18,51
Amazonas	1 001 540,11	13,96
Loreto	945 642,15	13,18
Junín	734 303,77	10,24
Ucayali	627 096,73	8,74
Huanuco	600 654,46	8,37
Cusco	537 632,37	7,50
Cajamarca	520 061,64	7,25
Pasco	302 020,89	4,21
Madre de Dios	203 891,86	2,84
Puno	146 041,32	2,04
Ayacucho	135 373,07	1,89
Huancavelica	51 990,69	0,72
Piura	31 737,07	0,44
La Libertad	7 231,69	0,10
Total	7 172 953,97	100,00

Nota. A nivel departamental, San Martín se destaca por tener la mayor superficie deforestada, totalizando 1,327,736.15 hectáreas, lo que representa el 18.51% del área afectada. Tomado del Instituto Nacional de Recursos Naturales, 2005.

1.3 Objetivos

1.3.1 Objetivo general

Cuantificar y analizar la variación de la deforestación durante el periodo 1987 - 2017 en el Departamento de San Martín a través de mapas de cambio de cobertura, contribuyendo a la conservación y preservación auto – sostenida del medio ambiente.

1.3.2 Objetivos específicos

- Demostrar la capacidad de las imágenes Landsat en la caracterización de la deforestación.
- Aplicar metodologías de clasificación para la identificación de las diferentes coberturas en el área de estudio establecido.
- Evaluar la calidad de dichos procedimientos.
- Fomentar la disposición y el uso de las geos tecnologías con otras entidades públicas involucradas en el manejo forestal sostenible.

1.4 Justificación

Las actividades humanas están llevando a la pérdida anual de extensas áreas boscosas. Este impacto no se limita a la desaparición de árboles; también pone en riesgo la biodiversidad, los hogares de la fauna silvestre y los beneficios ambientales que los bosques proporcionan. Además, la transformación de los bosques tropicales en terrenos cubiertos principalmente por vegetación gramínea o la deforestación no solo aumenta la temperatura superficial a nivel continental, sino que también reduce la evaporación y las precipitaciones. Este proceso de pérdida de biomasa forestal incrementa la concentración de dióxido de carbono (CO₂) en la atmósfera, lo que a su vez contribuye al calentamiento global. Estamos viendo cómo nuestras acciones están alterando drásticamente nuestro entorno, amenazando no solo la belleza natural de nuestros bosques, sino también el equilibrio vital de nuestro planeta.

Este estudio de investigación presenta avances significativos en el monitoreo de la deforestación mediante el análisis multitemporal de imágenes satelitales. Su objetivo central es promover la conservación y la recuperación sostenible del medio ambiente, concentrándose en prevenir, controlar y revertir la degradación forestal. Además, introduce una metodología innovadora que capacita a los usuarios para gestionar de manera eficaz los recursos naturales. Al mismo tiempo, se esfuerza por proporcionar políticas y herramientas de planificación precisas para el departamento de San Martín, marcando un paso importante hacia la gestión responsable de nuestros valiosos recursos forestales.

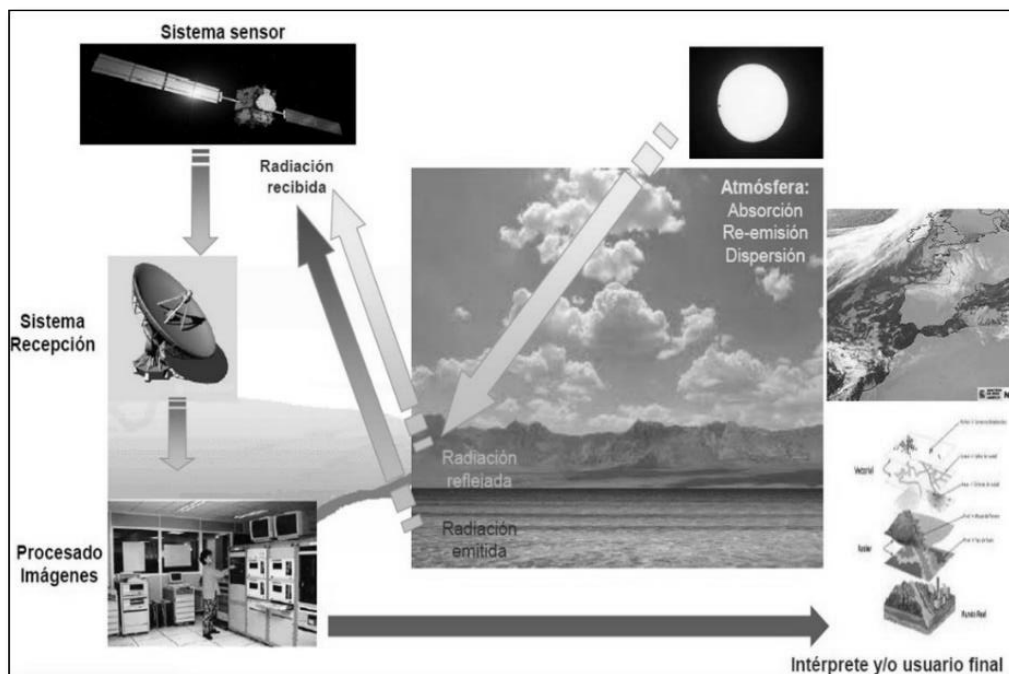
II. MARCO TEÓRICO

2.1 Bases teóricas sobre el tema de investigación

2.1.1 *Teledetección*

La teledetección es el proceso científico de adquirir y procesar información de la superficie terrestre mediante sensores instalados en plataformas espaciales. Esto se logra gracias a la interacción de la energía electromagnética entre el sensor y la tierra (Chuvieco, 1995a). Desde una perspectiva física, la teledetección se basa en el principio de la perturbación, es decir, la energía electromagnética que el sistema observado genera en su entorno. Esta energía se transmite al sistema receptor, que captura la señal para su posterior registro, almacenamiento e interpretación (Sobrino, 2000), como se muestra en la Figura 2.

Componentes: Fuente de energía, cubierta terrestre, atmósfera., sistema sensor, sistema de recepción., procesado imágenes, intérprete y/o usuario.

Figura 2*Proceso de la teledetección*

Nota. Este diagrama captura de manera concisa la interacción entre la fuente de energía, la cubierta terrestre, la atmósfera, el sistema sensor, el sistema de recepción, el procesamiento de imágenes y, finalmente, la interpretación y uso de los datos. Esta representación es fundamental para comprender la complejidad de la teledetección y cómo estos elementos se entrelazan para proporcionar información valiosa sobre la superficie terrestre. Tomado de Sobrino, 2000.

2.1.2 Fundamentos de la teledetección

La teledetección es una técnica que nos permite obtener información sobre objetos ubicados en la superficie terrestre desde una distancia considerable. Para que esta observación a distancia sea factible, debe existir una interacción entre los objetos y el sensor utilizado. Nuestros sentidos solo pueden percibir un objeto cuando son capaces de interpretar la información que este emite. Por ejemplo, podemos ver un árbol

porque nuestros ojos reciben y traducen adecuadamente la energía luminosa proveniente del mismo. Es importante notar que esta señal no es generada por el árbol en sí, sino por una fuente de energía externa que lo ilumina. Por esta razón, en completa oscuridad, no seríamos capaces de percibir ese árbol.

Este ejemplo sencillo nos ayuda a introducir los tres elementos principales de cualquier sistema de teledetección: el sensor (análogo a nuestros ojos), el objeto observado (como el árbol en el ejemplo) y el flujo de energía que conecta ambos y que, en última instancia, permite detectar el objeto. En nuestro caso, este flujo de energía proviene del árbol a través de la reflexión de la luz solar. Sin embargo, también podría tratarse de algún tipo de energía emitida por el propio objeto (por ejemplo, si fuéramos capaces de detectar el calor que emite), o incluso por el sensor (como sería el caso de una cámara equipada con flash). Estas son precisamente las tres formas en las que se puede adquirir información a través de un sensor remoto: por reflexión, por emisión y por reflexión-emisión, como se ilustra en la Figura 3. La información obtenida a través de la teledetección se clasifica en varias formas, siendo la primera y más crucial de ellas la que proviene directamente de la luz solar, la principal fuente de energía de nuestro planeta. Cuando el sol ilumina la superficie terrestre, esta refleja esa energía en función del tipo de cobertura presente en ella. Este flujo reflejado es capturado por el sensor y posteriormente transmitido a las estaciones receptoras. En este proceso, la atmósfera actúa como intermediaria, dispersando y absorbiendo parte de la señal original.


Además, la observación remota puede basarse en la energía emitida por las propias coberturas, o en la que podría ser enviada desde un sensor capaz tanto de generar su propio flujo energético como de recoger su reflexión en la superficie terrestre. Estos métodos de teledetección constituyen una herramienta esencial para entender nuestro entorno y realizar análisis detallados de la Tierra desde una perspectiva espacial.

En todos estos escenarios, la transferencia de energía entre la superficie terrestre y el sensor se realiza a través de radiación electromagnética. Como se sabe, la energía se desplaza de un punto a otro

mediante tres procesos: convección, conducción y radiación. Nos enfocaremos en este último proceso, ya que es fundamental para los sistemas de teledetección (Chuvienco, 2010).

Figura 3

Formas de adquirir información a partir de un sensor remoto



Nota. Formas de teledetección que nos permite observar y entender nuestro entorno desde el espacio, (1) Reflexión (2) Emisión (3) Reflexión-Emisión. Tomado de Chuvienco, 2002.

Para comprender plenamente cómo funciona un sistema de teledetección, es importante conocer las teorías que explican cómo se comporta y cuáles son las propiedades de la radiación electromagnética. Estas teorías se detallan a continuación y puedes verlas en la Figura 4 para tener una idea visual de cómo se relacionan.

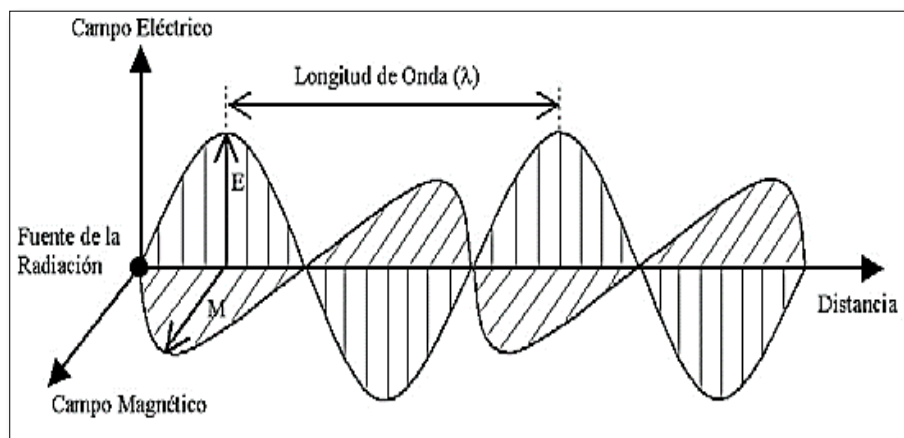
- **La radiación electromagnética** se propaga de un punto a otro de manera continua, como una onda armónica, a la velocidad de la luz. Esta radiación contiene dos campos de fuerza: uno eléctrico y otro magnético, los cuales están determinados por la longitud de onda y la

frecuencia de la radiación. En pocas palabras, esta teoría nos dice cómo la luz y otras formas de radiación electromagnética se mueven y se comportan en el espacio.

- **Teoría Cuántica:** Esta nos dice que la radiación electromagnética se presenta en forma de fotones, que son como pequeñas partículas sin masa. Es interesante porque nos permite calcular cuánta energía tiene un fotón si conocemos su frecuencia: a frecuencias más altas, corresponde una mayor cantidad de energía, y viceversa. En resumen, esta teoría nos ayuda a entender cómo la luz y otras formas de radiación se comportan a nivel subatómico, revelando su naturaleza dual tanto como onda como partícula.

Figura 4

Esquema de una onda electromagnética



Nota. La gráfica ilustra la representación visual de una onda electromagnética, mostrando la variación periódica de los campos eléctricos y magnéticos a medida que se propagan en el espacio. Tomado de Chuvieco, 2002.


2.1.3 Espectro electromagnético

La teoría cuántica nos dice que cuando la longitud de onda de la radiación electromagnética disminuye, la energía contenida en ella aumenta. La longitud de onda está relacionada con la frecuencia de la radiación, y son inversamente proporcionales. En otras palabras, si la frecuencia de una onda es alta, su longitud de onda será corta. Esto significa que las ondas con alta frecuencia tienen mucha energía.

Cuando un objeto se calienta lo suficiente, emite radiación electromagnética. La cantidad de energía que emite y la frecuencia de la radiación dependen de la temperatura del objeto. A temperaturas muy altas, el objeto emite mucha energía y las frecuencias de las ondas son elevadas, como se muestra en la Figura 5. En pocas palabras, este principio nos ayuda a entender cómo diferentes temperaturas están relacionadas con la energía y la frecuencia de la radiación que emiten.

Figura 5

Relación entre la temperatura y la radiación electromagnética emitida




Nota. Este gráfico ilustra cómo la temperatura del objeto emisor está relacionada con la longitud de onda en la que emite la mayor cantidad de radiación. Tomado del Dpto. de Física Aplicada Universidad de Sevilla, 2015.

En el análisis realizado, se descubre que cuando un objeto alcanza la temperatura del Sol, alrededor de 6000K, emite radiación principalmente en el espectro visible, lo que significa que vemos esa radiación como luz. A medida que la temperatura del objeto emisor disminuye, el punto de máxima emisión se desplaza hacia longitudes de onda más largas, entrando en el rango infrarrojo, que es invisible para el ojo humano. Cuando la temperatura aumenta, nos movemos hacia el espectro de los rayos ultravioleta, que también es invisible.

Aunque las longitudes de onda varían de forma continua, los científicos han establecido ciertas bandas donde la radiación electromagnética muestra un comportamiento similar. La Figura 6 muestra cómo se organizan estas bandas en el espectro electromagnético, especialmente en el contexto de su aplicación en teledetección. Estas bandas son fundamentales para entender cómo utilizamos la radiación electromagnética para observar y estudiar nuestro entorno.

Figura 6

Espectro electromagnético



Nota. Tomado de Ordoñez Luque, 2012.

2.1.4 *Bandas espectrales*

Es relevante mencionar cinco bandas espectrales, ya que son las más utilizadas en la tecnología actual.

- El Espectro Visible (VIS: 0,4 a 0,7 μ m) se llama así porque es el único rango de radiación electromagnética perceptible por el ojo humano. Este espectro se divide en tres bandas fundamentales: rojo (0,7 a 0,6 μ m), verde (0,6 a 0,5 μ m) y azul (0,5 a 0,4 μ m). Además, es interesante notar que el espectro visible coincide con la radiación máxima emitida por el Sol, lo que lo convierte en crucial para nuestras observaciones y percepciones visuales.
- El Infrarrojo Cercano (NIR: 0.7 a 1.3 μ m) es de gran relevancia para distinguir masas vegetales, ya que coincide con su punto máximo de reflexión. Esto lo convierte en una herramienta esencial para analizar y comprender la salud y la composición de la vegetación en diversos entornos.
- Infrarrojo Medio (SWIR: 1.3 a 8 μ m), se mezclan los procesos de reflexión solar en objetos y la emisión de energía electromagnética desde la superficie terrestre. En el rango de 1.3 μ m a 2.5 μ m, resulta útil para evaluar la humedad en los suelos. Por otro lado, de 2.5 μ m a 8 μ m, este espectro es crucial para identificar incendios forestales y procesos de alta temperatura en la superficie terrestre, como erupciones volcánicas.
- Infrarrojo Lejano o Térmico (TIR: 8 a 14 μ m), se puede captar claramente el calor emitido por la mayoría de las superficies terrestres.
- Las Microondas (a partir de 1 mm) son especialmente intrigantes porque esta forma de energía es altamente transparente en la atmósfera terrestre. Este espectro se utiliza en tecnologías como el radar, donde el sensor emite y recibe la radiación, y, según cómo sea reflejada, permite discriminar entre diversos objetos con precisión.

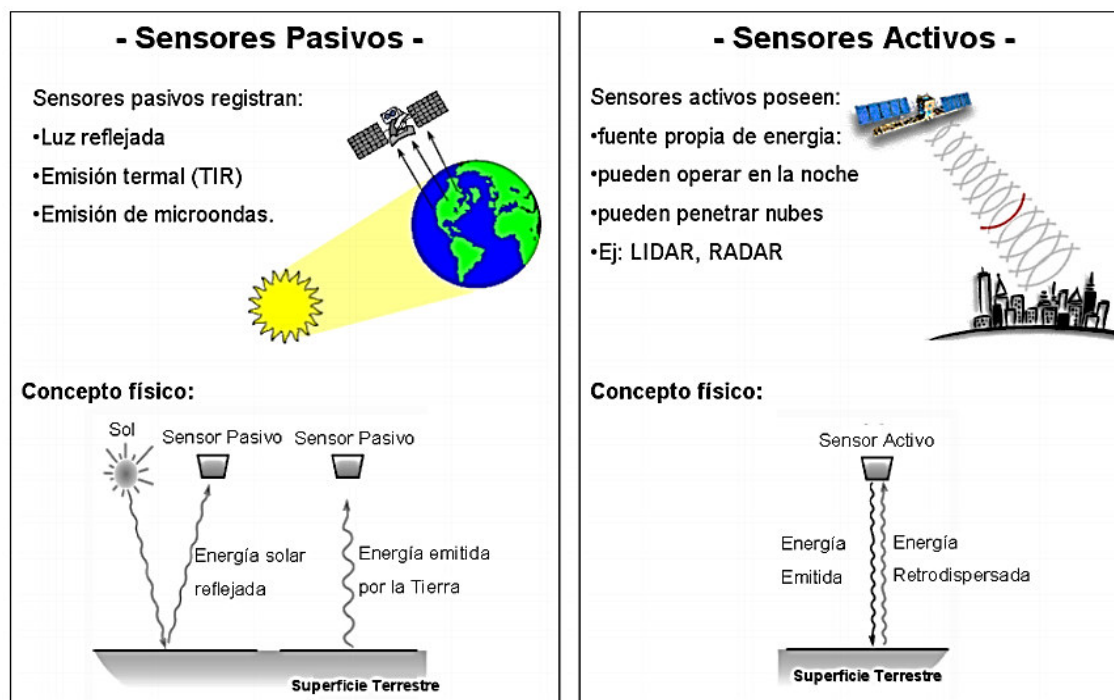
2.2 Tipos de sensores

La teledetección se realiza mediante sensores, dispositivos diseñados para captar señales electromagnéticas (ya sea radiación reflejada o emitida) provenientes de la tierra y la atmósfera. Estos sensores transforman estas señales en datos físicos que pueden ser procesados y almacenados para su análisis posterior.

Según Kramer (2016, p. 70), hoy en día se reconocen dos categorías de sensores: los activos y los pasivos. La diferencia entre ellos radica en cómo capturan la radiación de la superficie terrestre, como se ilustra en la Figura 7.

Figura 7

Ilustración del funcionamiento de un sensor



Nota. Tomado de CONAE, 2016.

2.2.1 Sensores pasivos

Los sensores pasivos son dispositivos que capturan la energía electromagnética procedente de la superficie terrestre, la cual puede originarse tanto en la reflexión de la luz solar como en las emisiones provenientes de fuentes con altas temperaturas. Ejemplos de estos sensores incluyen sistemas fotográficos, radiómetros multi e hiperespectrales, y espectrómetros de imagen. La principal ventaja de los sensores pasivos radica en su sensibilidad espectral, lo que les permite recopilar información de diversas bandas espectrales de forma simultánea y descomponer el espectro en datos discretos. Al observar diferentes regiones del espectro electromagnético, estos sensores proporcionan detalles precisos sobre el estado del medio ambiente, ofreciendo así una visión integral de la superficie terrestre.

2.2.2 Sensores activos

Estos sensores poseen la capacidad de generar y enviar su propia energía hacia la superficie terrestre. Después de reflejarse en la superficie, esta energía es captada nuevamente por el satélite. Un ejemplo notable de estos sensores es el radar, también conocido como radiómetro activo de microondas, que tiene la habilidad de operar eficientemente en diversas condiciones atmosféricas.

2.2.3 Cualidades de los sensores


La resolución de un sensor se refiere a su habilidad para discernir y capturar información detallada de la superficie terrestre. Esta capacidad está directamente ligada al estado tecnológico del momento y actualmente contamos con satélites que ofrecen una resolución notablemente alta. Estos avanzados sensores nos permiten obtener datos precisos y detallados sobre la tierra desde el espacio. La resolución de un sensor implica considerar la calidad de la información aportada en distintos aspectos, por lo que en la práctica se habla de cuatro tipos de resolución:

- Resolución espacial (tamaño de pixel).
- Resolución espectral (capacidad de discriminar entre longitudes de onda vecinas en el espectro, así como el número de bandas disponible).
- Resolución radiométrica (número de intervalos de intensidad que puede captar el sensor dicho de otra manera número de niveles de gris distintos que registra el sensor).
- Resolución temporal (tiempo que tarda el satélite en tomar dos imágenes del mismo sitio).

2.3 Satélites de observación

Existen dos tipos principales de satélites: los geosíncronos o geoestacionarios y los heliosíncronos. Los geosíncronos están posicionados a unos 36,000 km sobre el Ecuador y permanecen fijos sobre un punto específico en la Tierra, siguiendo su rotación. Por otro lado, los satélites heliosíncronos se desplazan en órbitas circulares y polares, alineadas con el eje de rotación de la Tierra. Aprovechan el movimiento de rotación terrestre para capturar imágenes de diferentes áreas cada vez que pasan por el mismo punto de su órbita.

Estas órbitas son viables a altitudes de entre 300 y 1500 km. La disposición de la órbita está diseñada de tal manera que el satélite siempre pasa sobre el mismo punto a la misma hora local, lo que se ilustra en la Figura 8.

Figura 8*Órbitas de los satélites*

Nota. Izquierda Esquema de una Órbita Geosíncrona, Derecha Esquema de una Órbita Polar. Tomado de Chuvieco, 2002.

A continuación, se presenta una lista de satélites junto con sus aplicaciones en la observación de la Tierra (consulte la Tabla 2 para obtener más detalles).

Tabla 2*Satélites de observación de la tierra*

Satélite	Agencia	Órbita	Uso
LandSat	NASA	LEO	Información geográfica
Sentinel	ESA	LEO	Información geográfica
Meteosat	ESA	GEO	Meteorología
GOES	United States National Weather Service	GEO	Meteorología
SPOT	CNES	LEO	Diversos usos
SAOCOM 1-A	CONAE	LEO	Observación Terrestre

Nota. Tomado de NASA, 2012.

2.3.1 *Satélite landsat*

El programa Landsat ha transformado la forma en que observamos y estudiamos la Tierra. Esta serie de datos, que comenzó en 1972, es la más larga de la historia y sigue registrando los cambios en la superficie terrestre desde el espacio. Landsat es único en su clase, ya que está diseñado y operado específicamente para observar repetidamente la cobertura terrestre con una resolución media; por lo general, cada píxel de imagen puede abarcar el tamaño de un campo de béisbol. Inicialmente, el programa comenzó con Landsat 4, Landsat 5 y Landsat 7, estableciendo un sistema de coordenadas de referencia para todos los datos del Landsat Data Continuity Mission (LDCM). Esta continuidad permite el registro y análisis de los cambios en la Tierra durante décadas (Ariza, 2013).

Landsat 8 fue lanzado con éxito en febrero de 2013. Este satélite proporciona una visión más nítida, con una mayor resolución espacial que ciertos sensores e instrumentos oceánicos, y también muestra una mayor sensibilidad al brillo y al color en comparación con algunos satélites más antiguos (Dev Acharya & Yang, 2015).

2.3.2 *Características del landsat 5*

Lanzado desde la Base de la Fuerza Aérea Vandenberg en California el 1 de marzo de 1984 y retirado del servicio el 5 de junio de 2013, Landsat 5, desarrollado por la NASA, estaba equipado con dos sensores: el Multiespectral Scanner (MSS) y el Thematic Mapper (TM). El sensor Thematic Mapper (TM) era una tecnología de escaneo multiespectral avanzada diseñada para ofrecer una mayor resolución espacial, una mejor capacidad de identificación espectral de objetos en la superficie terrestre, y una precisión geométrica y radiométrica superiores en comparación con el sensor MSS. Operaba con siete bandas espectrales, incluyendo una banda térmica, y tenía un intervalo de muestreo terrestre (tamaño de píxel) de 30 metros en el espectro reflectante y 120 metros en el térmico.

Bandas espectrales:

Banda 1 Azul visible (0,45 - 0,52 μm) 30 m

Banda 2 Verde visible (0,52 - 0,60 μm) 30 m

Banda 3 Rojo visible (0,63 - 0,69 μm) 30 m

Banda 4 Infrarrojo cercano (0,76 - 0,90 μm) 30 m

Banda 5 Infrarrojo cercano (1,55 - 1,75 μm) 30 m

Banda 6 Térmica (10,40 - 12,50 μm) 120 m

Banda 7 Infrarrojo medio (2,08 - 2,35 μm) 30 m

2.3.3 Características del landsat 8 - OLI y TIRS

El 11 de febrero de 2013, Landsat 8 fue lanzado desde la Base de la Fuerza Aérea de Vandenberg en California, equipado con dos instrumentos esenciales: el Operational Land Imager (OLI) y el Thermal Infrared Sensor (TIRS). El OLI tiene la capacidad de capturar datos en las porciones visible, infrarrojo cercano e infrarrojo de onda corta (VNIR, NIR y SWIR) del espectro electromagnético. Por otro lado, el TIRS mide la temperatura de la superficie terrestre en dos bandas térmicas, utilizando tecnología basada en principios de física cuántica para detectar el calor.

Las imágenes tomadas por Landsat 8 presentan resoluciones espaciales de 15 metros en el espectro pancromático y 30 metros en el espectro multiespectral. El OLI captura datos con precisión radiométrica mejorada en un rango dinámico de 12 bits, lo que mejora significativamente la relación señal/ruido general. Este mejor rendimiento de señal a ruido permite una caracterización más precisa del estado y la condición de la cubierta terrestre, lo que resulta fundamental para el monitoreo y análisis detallado de los cambios en el medio ambiente.

Bandas espectrales:

Nueve bandas espectrales, incluida una banda panorámica.

Aerosol Costero Banda 1 (0.43 - 0.45 μm) 30 m

Banda 2 Azul (0,450 - 0,51 μm) 30 m

Banda 3 Verde (0,53 - 0,59 μm) 30 m

Banda 4 Roja (0,64 - 0,67 μm) 30 m

Banda 5 Infrarrojo cercano (0,85 - 0,88 μm) 30 m

Banda 6 SWIR 1(1,57 - 1,65 μm) 30 m

Banda 7 SWIR 2 (2,11 - 2,29 μm) 30 m

Banda 8 Pancromática (PAN) (0,50 - 0,68 μm) 15 m

Banda 9 Cirro (1,36 - 1,38 μm) 30 m

2.4 Plataformas de descarga

Actualmente, hay una amplia gama de plataformas disponibles para obtener imágenes satelitales, muchas de las cuales son de acceso gratuito. Sin embargo, al buscar estas imágenes, es fundamental considerar ciertos parámetros, como el tipo de sensor y la resolución espectral necesaria. Dependiendo de estas especificaciones, algunas plataformas son más precisas que otras en la entrega de datos satelitales.

Por lo general, las más utilizadas son:


- USGS – Servicio Geológico de Estados Unidos.
- INPE - Instituto Nacional de Pesquisas Espaciais.
- GCLF – Global Land Cover Facility.

La selección del material satelital es crucial y depende de varios factores, como el tipo de sensor que se pretende actualizar, el procesamiento que se aplicará a las imágenes, la fecha de adquisición del

conjunto de datos y el porcentaje de cobertura de nubes (Rodríguez & Arredondo, 2005). Para cada investigación, se determinará el satélite a utilizar en función del período de estudio establecido, asegurándose de que los datos recopilados coincidan con la fecha de interés. Se ilustra un ejemplo de imagen satelital en la Figura 9.

Figura 9

Escena landsat para path 8 / row 66



Nota. Una vez que se tiene identificado los Path/Row de las imágenes se podrá descargar las bandas en formato GeoTIF junto a los metadatos. Tomado de la NASA, 2017.

2.5 Fundamentos físicos

2.5.1 *Magnitudes radiométricas básicas*

Este texto explora los conceptos esenciales que permiten comprender cómo se puede utilizar la radiación electromagnética en teledetección para adquirir información sobre los sistemas bajo estudio. Se comienzan explicando los fundamentos relacionados con el transporte de ondas electromagnéticas y la energía radiante, junto con las propiedades radiativas de la materia. Luego, se abordan las leyes básicas que

rigen el campo de radiación dentro de una cavidad en equilibrio termodinámico, lo que se conoce como radiación de cuerpo negro. Finalmente, se examina la ecuación de transferencia radiativa, que involucra los procesos físicos que intervienen en la transmisión de la señal a través de la atmósfera (Chuvieco, 2002).

La observación remota de un sistema requiere que el sensor detecte el flujo de energía emitido por ese sistema. Por lo tanto, es esencial comprender las magnitudes físicas comúnmente utilizadas para describir el campo radiativo.

2.5.2 *Descripción del campo radiativo*

En el contexto del campo radiativo, se hace referencia al campo electromagnético que viaja a través de las ondas desde la fuente emisora hasta el detector. La energía contenida en estas ondas se conoce como energía radiante (Q). Sin embargo, para ofrecer una descripción exhaustiva de esta energía radiante, se utilizan diversas magnitudes radiométricas adicionales. Cada una de estas magnitudes está detallada en la Tabla 3 (Chuvieco, 1995b).

Tabla 3*Magnitudes radiométricas*

MAGNITUD	SÍMBOLO	DEFINICIÓN	UNIDAD (S.I.)
Energía radiante	Q	-	J
Flujo radiante	ϕ	dQ/dt	W
Emitancia radiante	M	d ϕ /dS	W m ⁻²
Irradiancia	E	d ϕ /dS	W m ⁻²
Intensidad radiante	I	d ϕ /d Ω	W sr ⁻¹
Radiancia	L	d ² ϕ /(d Ω dScos θ)	W m ⁻² sr ⁻¹
Radiancia espectral	L $_{\lambda}$	dL/d $_{\lambda}$	W m ⁻² sr ⁻¹ μ m ⁻¹

Nota. Se muestra todas las magnitudes comúnmente utilizadas en teledetección indicando cuáles son sus unidades de medida en el sistema internacional. Tomado de Sobrino, 2000.

- Energía radiante (Q), indica el total de energía radiada en todas las direcciones. Se mide en (J).
- Densidad radiante (W), total de energía radiada en todas las direcciones por unidad de volumen. Se mide en julios por metro cúbico (J/m³).
- Flujo radiante (Φ) = dQ/dt, representa la energía radiante emitida, transportada o recibida por unida de tiempo.
- Emitancia o excitancia (M). Total, de energía radiada en todas las direcciones desde una unidad de área y por unidad de tiempo. Se mide en vatios por metro cuadrado (W/m²).
- La irradiancia radiante (E) se define como la cantidad total de energía radiada por unidad de área y por unidad de tiempo. Es importante destacar que, aunque se asemeja a la emitancia

en términos de energía emitida, la irradiancia se refiere específicamente a la energía incidente, mientras que la emitancia hace referencia a la energía emitida (medida en W/m^2).

- La intensidad radiante (I) se define como la tasa de cambio del flujo radiante ($d\Phi$) con respecto al ángulo sólido ($d\Omega$). Representa el flujo radiante transportado por unidad de ángulo sólido. Este ángulo tridimensional se refiere a la sección completa de la energía transmitida y se mide en estereorradianes (W/sr).
- La radiancia (L) se define como el flujo radiante proveniente de una superficie elemental dS , expresado por unidad de ángulo sólido $d\Omega$ y por unidad de superficie $d\Sigma = dS \cos\theta$, colocada normalmente en la dirección de propagación θ . Representa el total de energía radiada por unidad de área y por ángulo sólido de medida. Este concepto es esencial en teledetección, ya que describe precisamente lo que un sensor detecta. La radiancia se cuantifica en vatios por metro cuadrado y estereorradianes ($\text{W}/\text{m}^2 \text{ sr}$).
- La radiancia espectral (L_λ) representa la cantidad total de energía radiada en una longitud de onda específica por unidad de área y ángulo sólido de medida. Dado que un sensor detecta una banda particular del espectro, la radiancia espectral es la medida más cercana a la observación remota. Además de la radiancia, tanto la emitancia como la irradiancia pueden describirse con el término "espectral" (añadiendo el subíndice λ) para referirse a una longitud de onda específica del espectro electromagnético.
- La emisividad (ξ) es la relación entre la emitancia de una superficie (M) y la emitancia que tendría un emisor ideal conocido como cuerpo negro, cuando ambos se encuentran a la misma temperatura (M_n).
- La reflectividad (ρ) se define como la relación entre el flujo de radiación incidente y el flujo reflejado por una superficie.

- La absorptividad (α) representa la relación entre el flujo de radiación incidente y el flujo que una superficie absorbe.
- La transmisividad (τ) se define como la relación entre el flujo de radiación incidente y el flujo transmitido por una superficie.

2.5.3 Características radiativas de la materia

En el contexto de las características radiativas de la materia, se analiza la interacción de la radiación electromagnética con los materiales para caracterizar el sistema en estudio. Cuando la radiación electromagnética alcanza la superficie de un material, se produce una división en tres componentes distintas. Una parte de esta radiación es reflejada, generando un flujo reflejado (Φ_r), mientras que otra parte es absorbida por el objeto, dando lugar a un flujo absorbido (Φ_a). Además, una fracción del flujo incidente se transmite, a menudo en otras formas de energía (Sobrino, 2000). Esta interacción compleja se describe en la ecuación 2.1, que ilustra cómo la radiación que llega a la superficie se divide en estas tres componentes.

$$\Phi_i = \Phi_r + \Phi_a + \Phi_t \dots\dots\dots (2.1)$$

No obstante, es común presentar la ecuación anterior en términos relativos. Para hacerlo, se divide por el flujo incidente, dando lugar a la siguiente relación:

$$1 = \Phi_r/\Phi_i + \Phi_a/\Phi_i + \Phi_t/\Phi_i = \rho + \alpha + \tau \dots\dots\dots (2.2)$$

Donde: ρ representa la reflectividad, α la absorptividad, y τ la transmisividad. El enfoque en la interacción de la radiación solar con las superficies naturales se centra en el análisis de los datos capturados por un sensor desde el exterior de estas superficies. Por lo tanto, nos enfocaremos en la radiación reflejada. En resumen, la suma de reflectividad, absorptividad y transmisividad debe ser igual a uno. La relación entre


estas tres magnitudes no es constante a lo largo de la longitud de onda, por lo tanto, en términos más precisos, debería expresarse de acuerdo con la ecuación 2.3 (Chuvieco, 1995c).

$$1 = \rho_{\lambda} + \alpha_{\lambda} + \tau_{\lambda} \dots \dots \dots (2.3)$$

La cantidad de radiación que es reflejada, absorbida y transmitida del flujo incidente varía según las propiedades de la superficie observada. El esquema de cómo se transforma el flujo incidente al interactuar con la superficie se ilustra en la Figura 10.

Figura 10

Relación entre el flujo incidente y reflejado



Nota. Tomado de Chuvieco, 1995.

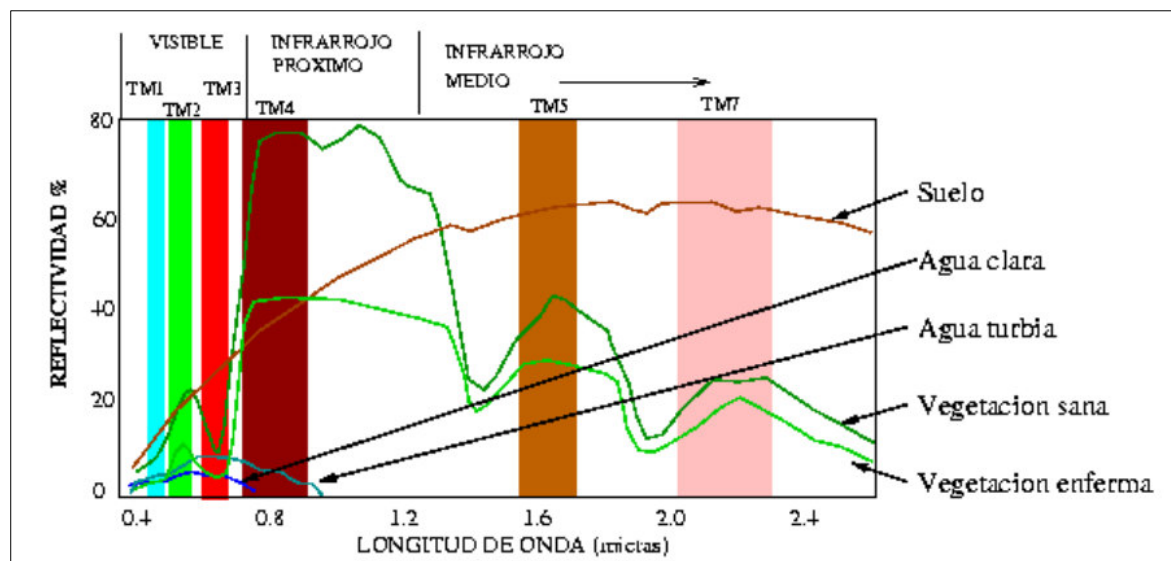
2.5.4 Generalidades sobre la reflectancia de las superficies

Las propiedades reflectivas de las superficies terrestres pueden medirse cuantificando la cantidad de energía incidente que se refleja, como se indica en la ecuación 2.4. Esta proporción se conoce como reflectividad espectral (ρ_{λ}) y varía en función de la longitud de onda (Alonso et al., 1999).

$$\rho_{\lambda} = ER(\lambda)/RI(\lambda) \dots\dots\dots (2.4)$$

La curva de reflectividad espectral representa gráficamente la relación entre la reflectividad espectral y la longitud de onda. Estas curvas son cruciales para comprender las propiedades espectrales de un objeto y tienen un impacto significativo en la selección de la región espectral adecuada para adquirir datos de teledetección en una aplicación específica.

En la Figura 11, se puede observar que, para cada longitud de onda, existe un valor de reflectividad expresado en porcentaje, conocido como *signatura espectral*. Esta *signatura espectral* actúa como una firma única de los objetos, lo que permite diferenciar entre superficies de suelo y vegetación, e incluso entre diferentes tipos de suelos o vegetación.

Figura 11*Respuestas espectrales*

Nota. Esta gráfica representa el comportamiento espectral del sensor TM (Thematic Mapper) de Landsat, lo que permite prever los valores promedio de reflectividad que el sensor capturaré para diversas superficies. Tomado Short, 1997.

2.6 Firmas espectrales de la vegetación

Nos enfocaremos en la firma espectral de la vegetación verde, la cual se distingue por mostrar una marcada diferencia entre las áreas del espectro que corresponden al color rojo visible y al infrarrojo cercano.

En la región visible del espectro, los pigmentos en las hojas absorben la mayoría de la luz, pero en el infrarrojo cercano, estas sustancias son bastante transparentes. Como resultado, la vegetación sana tiene una reflectividad baja en la banda roja del espectro (entre 600 y 700 nm) y alta en el infrarrojo cercano (entre 800 y 1000 nm). Cuanto más vigorosa esté la vegetación, mayor será la diferencia entre los valores de reflectancia en estas dos bandas. Valores bajos de reflectancia en el infrarrojo cercano pueden indicar vegetación enferma o con falta significativa de humedad (Lobo, 1995).


En la región del espectro visible, se pueden identificar las siguientes franjas:

- 400 – 500 nm: En esta franja, la clorofila, el caroteno y la xantofila absorben fuertemente la luz.
- 500 – 600 nm: En esta zona, la absorción es menor, lo que resulta en una mayor reflectancia en comparación con las regiones azules y rojas cercanas. Esta reflectancia es la responsable del color verde que percibimos en las plantas.
- 600 – 700 nm: La clorofila absorbe fuertemente en esta franja, especialmente en la parte inferior de las hojas (ver Figura 3), y aún menos en la vegetación seca.
- 700 – 800 nm: Esta franja marca la transición entre la zona de absorción de la clorofila y los altos niveles de reflectancia que comienzan alrededor de los 750 nm.

En la región del infrarrojo cercano (entre 800 y 1100 nm), la estructura interna de la hoja, especialmente el mesófilo esponjoso, es responsable de la alta reflectancia (consultar Figura 12).

Figura 12

Comportamiento espectral de la vegetación



Nota. Tomado de Chuvieco, 1996.

2.7 Pre procesamiento de imágenes de satélite

Para analizar la información obtenida de un sensor remoto, es esencial someter los datos a un proceso de tratamiento previo, comúnmente denominado "preprocesamiento de imágenes" en la literatura (Jensen,

1996). Este procedimiento tiene como objetivo corregir los errores inherentes al proceso de adquisición de datos, los cuales podrían degradar la calidad de la información recopilada por el sensor (Chuvienco, 1996).

2.7.1 Imagen satelital

Las imágenes satelitales están compuestas por matrices en las que cada celda representa un píxel. Las dimensiones de estos píxeles varían según la resolución espacial del sensor utilizado. Estos sensores capturan la radiación electromagnética proveniente de diversas coberturas y la almacenan en cada píxel, según los intervalos de longitudes de onda programados en el sensor para la captura (Bravo, 2017).


Cada píxel en una imagen satelital representa energía electromagnética mediante un valor digital al que se le asigna una tonalidad, conocido como Número Digital (ND). La gama de números digitales que se puede representar depende de la Resolución Radiométrica del sensor; por ejemplo, un sensor con Resolución Radiométrica de 8 bits tiene números digitales que varían de 0 a 255. En una escala de grises, el valor 0 corresponde al color negro y el 255 al color blanco.

La posición de cada píxel en la imagen satelital se determina a través de un sistema de coordenadas XYZ, como se ilustra en la Figura 13.

X: N.º de columna de la matriz.

Y: N.º de fila de la matriz.

Z: Numero digital (valor de intensidad de la escala de grises).

Figura 13*Componentes de una imagen satelital digital*

Nota. Tomado de Bravo, 2017.

2.7.2 Corrección geométrica

La corrección geométrica es un paso fundamental en el procesamiento de datos de satélite, ya que garantiza la precisión espacial y la alineación adecuada de los objetos en las imágenes. Su objetivo principal es corregir las distorsiones espaciales que se producen durante la adquisición de imágenes, de modo que estas representen con precisión la ubicación y forma real de los objetos en la superficie terrestre.

La corrección geométrica no implica cambios en los Números Digitales (ND) de los píxeles de la imagen; en cambio, se centra en ajustar su posición y coordenadas. Hay dos enfoques posibles para llevar a cabo esta corrección. El primero se denomina corrección orbital, que requiere un conocimiento detallado de las características de los sensores y la aplicación de un proceso inverso para ajustar la posición de los píxeles.

El segundo método es más empírico y consiste en evaluar el error geométrico de la imagen mediante una serie de puntos con coordenadas conocidas, llamados puntos de control (Chuvieco, 2002). Estos puntos

de control se utilizan para realizar ajustes precisos en la posición de los píxeles y corregir cualquier distorsión geométrica en la imagen.

2.7.3 Corrección radiométrica

La corrección radiométrica es un proceso esencial en el análisis de datos obtenidos mediante satélites. Su objetivo principal es eliminar o reducir los efectos causados por la atmósfera y otros factores externos que pueden afectar las mediciones de la energía electromagnética reflejada o emitida por la superficie terrestre. Estos efectos atmosféricos pueden distorsionar los datos recopilados y dificultar la interpretación precisa de la información.

2.7.4 Radiancia

La radiancia es la cantidad de energía electromagnética emitida desde un área en particular, las imágenes Landsat descargadas de los servidores tienen valores digitales de ocho bits, que generan valores de 0 a 255 en tonalidades de grises, por lo cual es necesario transformar estos valores conocidos como nivel digital (ND) a variables físicas de Radiancia, que nos representa el comportamiento espectral de los objetos en las 7 bandas espectrales de la imagen Landsat. Para el cálculo de la radiancia se usa la ecuación 2.5:

$$L_{\lambda} = G_{rescale} * Q_{cal} + B_{rescale} \dots\dots\dots (2.5)$$

Donde:

λ = número de banda spectral (1,2,3,4,5 y 7)

L_{λ} = radiancia espectral en la abertura del sensor [$W/(m^2 sr \mu m)$]

Q_{cal} = valores digitales de la imagen de 0 a 255 [ND]

$G_{rescale}$ = factor ganancia [$W/(m^2 sr \mu m)$]

$B_{rescale}$ = factor bias [$W/(m^2 sr \mu m)$]

2.7.5 Reflectancia (TOA)

Una vez obtenidas las Radiancias espectrales por el sensor se puede calcular la reflectividad aparente conocida como (TOA) debido a que no tiene en cuenta la dispersión ocasionada por la atmosfera y se define como el cociente entre la energía reflejada y la energía incidente.

Según Chander y Markham (2009), al comparar imágenes de diferentes fechas, es beneficioso convertir los valores de radiancia a reflectancia, ya que esto elimina el efecto causado por el ángulo solar y compensa las variaciones en los valores de irradiancia solar extraterrestre. La reflectancia total de la superficie y la atmósfera se calcula utilizando la ecuación 2.6.

$$\rho_{\lambda} = \frac{\pi L_{\lambda} d^2}{ESUN_{\lambda} \cdot \cos(\theta_s)} \dots\dots\dots (2.6)$$

Donde:

$$d = [1 + 0.33 \cdot \cos(\frac{2\pi D_j}{365})]^{-1} \dots\dots\dots (2.7)$$

λ = número de banda spectral (1,2,3,4,5 y 7)

L_{λ} = radiancia espectral en la abertura del sensor [$W/(m^2 sr \mu m)$]

ρ_{λ} = Reflectancia al tope de la atmósfera [adimensional]

d = Distancia tierra sol, [Duffie y Beckman 1980, Unidades astronómicas, UA]

$ESUN_{\lambda}$ = Irradiancia Solar promedio exoatmosferica [$W/(m^2 \mu m)$]

(θ_s) = Angulo Zenith Solar [radianes]

π = Constante matemática ~ 3.14159

D_j = Día Juliano [de 1 a 365]

2.7.6 Corrección atmosférica

La corrección atmosférica es un procedimiento que tiene como objetivo eliminar el efecto de dispersión de la energía electromagnética causada por partículas de agua suspendidas en la atmósfera. Esto se logra restando de la imagen los valores que estas partículas añaden a los datos de la imagen. El procedimiento utilizado para esto se conoce como DOS (Dark Object Subtraction), que es un método de sustracción de píxeles oscuros también conocido como método de Chávez.

Se ha optado por el método del objeto oscuro, desarrollado por (Chávez, 1988), por ser un método sencillo que presenta los mejores resultados considerando la estabilidad temporal de las zonas pseudo invariantes.

El método de corrección propuesto por Chávez se basa en el valor mínimo de radiancia, también conocido como el método de ajuste del histograma al origen. Este algoritmo sugiere estimar la influencia de la atmósfera directamente desde la imagen al determinar la radiancia medida por el sensor en áreas oscuras. Aunque teóricamente estas áreas deberían tener un valor de radiancia cero, debido a la dispersión atmosférica, este valor no es cero. Con esta suposición, según Chávez, solo se puede eliminar una dispersión simple, y se calcula utilizando la ecuación 2.8.

Por tanto, si asumimos que la radiación solar difusa es nula y la transmisividad atmosférica entre la superficie y el sensor es uno, podemos calcular la reflectividad de la superficie utilizando las siguientes fórmulas:

$$\rho_{\lambda}^{sup} = \frac{d^2\pi(L_{\lambda}^{sen} - L_{\lambda}^{camino})}{\tau_{\lambda} \cdot E_{0,\lambda} \cos(\theta_z)} \dots\dots\dots (2.8)$$

La radiancia de camino se calcula a partir de la siguiente expresión:

$$L_{camino} = L_{min,\lambda} - L_{1\%,\lambda} \dots\dots\dots (2.9)$$

En el caso de Landsat, los valores τ_λ son 0.70, 0.78, 0.85 y 0.91 para las bandas 1, 2, 3 y 4, mientras que para las bandas 5 y 7 se considera un valor de 1 y se aplica a **la ecuación 2.10**.

$$L_{1\%,\lambda} = \frac{0.01\tau_\lambda E_{0,\lambda} \cos(\theta_z)}{d^2\pi} \dots\dots\dots (2.10)$$

2.8 Monitoreo del cambio de cobertura

La Tierra está experimentando cambios a un ritmo alarmante que necesitan ser documentados mediante imágenes integrales y repetibles. Las herramientas de observación terrestre desempeñan un papel fundamental en la generación de evaluaciones precisas de las transformaciones del paisaje. Se requieren mediciones coherentes, confiables y precisas de la dinámica de la cubierta terrestre para mejorar nuestra comprensión de cómo funcionan los diversos elementos del sistema (Miranda, 2013). Para aprovechar al máximo la riqueza numérica de los datos capturados en las imágenes satelitales, se han desarrollado distintos métodos para analizar y clasificar de manera estadística los píxeles individuales y, mediante series temporales, caracterizar su comportamiento espectral (Macedo Cruz, A. et al., 2010).

2.9 Detección y mapeo del cambio de cobertura

La detección de cambios nos permite identificar las modificaciones o variaciones entre imágenes y realizar análisis multitemporales. Existen diversas técnicas de Detección de Cambios aplicadas en imágenes, y durante las últimas tres décadas se han desarrollado una amplia variedad de enfoques para la detección espacial del cambio. Estos métodos pueden clasificarse según varios criterios, como se ha señalado en la literatura (Newton, 2007). Una forma interesante de categorizar las metodologías de cambio ha sido propuesta por Van Oort (2007), quien divide los métodos de cambio en dos tipos:

- Categoría 1; Aquellos que primero detectan el cambio y posteriormente asignan clases (diferencia de imágenes o análisis de componentes principales).
- Categoría 2; Aquellos que primero asignan clases y posteriormente detectan el cambio (comparación post clasificación).

En los métodos de la categoría 1, puede ser adecuado simplemente diferenciar las áreas que han cambiado de las que no han cambiado. Sin embargo, en la mayoría de los casos, existe un interés específico en comprender la naturaleza exacta del cambio y, por lo tanto, en asignar clases específicas a dichos cambios. Estos métodos tienen la ventaja de ser altamente sensibles incluso a cambios numéricos mínimos (Gao, 2009).

Los métodos de la categoría 2 han ganado una alta popularidad, posiblemente debido a su aplicabilidad en mapas temáticos disponibles en cartografía oficial o creados por investigadores mediante técnicas de interpretación de imágenes (Eggleston et al., 2006, p. 31).

2.10 Técnicas de análisis multitemporal

La teledetección espacial ha hecho una destacada contribución al estudio del medio ambiente al permitir el seguimiento de procesos dinámicos. La información recopilada por sensores en órbita estable y repetitiva se convierte en una fuente valiosa para investigar los cambios en la superficie terrestre, ya sean resultado del ciclo estacional de las cubiertas, catástrofes naturales o alteraciones de origen humano. El análisis multitemporal tiene como objetivo detectar las diferencias entre dos o más fechas, generalmente a través de la comparación visual o digital de imágenes adquiridas en distintos años (Condoy & Silva, 2006).

2.11 Técnicas de clasificación

En teledetección, el conjunto de variables incluye la reflectividad en cada una de las bandas espectrales. Sin embargo, además de esta información espectral, se pueden utilizar datos texturales y contextuales. La información textural se refiere a las características en las proximidades de un píxel. Se definen varias variables que intentan cuantificar algunas de las propiedades cualitativas examinadas en la fotointerpretación. Por otro lado, el contexto se refiere a la coherencia necesaria en la clasificación de los píxeles (Benediktsson & Arnason, 1995). La asignación de clases puede basarse principalmente en dos criterios:

2.11.1 Clasificación supervisada

En el proceso de clasificación supervisada, se comienza con un conjunto predeterminado de clases que ya se conocen de antemano. Estas clases se definen minuciosamente en función de un conjunto específico de variables, las cuales se miden en individuos cuya pertenencia a una de las clases no genera ninguna duda (estas áreas se llaman áreas de entrenamiento). En otras palabras, se selecciona cuidadosamente un grupo de variables relevantes y se evalúan en individuos claramente asignados a categorías conocidas, proporcionando así un marco sólido para la clasificación supervisada.

Las máquinas de aprendizaje con aprendizaje supervisado. Tiene como idea principal utilizar la información provista por un conjunto de datos (llamado conjunto de entrenamiento) para generar funciones de decisión capaces de clasificar automáticamente cada dato en las distintas categorías que contiene el problema. Los ejemplos que contiene el conjunto de entrenamiento tienen la particularidad de que han sido previamente etiquetados con la clase a la cual pertenecen, por lo que la máquina de aprendizaje puede evaluar cuántos ejemplos clasificó bien y cuántos clasificó mal y así corregir la función de clasificación

para generar una mejor. Este proceso de verificación y corrección en base a ejemplos etiquetados es el que denomina que la máquina sea de aprendizaje supervisado (Candel, 2011).

2.11.2 Clasificación no supervisada.

En contraste con la clasificación supervisada, en la clasificación no supervisada no se establecen clases previas de antemano. En este enfoque, no se presuponen categorías específicas para los datos. En su lugar, el proceso implica determinar el número de clases que se desean establecer y permitir que este número sea definido por un procedimiento estadístico. En esencia, se deja que los datos mismos revelen patrones y agrupaciones naturales, sin imponer ninguna estructura preconcebida. Esta metodología permite descubrir relaciones y tendencias intrínsecas en los datos, lo que puede llevar a una comprensión más profunda de los fenómenos estudiados.

2.12 El clasificador support vector machines (SVM)

Entre las técnicas de aprendizaje automático más populares aplicadas a la clasificación se encuentran las Máquinas de Soporte Vectorial (SVM por sus siglas en inglés, Support Vector Machines). Estas máquinas funcionan mediante el mapeo de las diversas características de los elementos que se desean clasificar a un espacio vectorial. En este espacio, las SVM trazan un hiperplano que separa los vectores de una clase del resto. La popularidad de las SVM radica en su funcionamiento relativamente simple, respaldado por una serie de propiedades teóricas y prácticas atractivas, como se señaló en el trabajo de Vapnik (1999). Además, estas técnicas pueden ser adaptadas fácilmente para abordar problemas en los que los datos no pueden ser separados linealmente o contienen un alto nivel de ruido.


La meta principal de las Máquinas de Soporte Vectorial (SVM) es encontrar un hiperplano que pueda separar distintas clases en las que puede agruparse una distribución de datos en un espacio N-dimensional. Este proceso se basa en una optimización que implica la identificación de vectores que

delinean los límites de las clases, comúnmente conocidos como vectores soporte. Al ver los datos de entrada como dos conjuntos de vectores en un espacio N-dimensional, el SVM busca construir un hiperplano de separación que maximice la distancia entre los dos conjuntos de datos (Hofmann, T. et al., 2008). En esencia, el objetivo es encontrar una superficie (o hiperplano) que no solo separe las clases de manera efectiva, sino que también maximice el margen de distancia entre ellas en este espacio multidimensional.

En la Figura 14, se ilustra la representación del hiperplano de separación mediante la construcción de dos hiperplanos paralelos adicionales. Estos hiperplanos se ensanchan o ajustan para aproximarse lo máximo posible a las distintas clases, identificadas por los puntos azules y rojos. Una separación efectiva se logra cuando el hiperplano de separación se encuentra a la máxima distancia posible entre ambas clases. En términos generales, cuanto mayor sea esta distancia, menor será el error del clasificador, lo que indica una mejor capacidad para distinguir entre las clases.

Figura 14

Esquema de funcionamiento del clasificador SVM

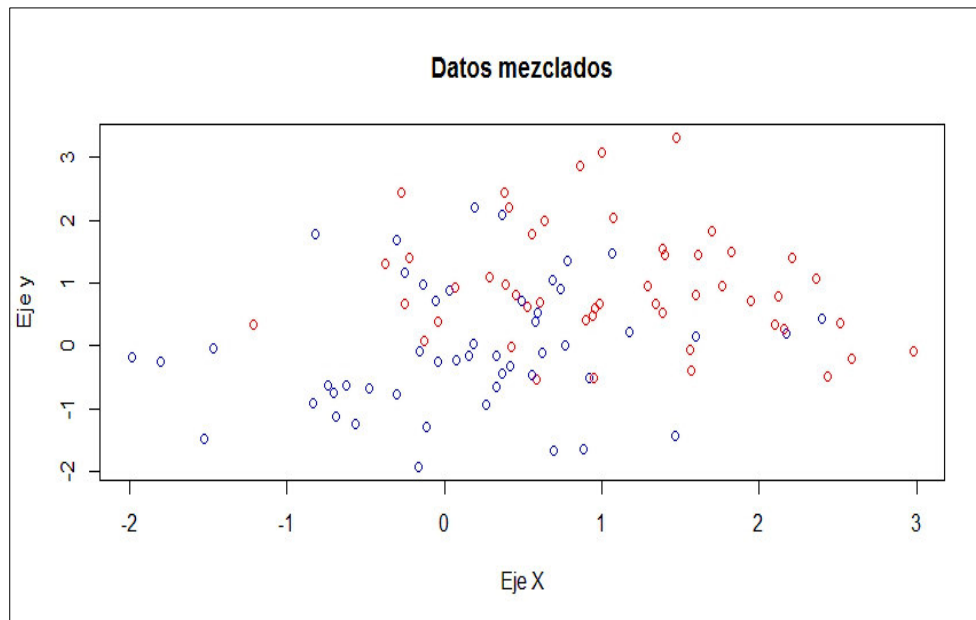


Nota. Tomado de Vapnik, 1999.

A modo de ejemplo se realizó una simulación del funcionamiento del clasificador SVM en R Studio ver código en el anexo A. En la Figura 15 se observa una muestra del método SVM en la distribución de dos clases mezcladas que son los puntos azules y los puntos rojos en el plano (X, Y).

Figura 16

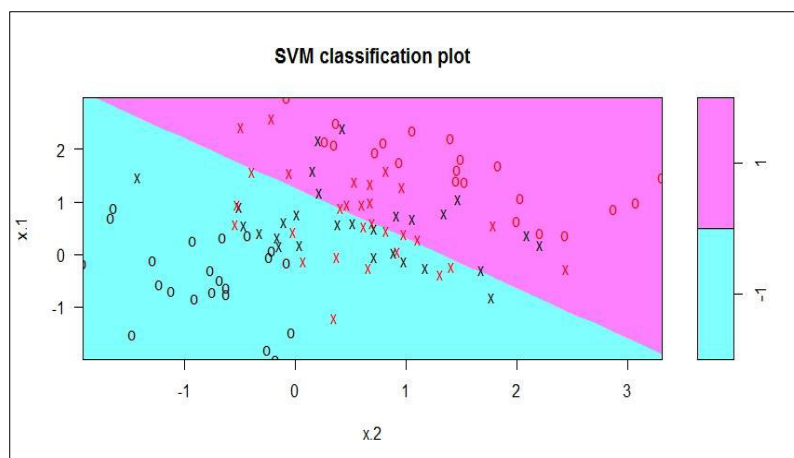
Grafica de puntos generados en el plano (x, y)



Nota. Dispersión de dos clases mezcladas. Elaboración propia.

Figura 15

Grafica de la estimación del método SVM con kernel lineal



Nota. Se muestra la zona de mejor separación de ambas clases. Elaboración propia.

Luego se estima el método SVM con el Kernel lineal a las dos clases como se observa en la Figura 16 que muestra el hiperplano de separación como una recta trazada donde hay mayor acumulación de aspas que indica que es la zona de mejor separación de ambas clases, este proceso es el que se ejecuta al realizar la clasificación de diferentes clases con vectores denominados (ROI's – región de interés).

2.13 Matriz de confusión

Una vez que el modelo SVM ha sido entrenado, se necesita evaluar su rendimiento para determinar qué tan bien está realizando las predicciones. Aquí es donde entra en juego la matriz de confusión que es una matriz cuadrada en la que se compara la clasificación de la imagen con la verdad de terreno (ver Figura 17). La exactitud de la clasificación se evalúa mediante la matriz de confusión, donde las clases o categorías de nuestro mapa se colocan en las filas y las mismas clases se ubican en las columnas para la verdad de terreno o campo (Boca, 2012). Esta matriz proporciona una visión detallada de los aciertos y errores del modelo, permitiendo una evaluación exhaustiva de su rendimiento en la clasificación.

Las características más destacadas de esta matriz son:

- Proporciona una visión completa de las asignaciones, mostrando tanto las clasificaciones correctas (elementos en la diagonal) como las desviaciones o errores (elementos fuera de la diagonal).
- Identifica tanto los errores de omisión como los de comisión, ofreciendo una comprensión detallada de las discrepancias entre las predicciones del modelo y la verdad de terreno o campo.

2.13.1 Errores de comisión

Los errores de comisión indican la fracción de valores que el modelo predijo que pertenecerían a una clase específica, pero que en realidad no pertenecen a esa clase. Estos errores son esencialmente falsos

positivos. En la matriz de confusión, los errores de comisión se reflejan en las filas, excluyendo los valores en la diagonal principal. La precisión del usuario, que representa la complementaria de estos errores, ofrece una medida importante de cuánto se puede confiar en las clasificaciones proporcionadas por el modelo.

2.13.2 Errores de omisión

Los errores de omisión denotan la fracción de valores que realmente pertenecen a una clase específica, pero el modelo predijo que estarían en una clase diferente. Estos errores se consideran falsos negativos. En la matriz de confusión, los errores de omisión se reflejan en las columnas, excluyendo los valores en la diagonal principal. La precisión del productor, que es el complemento de estos errores, proporciona una medida crucial de qué tan eficaz es el modelo al identificar correctamente los miembros de una clase específica.

2.13.3 Precisión del usuario

La precisión del usuario representa la probabilidad de que un valor predicho como perteneciente a una cierta clase sea realmente parte de esa clase. Esta probabilidad se calcula mediante la fracción de valores correctamente pronosticados en relación con el número total de valores predichos para esa clase en particular. En esencia, la precisión del usuario indica qué tan confiables son las predicciones del modelo cuando se trata de identificar correctamente una clase específica.

2.13.4 Precisión del productor

La precisión del productor representa la probabilidad de que un valor perteneciente a una clase específica haya sido clasificado correctamente. En otras palabras, esta medida indica qué tan acertadamente el modelo identifica los elementos de una clase determinada.

Figura 17

Esquema general de la matriz de confusión

		CLASES EN EL CAMPO				Total mapa	EXACTITUD USUARIO	ERROR COMISION
		A1	A2	...	AM			
CLASES MAPA	A1	a_{11}^*	a_{12}	...	a_{1m}	$a_{.1}$	$a_{.1} / a_{..}$	$1 - (a_{.1} / a_{..})$
	A2	a_{21}	a_{22}	...	a_{2m}	$a_{.2}$	$a_{.2} / a_{..}$	$1 - (a_{.2} / a_{..})$
				
	AM	a_{m1}		...	a_{mm}	$a_{.m}$	$a_{.m} / a_{..}$	$1 - (a_{.m} / a_{..})$
	Total campo	$a_{.1}$	$a_{.2}$...	$a_{.m}$	$a_{..}$		
	EXACTITUD PRODUCTOR	$a_{.1} / a_{..}$	$a_{.2} / a_{..}$...	$a_{.m} / a_{..}$			
	ERROR OMISIÓN	$1 - (a_{.1} / a_{..})$	$1 - (a_{.2} / a_{..})$...	$1 - (a_{.m} / a_{..})$			

Nota. Esta notación indica en los subíndices la posición dentro de la matriz. Tomado de Teresa Boca, 20012.

2.14 Índices globales

2.14.1 Exactitud global

La precisión del productor se calcula dividiendo el número de unidades clasificadas correctamente entre el número total de unidades consideradas. Este cálculo implica sumar los elementos en la diagonal de la matriz de confusión y dividir el resultado por el total de observaciones. Sin embargo, es importante tener en cuenta que este índice tiene la tendencia a exagerar la calidad de la clasificación. Los valores de la precisión del productor se encuentran en el rango de [0, 1] o [0, 100], siendo una clasificación óptima cuanto más se aproxime a 100 o a la unidad (Boca, 2012).

La exactitud global se calcula a partir de la siguiente expresión:

$$\text{Valor de Exactitud Global} = \frac{\text{Suma de los valores de la diagonal } (a_{m+,m+})}{\text{número de observaciones } (a_{..})} \dots\dots\dots (2.11)$$

2.14.2 Índice kappa

Para examinar las complejas relaciones entre las diversas categorías, se emplean técnicas de análisis categórico multivariante, especialmente adecuadas para evaluar globalmente las matrices de confusión. Un índice ampliamente utilizado en este contexto es el estadístico de Kappa (κ), que cuantifica la discrepancia entre la concordancia observada entre el mapa y la realidad y la concordancia que se podría esperar por pura casualidad. En esencia, el estadístico de Kappa intenta medir el grado en que la precisión de la clasificación es mejor que la que se podría lograr por azar, aislando el ajuste causado únicamente por la exactitud de la clasificación y desestimando las influencias aleatorias (Chuvieco, 2010).

El índice Kappa se utiliza para evaluar la concordancia entre métodos que producen resultados categóricos con dos o más clases. Este índice representa la proporción de acuerdos observados en relación con el máximo acuerdo posible que podría ocurrir por pura casualidad. Es importante considerar que la interpretación del índice Kappa depende del grado de concordancia observado. En este contexto, el índice Kappa (K) se define como:

$$K = \frac{\rho_0 - \rho_e}{1 - \rho_e} \dots\dots\dots (2.12)$$

Donde:

ρ_0 : Número de aciertos / Número total de clases

ρ_e : Calculo generado desde la matriz de confusión

Finalmente, (Landis & Koch, 1977) propusieron, la escala de valoración del índice Kappa que se describe en la Tabla 4.

Tabla 4*Valoración de índice kappa*

Kappa	Grado de acuerdo
< 0,00	Sin acuerdo
0,00-0,20	Insignificante
0,21-0,40	Mediano
0,41-0,60	Moderado
0,61-0,80	Sustancial
0,81-1,00	Casi perfecto

Nota. Tomado de Landis & Koch, 1977.

2.15 Tasa de deforestación

La tasa de deforestación en una serie temporal se refiere a la velocidad o el ritmo al cual se está perdiendo la cobertura forestal en una región durante un período de tiempo continuo y específico. Esta métrica mide la disminución o pérdida de bosques en el transcurso de varios años y se expresa generalmente en forma de porcentaje (%) y se calcula como indica la ecuación 2.13.

$$Tasa\ de\ deforestacion(\%) = \frac{\text{área deforestada}}{\text{área total}} \dots\dots\dots (2.13)$$

Donde:

- Área deforestada: valor en (ha) de deforestación, obtenido del mapa de cambio de cobertura del suelo en las series de tiempo definidas.
- Área total: valor en (ha) de la superficie boscosa, obtenido del mapa bosque no bosque del año menor en la serie de tiempo.

III. MÉTODO

3.1 Tipo de investigación

Este estudio se ajusta a los criterios metodológicos de una investigación aplicada, con un enfoque específico en la producción de conocimiento práctico para resolver problemas y situaciones reales. Se orienta hacia su implementación inmediata en lugar de enfocarse en la construcción teórica.

3.2 Ámbito temporal y espacial

El presente estudio se enfoca en el departamento de San Martín en el período comprendido entre 1987 y 2017, con el objetivo de cuantificar y analizar la variación de la deforestación a lo largo de estas tres décadas utilizando la teledetección como herramienta principal. Esto permitirá una comprensión más profunda de la evolución de la cobertura forestal en esta región durante un período crítico en términos de cambio ambiental.

El departamento de San Martín, ubicado en la región nororiente del Perú. Este departamento es conocido por su rica biodiversidad y su importancia en términos de cobertura forestal. El análisis se llevará a cabo en todo el territorio de San Martín, abarcando sus diversas provincias y ecosistemas.

3.3 Variables

Las variables identificadas en el presente estudio nos proporcionan un marco completo para analizar la deforestación en el departamento de San Martín durante el período especificado, estas variables son:

- cobertura forestal (ha)
- tasa de deforestación (%)

3.4 Población y muestra

Para medir y examinar la variación en la deforestación utilizando imágenes satelitales como datos de población, se utilizará todo el territorio del Departamento de San Martín. Este territorio se ha dividido

en 8 clases de cobertura conocidas como regiones de interés (ROI's), que se encuentran en todo el Departamento de San Martín, y se evaluarán para los años 1987, 1997, 2007 y 2017.

La muestra de este estudio de investigación está basada en el análisis de la deforestación para todo el Departamento de San Martín, para dicho análisis se realizó la reclasificación de las clases, obteniendo así dos clases denominadas bosque/no bosque para todo el Departamento de San Martín.

3.5 Instrumentos

3.5.1 Equipos y software

Los equipos empleados para la presente investigación son los siguientes:

Para el procesamiento digital de imágenes se usará, PCs con alta potencia denominada Workstation, de características HP Z840 - Xeon E5-2640 V3 - 16GB - 2TB + 128GB SSD - NVIDIA Quadro K2200 4GB - Windows 7/8.1 Pro, con dos monitores LCD de 24 pulgadas.

Los softwares empleados para la presente investigación son los siguientes:

- Utilización de software gratuito como licenciado
- ENVI 5.0 (MODULO CONIDA)
- ENVI 10.1
- ARCGIS 10
- QGIS 2.10

3.5.2 *Materiales*

Los materiales que se han empleado para realizar esta caracterización de los cambios en la provincia de San Martín entre 1987 y 2017 han sido los siguientes:

Se descargará un total de 40 imágenes Landsat distribuidos de la siguiente manera:

- 24 imágenes satelitales Landsat 5 sensor TM (Sensor Thematic Mapper) que denominaremos imagen esclava
- 8 imágenes satelitales Landsat L8 sensor OLI (Operational Land Imager)
- 8 imágenes Landsat Ortho rectificadas que denominaremos imagen master que servirán en la corrección geométrica

En esta investigación, se emplearon los siguientes materiales cartográficos:

Se recopiló toda la información cartográfica relevante y disponible según la escala de trabajo necesaria para la ubicación y planificación de la zona de estudio, como se detalla en la Tabla 5.

Tabla 5*Cartografía de la zona de estudio*

Ítem	Cartografía	Escala	Fuente
Base	Hidrografía	1/100 000	CENEPRED
	Centros poblados	1/100 000	IGN
Ubicación	Departamentos, provincias y Distritos	1/250 000	PCM
Accesibilidad	Vías/carreteras	1/250 000	MTC
Estudio de Ciudades Sostenibles	Casco urbano	1/5 000	INDECI
	Manzanas	1/5 000	INDECI
	Peligros	1/5 000	INDECI
	Sectores críticos	1/5 000	INDECI
Cartas digitales	Cartografía base	1/5 000	IGN
Generados por criterio propio del analista	Climas	1/5 000	IGN
	Desprendimientos	1/5 000	IGN
	Ecología	1/5 000	IGN
	Geo formas	1/5 000	IGN
	Geología	1/5 000	IGN
	Litografía	1/5 000	IGN
	Pisos altitudinales	1/5 000	IGN

Nota. Elaboración propia.

3.6 Procedimiento

El presente estudio de investigación tiene las siguientes etapas:

3.6.1 *Etapas de descarga de imágenes*

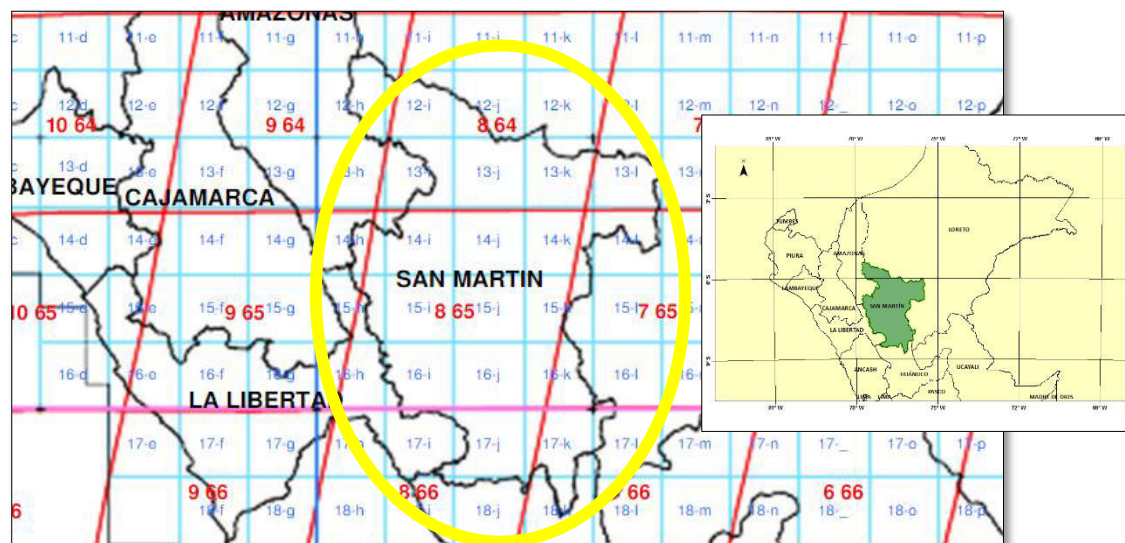
Para la obtención de las imágenes satelitales se realizó la descarga de imágenes del satélite Landsat brindadas por la NASA, este satélite tiene larga permanencia en órbita y en consecuencia data histórica y son de costo gratuito. La búsqueda de las imágenes Landsat se realizaron a través de los parámetros numéricos Path y Row que nos permitirán identificar rápidamente la imagen de forma análoga a los valores de longitud y latitud.

Se realizó la descarga de 40 imágenes satelitales Landsat (L5-L8). Son 8 imágenes satelitales Landsat que cubren el departamento de San Martín por año como se observa en la Figura 18, (ver lista de imágenes satelitales Landsat descargadas para los años 1987-1997-2007-2017 en el anexo B).

En la Tabla 6 se muestra la distribución por año y sensor de descarga de las 32 imágenes Landsat utilizadas para el análisis de resultados de este estudio de investigación, también se utilizaron 8 imágenes orto rectificadas que denominaremos como imagen master (ver lista de imágenes descargadas en el Anexo C). En la Figura 19 nos muestra la distribución por mes de las 32 imágenes Landsat descargadas.

Figura 18

Cobertura espacial de las escenas de las imágenes landsat



Nota. Se muestra que son 8 Path/Row los que cubren el departamento de San Martín. Elaboración propia.

Tabla 6

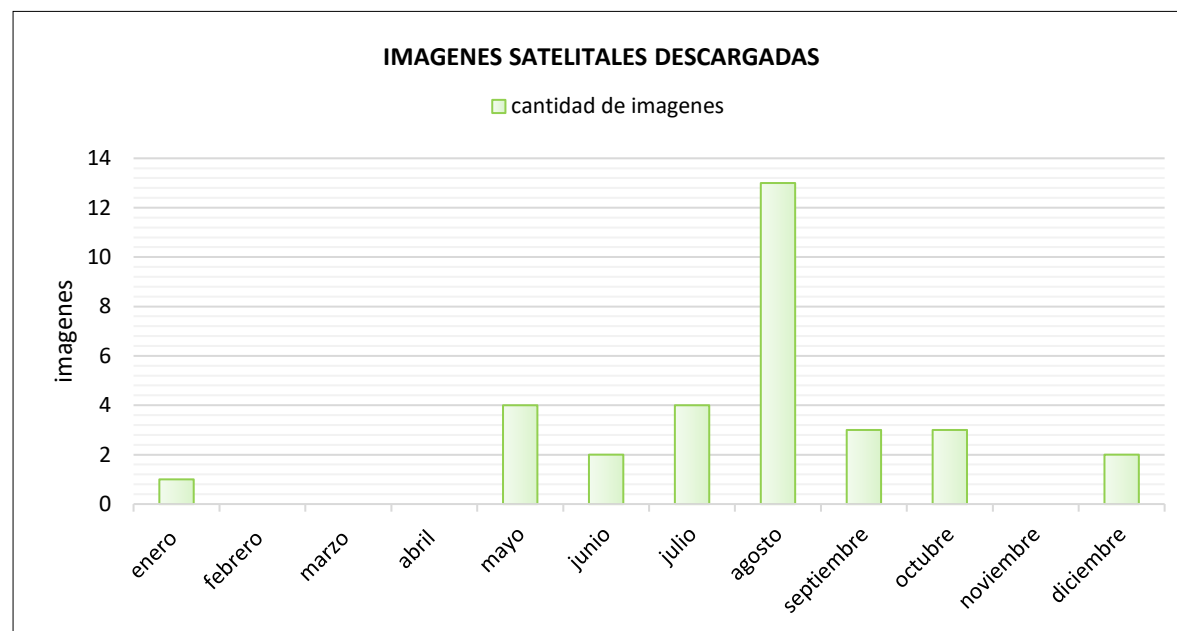
Lista de sensores landsat descargados

Año	Cantidad de Imágenes
1987	8 - Landsat 5TM
1997	8 - Landsat 5TM
2007	8 - Landsat 5TM
2017	8 - Landsat L8 OLI

Nota. Elaboración propia.

Figura 19

Distribución de imágenes descargadas para el periodo de estudio



Nota. Se observa que en el mes de agosto se descargó la mayor cantidad de imágenes, esto se debe que el mes de agosto pertenece a la temporada secante que nos indica zonas despejadas de nubes. Elaboración propia.

3.6.2 Etapa de procesamiento

Las imágenes satelitales descargadas pasaran por una etapa de pre procesamiento, basadas en correcciones geométricas, radiométricas y atmosféricas, para luego ser analizadas en parámetros de reflectancia a través de las firmas espectrales, esto nos llevará a emplear el método de clasificación supervisada SVM (Support Vector Machines). Sin embargo, este enfoque no nos permitirá generar mapas de clasificación, mapas de cambio de cobertura ni informes estadísticos sobre las tendencias y tasas de deforestación para el departamento de San Martín.

Corrección geométrica

Es importante para determinar si un píxel está ubicado correctamente en el espacio. El estudio cuenta con 32 imágenes Landsat de las cuales 24 son imágenes Landsat L5 TM que requieren de análisis geométrico y 8 son imágenes Landsat L8 OLI que no necesitan análisis geométrico ya que estas imágenes vienen Orthorectificadas.


Para corregir geoméricamente las 24 imágenes Landsat L5 TM se descargaron 8 imágenes L5 TM Orthorectificadas de los años 2010 y 2011 que denominaremos imágenes master, estableciéndose un análisis basado en la identificación de puntos en una imagen referencial (imagen master) comparada con información vectorial oficializada por el IGN (Instituto Geográfico Nacional), siendo la imagen satelital resultante la que permite el corregistro de las 24 imágenes Landsat L5 TM que denominaremos imagen esclava utilizadas para los años 1987, 1997 y 2007.

- **Error de la imagen master**, el corregistro vector – imagen, se realizó con la selección de puntos de controles identificados visualmente en la información vectorial (ríos) e imágenes satelitales correspondiente al departamento de San Martín. La información vectorial es proporcionada por el IGN (Instituto Geográfico Nacional) y las imágenes satelitales master fueron descargadas de los servidores USGS (U.S. Geological Survey) y GCLF (Global Land Cover Facility).

Las imágenes de satélite Landsat descargadas en el nivel (L1T) con +/- 50 m de error según las características de precisión de su método de corrección geométrica es presentada con un punto rojo en la Figura 20 también se observa en verde el punto de control del vector IGN, dichos puntos se encuentran en coordenadas geográficas.

Figura 20

Identificación de los puntos de control

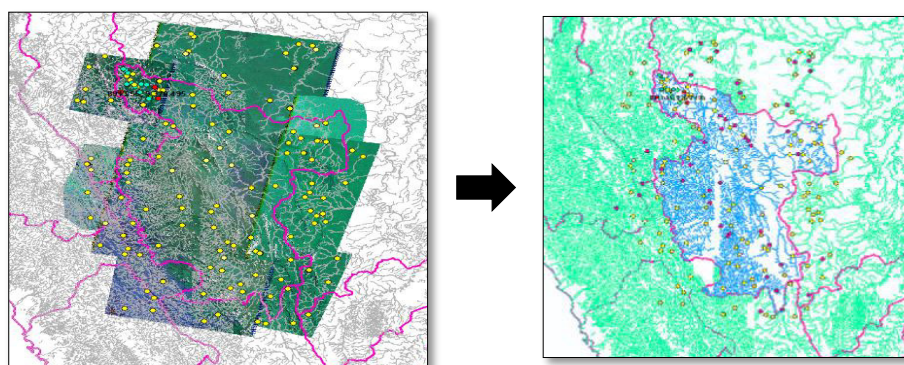


Nota. La identificación se realizó en la imagen master Landsat TM (30 M Resolución) con Combinación de Bandas 3 4 5 /R G B. Elaboración propia.

En la Figura 21, lado izquierdo, se muestra la distribución homogénea de 200 puntos de control en color amarillo ubicados en las ocho (8) imágenes master Landsat L5 TM que cubren el departamento de San Martín, lado derecho distribución homogénea de 200 puntos de control en color rosado ubicados en el vector.

Figura 21

Distribución homogénea de los puntos de control imagen – vector



Nota. Se muestra un mosaico de las imágenes master en combinación de bandas 3 4 5 /R G B (30 m resolución) y el vector hidrográfico de escala (1 / 100 000). Elaboración propia.

Para determinar los estadísticos se utilizó el error medio cuadrático (RMSE), desviación estándar (STVD) y % área. En la Tabla 7, se muestran los errores obtenidos para cada imagen, se observa en el path/row 7_65 con 16% del área de estudio y el path/row 9_64 con 6% del área de estudio representan los valores máximos encontrados para el RMSE ($\sigma_{RMSEmaster}$), el máximo valor obtenido puede darse por una cantidad menor de puntos de control distribuidos en dichos path/row o por la falta de intersecciones de ríos en dichas áreas del path/row, observamos también que el path/ row 9_65 con 3% del área de estudio representa el valor más bajo esto se debe a la distribución homogénea de los puntos de control en el área más pequeña, considerando que el valor del RMSE debe ser menor a un pixel los valores de la Tabla 7, están comprendidos entre $0.64 \text{ px} \leq \text{RMSE} \leq 1.00 \text{ px}$ siendo el promedio total del RMSE para el departamento de San Martín 0.78 px.

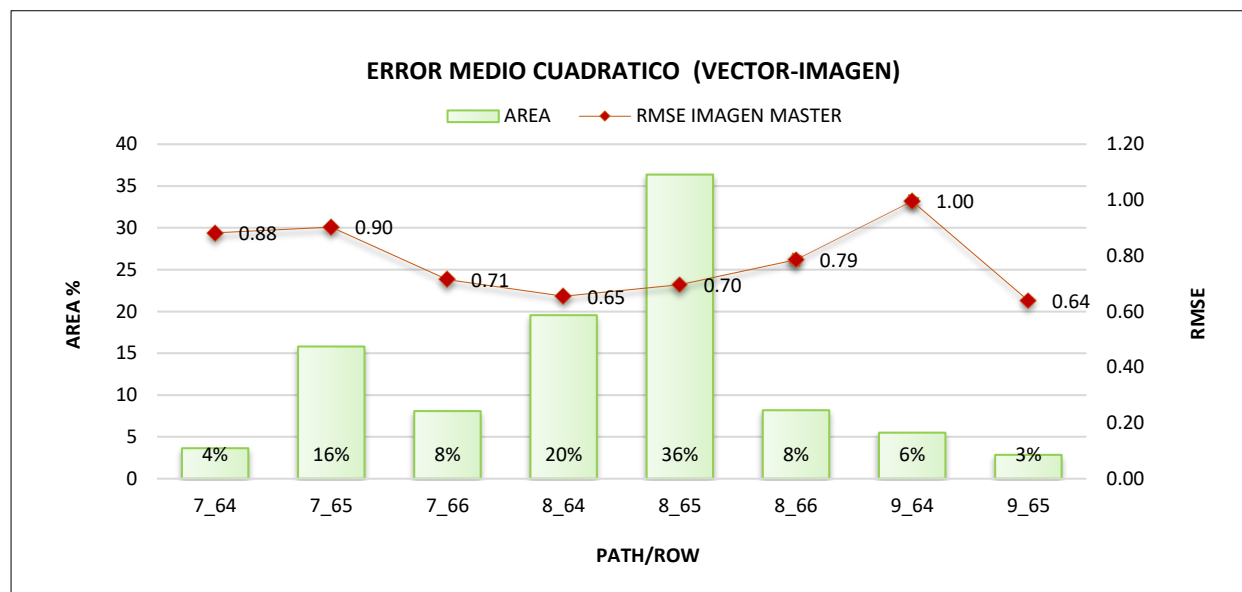
Tabla 7

Resultado del RMSE para la imagen master y área porcentual según path/row

Fecha Imagen Master	Path/Row	Área %	$\sigma_{\text{RMSEmaster}} \pm \sigma_{\text{DesvStand}}$
15/09/2011	7_64	4	0.88 ± 0.13
11/10/2010	7_65	16	0.90 ± 0.13
29/07/2011	7_66	8	0.71 ± 0.13
18/08/2010	8_64	20	0.65 ± 0.13
18/08/2010	8_65	36	0.70 ± 0.13
06/09/2011	8_66	8	0.79 ± 0.13
14/02/2010	9_64	6	1.00 ± 0.13
09/06/2011	9_65	3	0.64 ± 0.13
Promedio RMSE ± Desviación Estándar (Píxel)		100	0.78 ± 0.13

Nota. La desviación estándar ($\sigma_{\text{DesvStand}}$) representa la variación en la distancia que los valores pueden alejarse del promedio del RMSE total, que es de 0.13 píxeles. Elaborado por el autor del estudio.

Los resultados obtenidos del correregistro (vector – imagen master) se muestran en la Figura 22 donde se puede observar la distribución en barras que indican el porcentaje en área para el departamento del San Martín según path/row, también incluye las estadísticas del error cuadrático medio (RMSE), donde todos los valores fueron menor a un píxel, resultando un correregistro adecuado para las imágenes master.

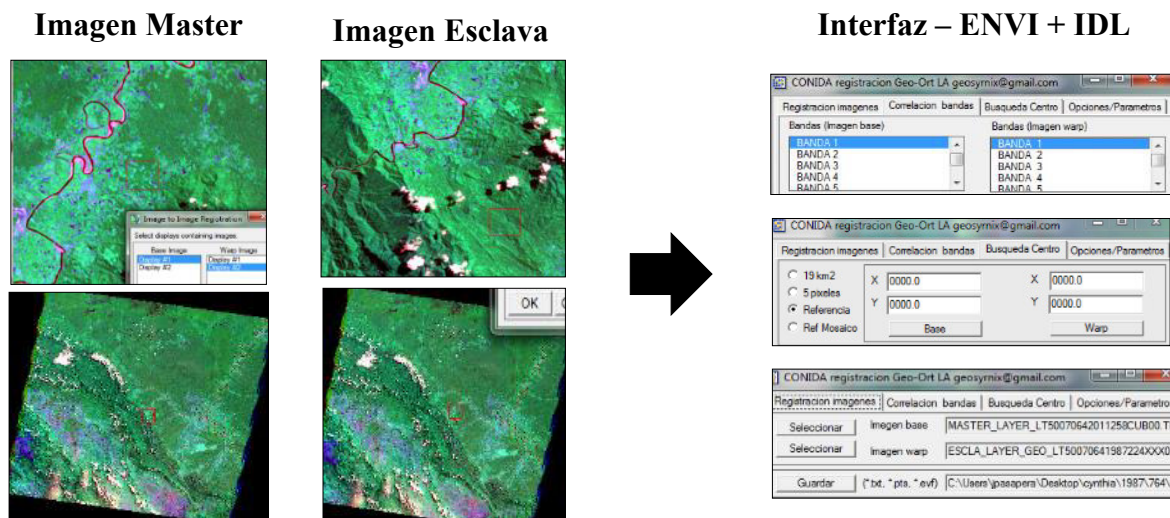
Figura 22*Distribución del RMSE*

Nota. Información según el área porcentual por cada path/row de la imagen landsat master para el Departamento de san Martín donde se puede observar que el Path/Row 8_65 abarca la mayor cantidad de área cubriendo un 36% del área total de estudio. Elaboración propia.

- **Error de correregistro**, el proceso de correregistro (alineación entre imágenes) se llevó a cabo utilizando imágenes satelitales Landsat L5 TM correspondientes a los años 1987, 1997 y 2007. La selección de puntos de control se realizó mediante una interfaz desarrollada en un lenguaje de programación, como se muestra en la Figura 23. Este interfaz contiene algoritmos para calcular las funciones de ajuste utilizando polinomios de Fourier, logrando un error cuadrático medio (RMSE) inferior a un píxel por año. Para el ajuste de los niveles digitales debido al cambio de proyección, se aplicó el método de vecino más próximo (nearest neighbor).

Figura 23

Selección de puntos de control usando el interfaz

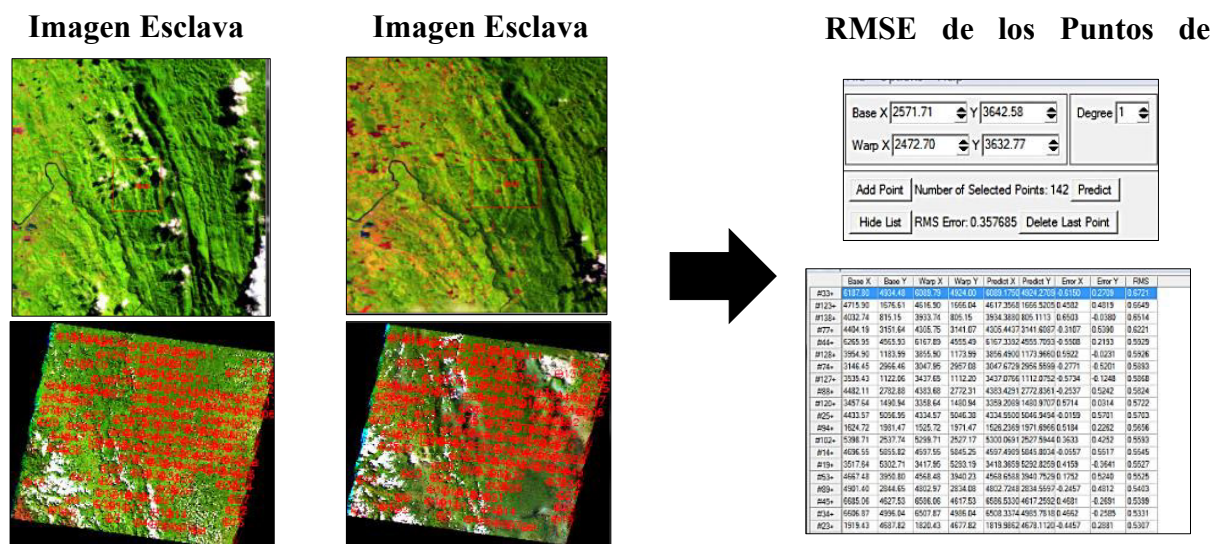


Nota. Se selecciona a las imágenes Landsat L5 TM (imagen esclava) con bajo porcentaje de nubosidad, para el uso del interfaz (registación Landsat TM, ETM) Desarrollado con Lenguaje de Programación IDL por la Dirección de Geomática de la CONIDA, combinación de bandas 3 4 5 /R G B. Elaboración propia.

De las opciones del interfaz, se escoge la cantidad de puntos que se desea en correlación, a mayor cantidad de puntos de control distribuidos en la imagen satelital mayor tiempo de ejecución del proceso, se consideró en las 8 imágenes Landsat L5 TM un aproximado de 300 puntos de control por imagen, entregando como resultado el valor del RMSE variable, Para calcular el valor del error cuadrático medio (RMSE), se llevaron a cabo ajustes considerando únicamente los puntos de control situados en áreas nubosas. Este enfoque nos permitió obtener un valor de RMSE menor a un píxel, como se ilustra en la Figura 24.

Figura 24

Compilación del interfaz



Nota. Se observa la distribución de 300 puntos de control aproximadamente en las imágenes master y esclava. Elaboración propia.

Las estimaciones del RMSE para las imágenes esclavas de los años 1987, 1997 y 2007 se muestran en la Tabla 8, donde se observa el mayor valor del RMSE corresponde al año 1987, esto se debe que las imágenes satelitales que corresponden a dicho año cuentan con mayor porcentaje de nubosidad, el menor valor del RMSE corresponde al año 2007 donde se trabajó con mayor cantidad de puntos de control debido a la disponibilidad de imágenes libres de nubes. Considerando que el RMSE debe ser menor al pixel los valores resultantes de RMSE para cada año se encuentra dentro de lo permisible obteniendo el valor del RMSE del año 2007 con mayor precisión en la correlación imagen – imagen.

Tabla 8*Resultados del correregistro (imagen master – imagen esclava)*

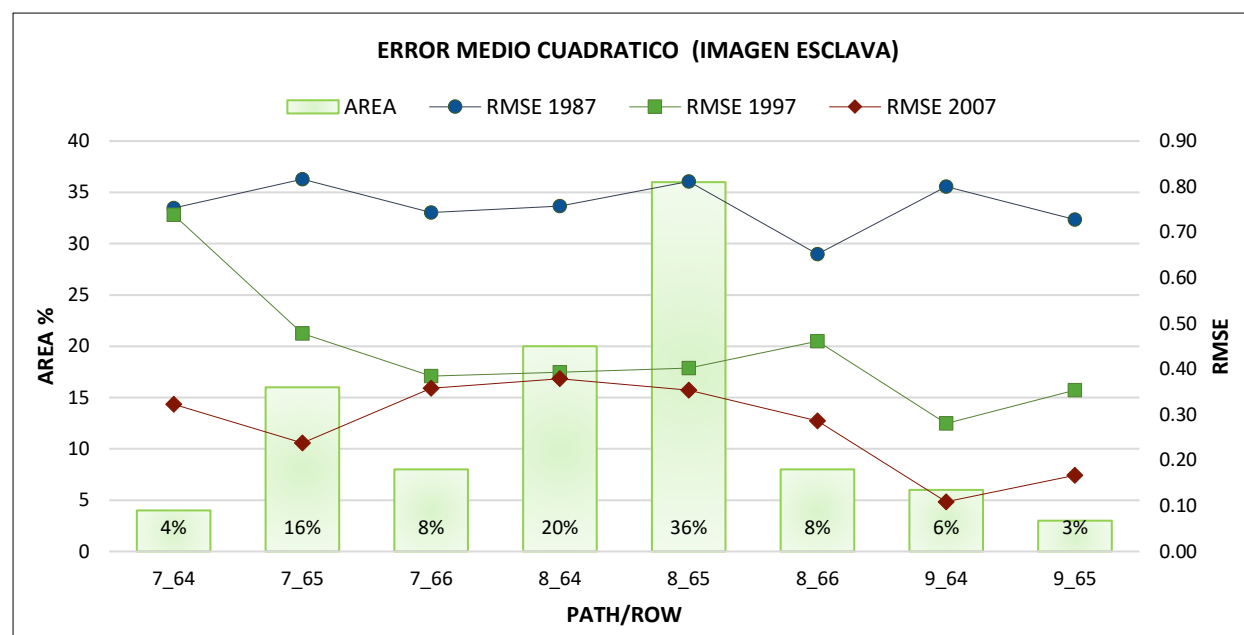
Path/Row	Área %	$\sigma_{RMSEimaEscl} \pm \sigma_{DesvStand}$		
		1987	1997	2007
7_64	4	0.75 ± 0.05	0.74 ± 0.14	0.32 ± 0.10
7_65	16	0.82 ± 0.05	0.48 ± 0.14	0.24 ± 0.10
7_66	8	0.74 ± 0.05	0.38 ± 0.14	0.36 ± 0.10
8_64	20	0.76 ± 0.05	0.39 ± 0.14	0.38 ± 0.10
8_65	36	0.81 ± 0.05	0.40 ± 0.14	0.35 ± 0.10
8_66	8	0.65 ± 0.05	0.46 ± 0.14	0.29 ± 0.10
9_64	6	0.80 ± 0.05	0.28 ± 0.14	0.11 ± 0.10
9_65	3	0.73 ± 0.05	0.35 ± 0.14	0.17 ± 0.10
	100	0.76 ± 0.05	0.44 ± 0.14	0.28 ± 0.10
Promedio RMSE ± Desviación Estándar (Pixel)				

Nota. Se observa los valores del RMSE correspondientes a los años 1987, 1997 y 2007 para las imágenes esclavas, área porcentual según path/row, desviación estándar respecto al promedio del RMSE total. Elaboración propia.

En la Figura 25 se observa la representación gráfica de los resultados estadísticos para los diferentes path/row, el RMSE del año 2007 indica la tendencia más baja por lo que representa los mejores resultados estadísticos, el RMSE del año 1987 muestra la tendencia más alta pero no mayor a un pixel lo cual indica que se mantiene en el rango de la precisión requerida, por otra parte, se observa la distribución en barras del área porcentual para el departamento de San Martín.

Figura 25

representación gráfica de la distribución del RMSE



Nota. De los resultados de distribución del RMSE para la imagen esclava, es interesante observar que el path/row 8_65 cubre gran cantidad de área estudio por lo cual se trabajara con la imagen completa, para los otros path/row el área porcentual es mucho más pequeño por lo que se aplicara recortes de las imágenes formando un mosaico del área de estudio. Elaboración propia.

- **Propagación del RMSE**, el RMSE total corresponde a la adición del error de la imagen master y el error de la imagen esclava generando un promedio total del RMSE y un promedio total de la desviación estándar por año, la Tabla 9 muestra el valor promedio del RMSE ($\sigma_{RMSE(M+E)}$) y de la desviación estándar promedio ($\sigma_{DesvStand}$) por path/row, se observa que el menor RMSE corresponde al año 2007 y el mayor RMSE corresponde año 1987 esto es consecuente con los resultados mostrados en las Figura 22 y la Figura 25.

Realizando la estadística determinamos la propagación del RMSE total para cada año como se observa en la Tabla 9.

Tabla 9

Resultado del RMSE total de la corrección geométrica

Path/Row	Área %	$\sigma_{RMSE(M+E)} \pm \sigma_{DesvStand}$		
		1987	1997	2007
7_64	4	1.64 ± 0.16	1.62 ± 0.21	1.21 ± 0.12
7_65	16	1.72 ± 0.16	1.38 ± 0.21	1.14 ± 0.12
7_66	8	1.46 ± 0.16	1.10 ± 0.21	1.07 ± 0.12
8_64	20	1.41 ± 0.16	1.05 ± 0.21	1.03 ± 0.12
8_65	36	1.51 ± 0.16	1.10 ± 0.21	1.05 ± 0.12
8_66	8	1.44 ± 0.16	1.25 ± 0.21	1.07 ± 0.12
9_64	6	1.80 ± 0.16	1.28 ± 0.21	1.10 ± 0.12
9_65	3	1.37 ± 0.16	0.99 ± 0.21	0.81 ± 0.12
	100	1.54 ± 0.16	1.22 ± 0.21	1.06 ± 0.12
Promedio RMSE ± Desviación Estándar (pixel)				

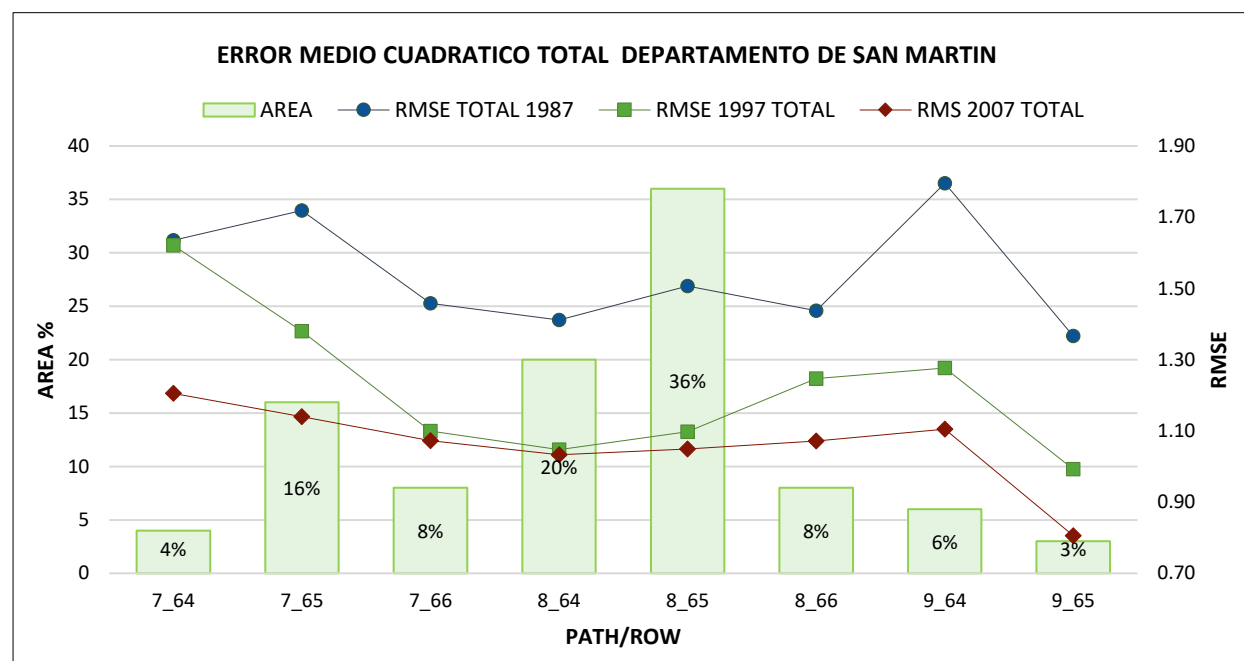
Nota. Se aplicó la estadística de (RMSE master + RMSE esclava) para los años 1987, 1997 y 2007.

Elaboración propia.

En la figura 26 se observa la representación gráfica de los resultados estadísticos totales del RMSE según el área porcentual en la imagen landsat para los diferentes path/row de los años 1987, 1997 y 2007.

Figura 26

Representación gráfica de la distribución del RMSE total



Nota. Se observa que el valor máximo del RMSE lo tiene el año 1987 con 1.54 px., este valor corresponde a la propagación del error. Elaboración propia.

La Tabla 10 muestra el resumen del promedio del RMSE total y el promedio total de la desviación estándar por año.

Tabla 10

Resultado del RMSE total de la corrección geométrica por año

	$\sigma_{RMSE(M+E)} \pm \sigma_{DesvStand}$		
	1987	1997	2007
$\sigma_{RMSEtotal}$	1.54 ± 0.16	1.22 ± 0.21	1.06 ± 0.12

Nota. Podemos mencionar que Cuanto menor sea el valor del RMSE total, mayor será la precisión de la corrección geométrica. Elaboración propia.

- **Desviación estándar total de la corrección geométrica**, esta medida de dispersión nos indica cuán cerca están las ubicaciones corregidas de las ubicaciones verdaderas, lo que es fundamental para garantizar la calidad y la precisión de los datos geoespaciales utilizados en este estudio, cuanto menor sea la desviación estándar, mayor será la confiabilidad de los datos corregidos en términos de su precisión espacial. La Tabla 11 nos muestra los resultados de la Media y la Desviación Estándar.

Tabla 11

Resultado de la media y la desviación estándar total de la corrección geométrica

Media	1.27
Desviación Estándar	0.24

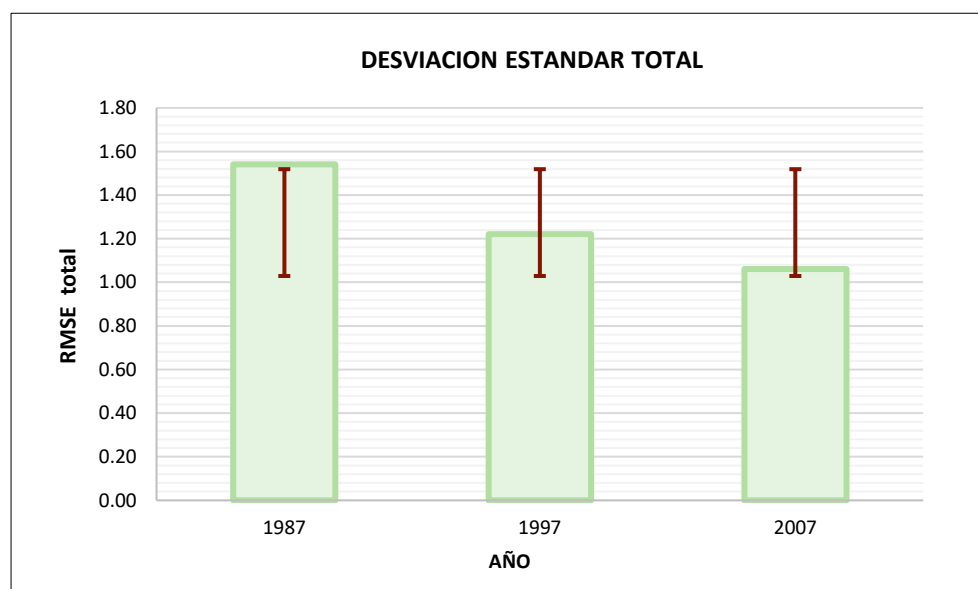
Nota. Fuente: Elaboración propia.

En la Figura 27 se observa que para cada uno de los valores mostrados la línea representa el intervalo sobre la Media global de nuestros valores que es 1.27 y se desvía normalmente en 0.24 por encima y por debajo.

En el proceso de análisis geométrico se puede observar el RMSE y la DESVIACIÓN ESTÁNDAR para los años 1987,1997 y 2007 respecto al vector de ríos, el objetivo del análisis fue para estandarizar la posición de coordenadas en el espacio de las imágenes esclavas landsat L5 TM por año para los procesos posteriores de clasificación.

Figura 27

Barras de error con desviación estándar



Nota. Los resultados nos permiten tener una idea de la dispersión de los datos y la incertidumbre asociada con la medición. Elaboración propia.

Corrección radiométrica.

Se realizó los cálculos de correcciones radiométricas a las 32 imágenes Landsat buscando estandarizar el comportamiento espectral de la longitud de onda de cada escena para los años 1987 – 1997 – 2007 - 2017. Se presenta dos modelos que se realizaron para los cálculos de las variables físicas de radiancia, reflectancia un total de 24 imágenes Landsat 5 TM.

Modelo:

Modelo A, cálculos utilizando una interfaz gráfica escrita en lenguaje de programación IDL elaborado por la CONIDA que procesa automáticamente las imágenes Landsat TM, ETM.

Modelo B, cálculos utilizando ecuaciones y parámetros predeterminados según el artículo Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+ and EO-1 ALI sensors. (Chander & Markham, 2009) con matemática de bandas y plantilla Excel.

Se utilizo dos modelos de cálculo para las correcciones radiométricas que nos permiten transformar los valores de brillo captados por el sensor y representados por los niveles digitales a variables físicas de radiancia y reflectancia las cuales pueden ser asociadas directamente con los distintos tipos de cobertura de suelo, se puede observar en la Tabla 12, La distribución de los modelos según el año y las escenas de las imágenes Landsat.

Con el objetivo de optimizar y automatizar los procesos de correcciones radiométricas se utiliza la interfaz gráfica (modelo A) en las 24 imágenes Landsat 5 TM, sin embargo, en las escenas (8_66, 9_64, 9_65) de los años 1987 y 1997 se aplicó el (modelo B) que conlleva en la práctica a una secuencia de procedimientos de la imagen.

Tabla 12*Distribución de correcciones radiométricas*

Escena	1987	1997	2007
7_64			
7_65			Interfaz gráfica escrita en lenguaje de programación IDL (A)
7_66			
8_64			
8_65			
8_66		Calculadora matemática utilizando ecuaciones y parámetros predeterminados (B)	Interfaz gráfica escrita en lenguaje de programación IDL (A)
9_64			
9_65			

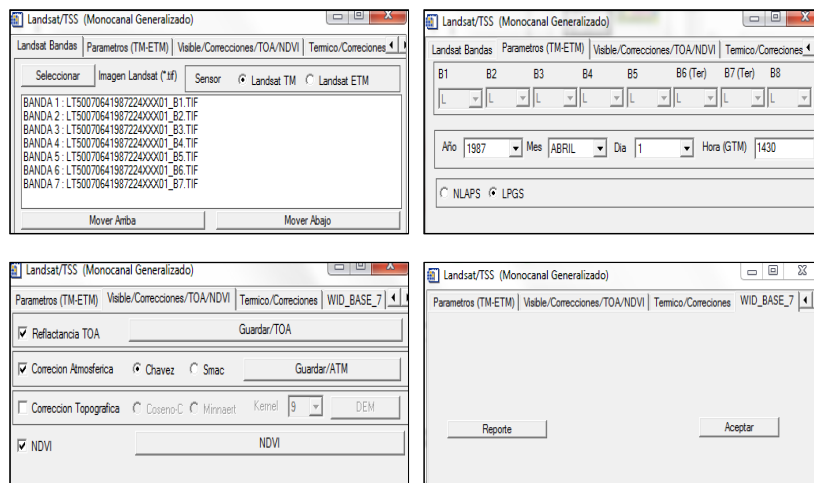
Nota. Elaboración propia.

- **Modelo A**, con este modelo se realizó el cálculo de las variables radiancia y reflectancia que consiste en la compilación de la interfaz gráfica escrita en lenguaje de programación IDL elaborado por la Dirección de Geomática de la CONIDA, está diseñada para procesar automáticamente las imágenes Landsat TM, ETM, ver Figura 28, en la Figura 29 se puede observar los resultados de la compilación para la escena 8_66 del año 2007.

El modelo A se aplicó a 18 imágenes Landsat como indica la Tabla 12, obteniendo resultados dentro de los parámetros establecidos para los valores de radiancia y reflectancia, los resultados de la reflectancia se expresan generalmente como valores numéricos que varían entre 0 y 1 o entre 0% y 100%. Un valor de 0 indica que la superficie absorbe toda la luz incidente, mientras que un valor de 1 o 100% indica que la superficie refleja toda la luz incidente.

Figura 28

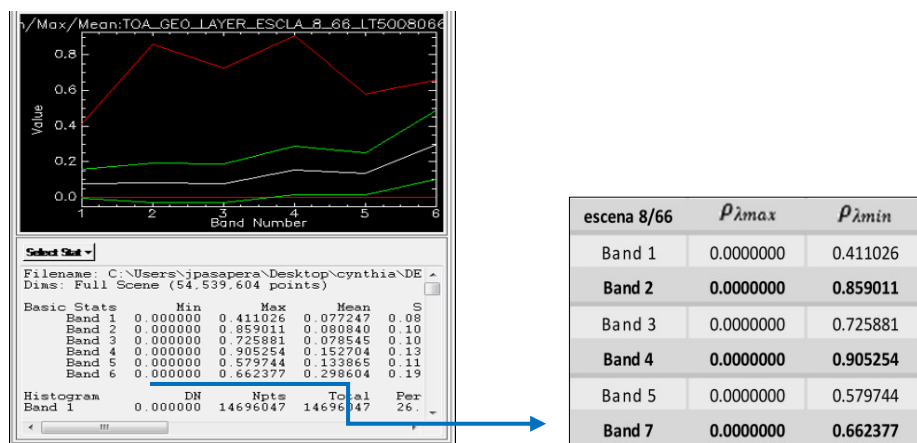
Interfaz de calibración radiométrica de radiancia y reflectancia



Nota. Interfaz escrito en lenguaje IDL+ENVI. Elaboración propia.

Figura 29

Resultados de la variable física reflectancia usando (Modelo A)

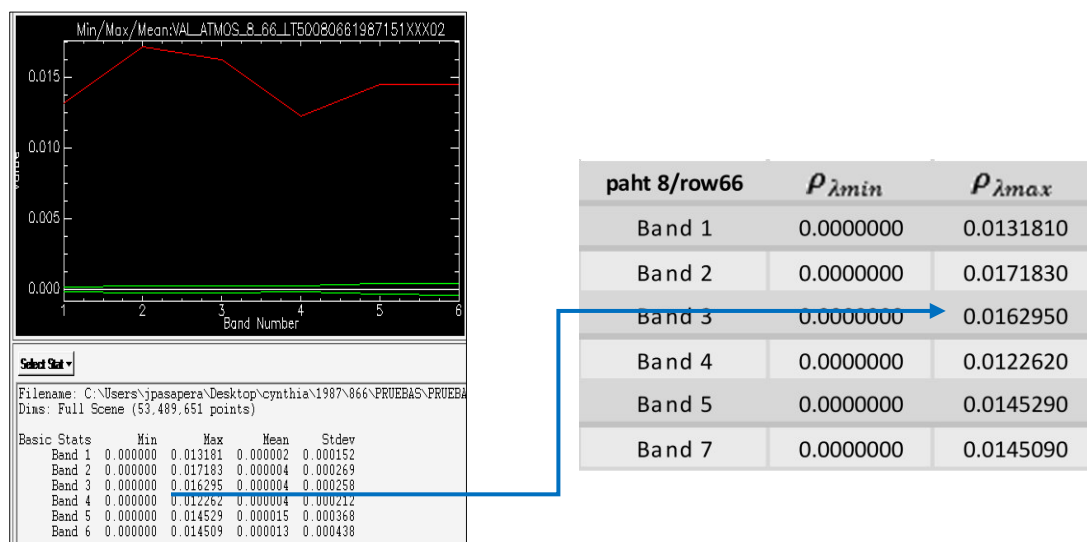


Nota. Información de la escena 8_66 del año 2007, Lado izquierdo se observa la gráfica de análisis espectral que nos permite identificar características específicas de la superficie, lado derecho resultado numérico que varía entre 0 y 1, estos resultados son fundamentales para comprender y monitorear la superficie. Elaboración propia.

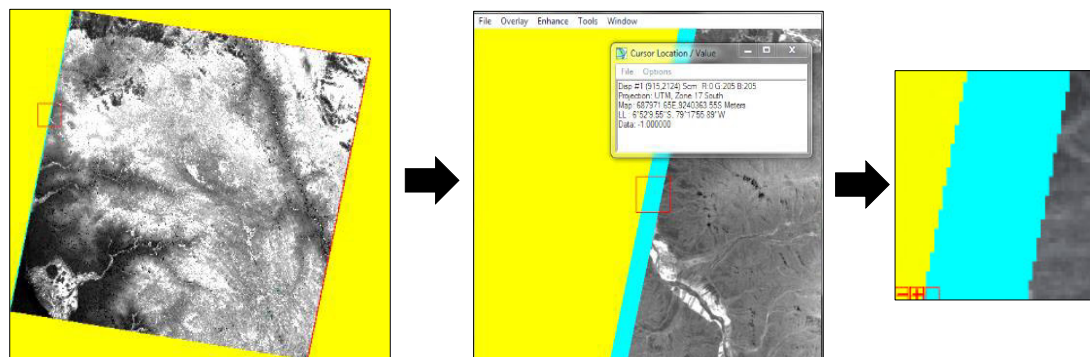
- **Modelo B**, este modelo se aplicó aquellas imágenes que después de haber sido compiladas utilizando la interfaz gráfica (modelo A) los resultados de las correcciones radiométricas se muestren fallidas ya q el valor de la Reflectancia debería ir de 0 a 1. En la Figura 30, se observa que el valor mínimo y máximo de la Reflectancia por banda es un resultado erróneo y se detectó en 6 imágenes procesadas con el (modelo A), este error puede ser causado por las correcciones geométricas, del análisis realizado en las correcciones geométricas se puede observar que 6 imágenes tienen el RMSE (error medio cuadrático) más elevado por lo tanto representaría una desviación de posición de la imagen frente la matriz ya que el interfaz gráfico utilizado es programado para matrices exactas como observamos en la Figura 31, estas 6 imágenes fueron del año 1987 y 1997.

Figura 30

Resultados erróneos de la reflectancia usando (modelo A)



Nota. Información de la escena 8_66 del año 1987. Elaboración propia.

Figura 31*Desviación de posición de la imagen*

Nota. Los bordes cian y rojo nos representan a la matriz entregada al compilar la interfaz gráfica, la escena 8_66 no calza dentro de esta matriz haciendo que los valores de la imagen corregida sean muy pequeños llevando al error del dato. Elaboración propia.

Frente a esta anomalía se aplica el (modelo B) utilizando matemática de bandas, plantillas Excel, y parámetros dados en los metadatos de la imagen satelital que coinciden con los aportados por Chander et al. (2009), mostrados en la Figura 32.

Este modelo consiste en el cálculo de las variables físicas de radiancia y reflectancia que utiliza las ecuaciones 2.5 y 2.6, con constantes predeterminadas y parámetros propios de la imagen y del sensor como se muestra en la Figura 32.

Figura 32

Constantes predeterminadas

TM Sensors ($Q_{calmin} = 1$ and $Q_{calmax} = 255$)							
Band	Spectral range	Center wavelength	$LMIN_{\lambda}$	$LMAX_{\lambda}$	$G_{rescale}$	$B_{rescale}$	$ESUN_{\lambda}$
Units	μm		$W/(m^2 sr m)$		$(W/m^2 sr m)/DN$	$W/(m^2 sr m)$	$W/(m^2 m)$
L4 TM (NLAPS)							
1	0.452 – 0.518	0.485	-1.52	152.10	0.602431	-1.52	1983
2	0.529 – 0.609	0.569	-2.84	296.81	1.175098	-2.84	1795
3	0.624 – 0.693	0.659	-1.17	204.30	0.805765	-1.17	1539
4	0.776 – 0.905	0.841	-1.51	206.20	0.814549	-1.51	1028
5	1.568 – 1.784	1.676	-0.37	27.19	0.108078	-0.37	219.8
6	10.42 – 11.66	11.040	1.2378	15.3032	0.055158	1.2378	N/A
7	2.097 – 2.347	2.222	-0.15	14.38	0.056980	-0.15	83.49
L4 TM (LPGS)							
1	0.452 – 0.518	0.485	-1.52	163	0.647717	-2.17	1983
			-1.52	171	0.679213	-2.20	
2	0.529 – 0.609	0.569	-2.84	336	1.334016	-4.17	1795
3	0.624 – 0.693	0.659	-1.17	254	1.004606	-2.17	1539
4	0.776 – 0.905	0.841	-1.51	221	0.876024	-2.39	1028
5	1.568 – 1.784	1.676	-0.37	31.4	0.125079	-0.50	219.8
6	10.42 – 11.66	11.040	1.2378	15.3032	0.055376	1.2378	N/A
7	2.097 – 2.347	2.222	-0.15	16.6	0.065945	-0.22	83.49
L5 TM (LPGS)							
1	0.452 – 0.518	0.485	-1.52	169	0.671339	-2.19	1983
			-1.52	193	0.765827	-2.29	
2	0.528 – 0.609	0.569	-2.84	333	1.322205	-4.16	1796
			-2.84	365	1.448189	-4.29	
3	0.626 – 0.693	0.660	-1.17	264	1.043976	-2.21	1536
4	0.776 – 0.904	0.840	-1.51	221	0.876024	-2.39	1031
5	1.567 – 1.784	1.676	-0.37	30.2	0.120354	-0.49	220.0
6	10.45 – 12.42	11.435	1.2378	15.3032	0.055376	1.18	N/A
7	2.097 – 2.349	2.223	-0.15	16.5	0.065551	-0.22	83.44

Nota. La tabla muestra los rangos de longitudes de onda y constantes de calibración radiométrica de la serie landsat. Tomado de Chander, 2009.

- Primero se calculó la variable física radiancia a un total de 6 imágenes, para ello se requiere extraer los datos de (Gain, Bias) que se encuentran en la metadata (*.met) de la imagen Landsat, de estos datos resulta las ecuaciones lineales para la radiancia como se observa en la Tabla 13.

Tabla 13*Ecuaciones Lineales para el Cálculo de la Variable Radiancia*

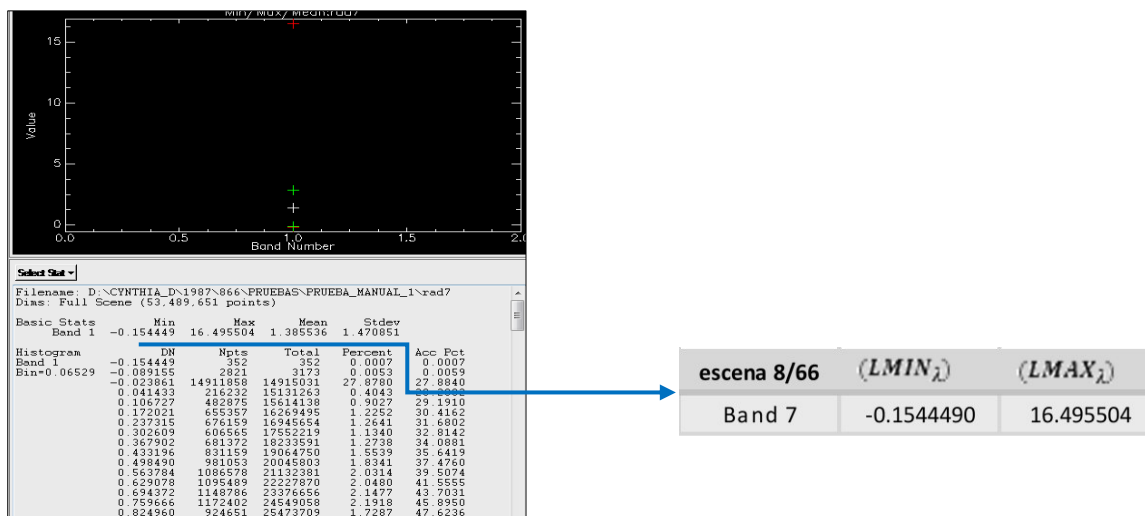
Escena 8_66	Ecuaciones lineales
Band 1	$0.671339*b1 - 2.19$
Band 2	$1.322205*b2 - 4.16$
Band 3	$1.043976*b3 - 2.21$
Band 4	$0.876024*b4 - 2.39$
Band 5	$0.120354*b5 - 0.49$
Band 7	$0.065551*b7 - 0.22$

Nota. Imagen de la escena 8_66 del año 1987. Elaboración propia.

Aplicando las ecuaciones lineales a cada banda de la imagen los resultados deben coincidir con los resultados mostrados por el artículo Chander et al. (2009), en la Figura 33, se muestra el valor resultante de la radiancia mínima ($LMIN_{\lambda}$) y la radiancia máxima ($LMAX_{\lambda}$) para la banda 7 de la imagen Landsat y efectivamente coinciden con los resultados mostrados por Chander et al. (2009), como se observa en la Figura 32.

Figura 33

Resultado del valor de la radiancia

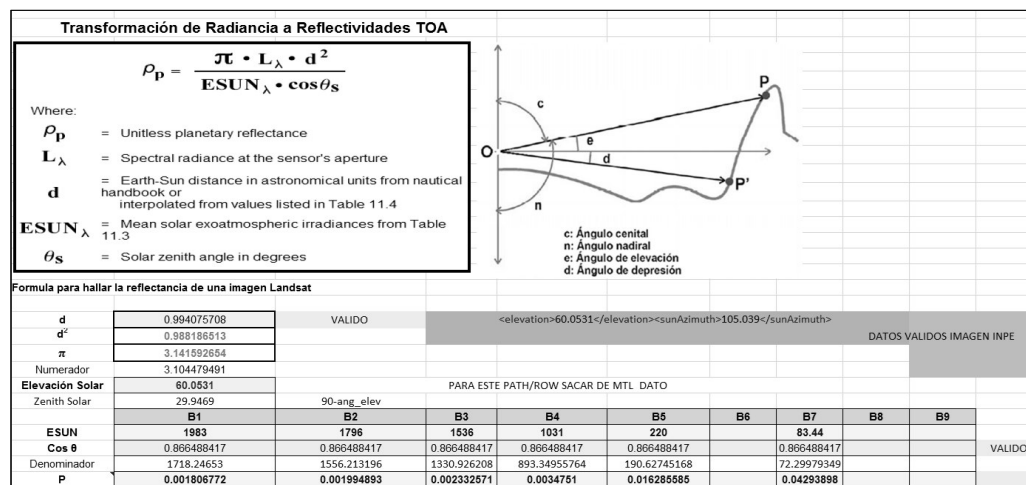


Nota. Los resultados mostrados pertenecen a la banda 7 de la escena 8_66 del año 1987. Elaboración propia.

- Segundo, una vez obtenido la radiancia espectral se calculó la variable física Reflectancia (TOA) usando la ecuación 2.6, a un total de 6 imágenes, para ello se requiere los parámetros d y $ESUN_{\lambda}$ que se encuentran en el artículo de Chander et al. (2009) y el ángulo cenital solar que se encuentran en los metadatos de la imagen, el parámetro d se calculó con la ecuación 2.7, para el cual se hizo uso de una plantilla Excel que muestra la Figura 34, a continuación la Tabla 14 muestra las ecuaciones que se ingresó en la matemática de banda del software utilizado para obtener resultados de reflectancia.

Figura 34

Plantilla excel



Nota. Los cálculos del parámetro d (distancia tierra sol) y del ángulo zenit solar en radianes. Elaboración propia.

Tabla 14

Ecuaciones para el cálculo de la variable reflectancia por banda

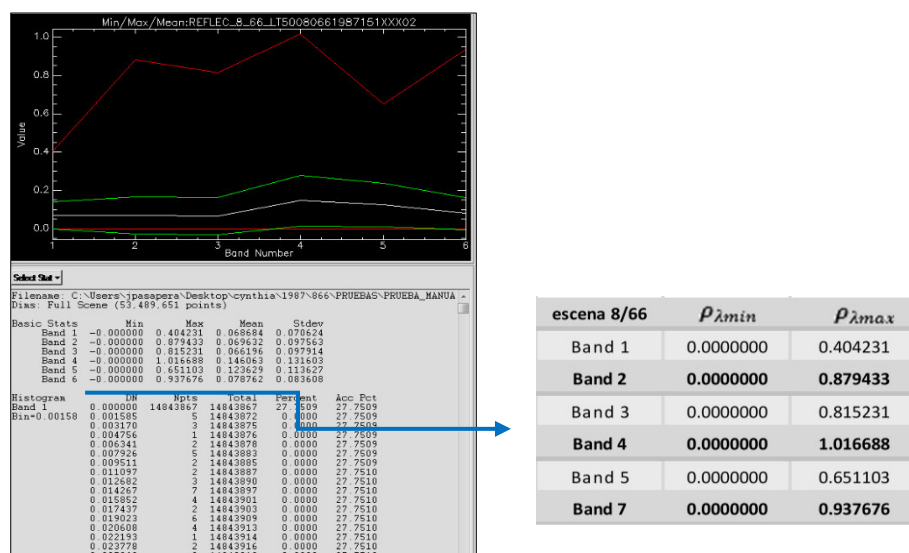
Escena8/66	Ecuaciones
Band 1	$((1.013676644^2) * 3.141516 * (b1)) / (1983 * 0.680575732)$
Band 2	$((1.013676644^2) * 3.141516 * (b2)) / (1796 * 0.680575732)$
Band 3	$((1.013676644^2) * 3.141516 * (b3)) / (1536 * 0.680575732)$
Band 4	$((1.013676644^2) * 3.141516 * (b4)) / (1031 * 0.680575732)$
Band 5	$((1.013676644^2) * 3.141516 * (b5)) / (220 * 0.680575732)$
Band 7	$((1.013676644^2) * 3.141516 * (b7)) / (83.44 * 0.680575732)$

Nota. Escena 8_66 del año 1987. Elaboración propia.

Al aplicar las ecuaciones mencionadas en la Tabla 14 los resultados de la reflectancia $\rho_{\lambda min}$ y $\rho_{\lambda max}$ nos da los valores por banda como se muestra en la Figura 35, donde se observa que los resultados obtenidos son correctos ya que se encuentra dentro del rango permitido para Reflectancia.

Figura 35

Resultados de la variable física reflectancia

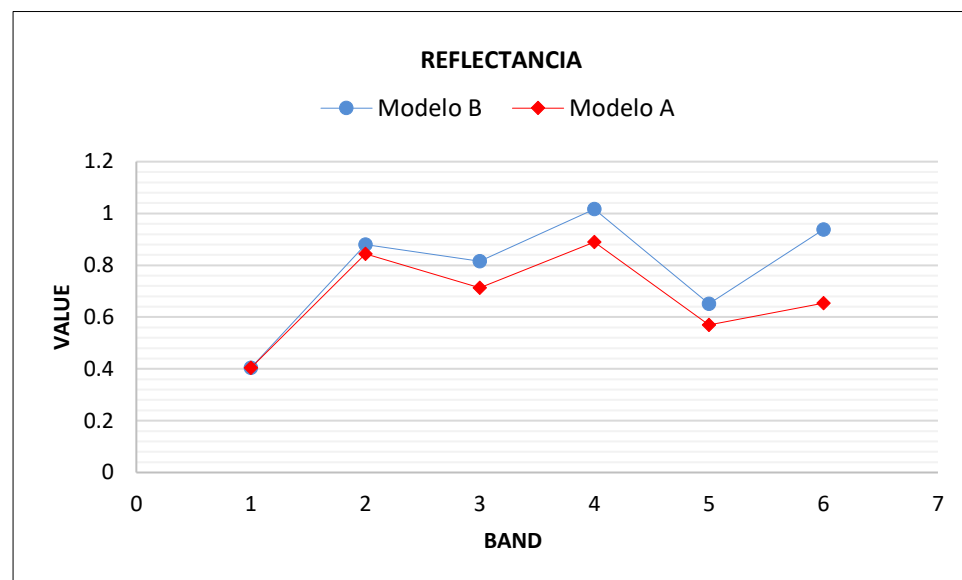


Nota. Datos obtenidos usando (modelo B) - escena 8_66 del año 1987. Elaboración propia.

En la Figura 36, se muestra un ejemplo de comparación de reflectancia en TOA corregido con el modelo A en línea color celeste y el modelo B en línea color rojo, se observa que la tendencia de la reflectancia de la superficie en cada banda es casi similar entre ambos modelos lo cual indica que ambos modelos son eficaces para la corrección radiométrica ya que nos otorgan valores entre los rangos establecidos para la reflectancia, también las firmas espectrales de los píxeles de las imágenes corregidas con ambos modelos.

Figura 36

Comparación de modelos en la distribución de la reflectancia TOA

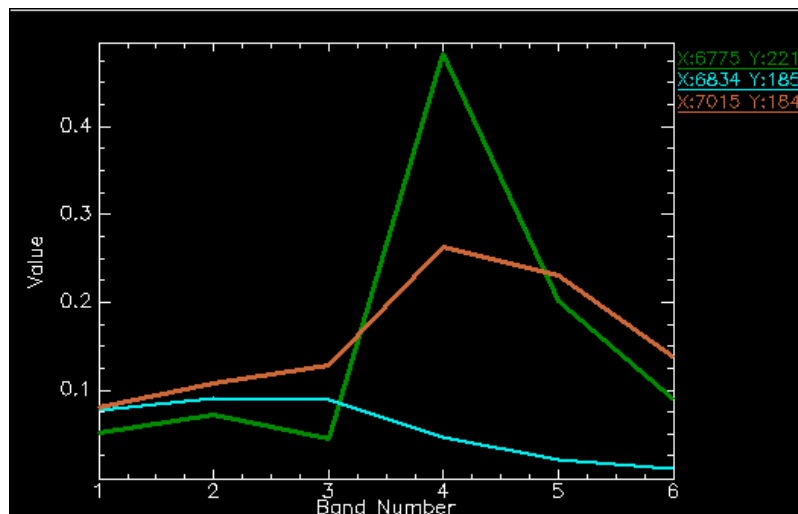


Nota. Se observa que los modelos utilizados son adecuados para representar y analizar la Reflectancia TOA en las diferentes bandas espectrales o tipos de superficie. Elaboración propia.

El comportamiento espectral de la superficie como se observa en la Figura 37 se refiere a cómo diferentes tipos de superficies que reflejan, absorben o transmiten la radiación electromagnética en función de la longitud de onda de la luz o la energía electromagnética incidente, esto nos permite identificar y caracterizar diferentes tipos de superficies y objetos que sus respuestas espectrales son únicas.

Figura 37

Comportamiento espectral de la superficie



Nota. Se observa que el comportamiento espectral responde correctamente a los patrones establecidos de las firmas espectrales de distintas coberturas. la curva espectral color verde para la vegetación, la curva espectral color naranja para suelo sin vegetación y la curva espectral color celeste para el agua. Elaboración propia.

Corrección atmosférica.

La corrección atmosférica refiere a la reducción de los errores de la atmosfera para obtener las imágenes en tonalidades más reales respecto al rango visible del espectro electromagnético y por lo tanto un adecuado comportamiento espectral.

- 24 imágenes Landsat 5TM han sido corregidas en niveles de reflectancia con los modelos A y B, a estas imágenes se le aplico la ecuación 2.8 para el cálculo de la corrección atmosférica se utilizó una plantilla Excel, la cual se muestra en la Figura 38, para obtener las ecuaciones de cada escena de los años 1987, 1997 y 2007.

Figura 38

Método del objeto oscuro, desarrollado por Chávez, J. (1988)

$P_{sup} = (d2 \pi (L \text{ sen} - L \text{ camin})) / t \text{ Esun} \cos \theta z$						
$d2 \pi$	3.228113177					
Elevación Solar	57.41501282					
Zenith Solar (θ)	32.58498718					
	B1	B2	B3	B4	B5	B7
Trasmisividad Descend (t)	0.7	0.78	0.85	0.91	1	1
ESUN	1983	1796	1536	1031	220	83.44
$\cos \theta$	0.680575732	0.68057573	0.680575732	0.68057573	0.68057573	0.68057573
$t \text{ Esun} \cos \theta z$	944.7071739	953.404932	888.559676	638.522958	149.726661	56.7872391

Nota. Los datos mostrados corresponden a la escena 8_66 del año 1987. Elaboración propia.

En la Tabla 15, se muestra las ecuaciones ingresadas en la calculadora de bandas del programa QGIS para la corrección atmosférica de cada escena usando las variables obtenidas de la plantilla Excel basada en el método de Chávez, J. (1988).

Tabla 15

Ecuaciones para el cálculo de la corrección atmosférica

Escena 8/66	Ecuaciones
Band 1	$((1.014^2) * 3.141 * (b1 - 22.408)) / (0.7 * 1983 * 0.681)$
Band 2	$(1.014^2) * 3.141 * (b2 - 11.397) / (0.78 * 1796 * 0.681)$
Band 3	$((1.014^2) * 3.141 * (b3 - 4.433)) / (0.85 * 1536 * 0.681)$
Band 4	$((1.014^2) * 3.141 * (b4 - 1.764)) / (0.91 * 1031 * 0.681)$
Band 5	$((1.014^2) * 3.141 * (b5 + 0.464)) / (1 * 220 * 0.681)$
Band 7	$((1.014^2) * 3.141 * (b7 + 0.176)) / (1 * 83.44 * 0.681)$

Nota. Datos de la escena 8_66 del año 1987. Elaboración propia.

- 8 imágenes Landsat 8 OLI del año 2017 han sido corregidas atmosféricamente utilizando plugin SCP del software open source QGIS donde se aplica la corrección atmosférica DOS 1 automáticamente.

Se aplico la corrección atmosférica a las 32 imágenes landsat de la siguiente manera (ver Tabla 16)

Tabla 16

Distribución de corrección atmosférica

CORRECCION ATMOSFERICA				
Escena	1987	1997	2007	2017
7_64				
7_65				
7_66				
8_64	Cálculo matemático - método de			Cálculo automático
8_65	Chávez (Plantilla Excel)			(PLUGIN SCP – QGIS)
8_66				
9_64				
9_65				

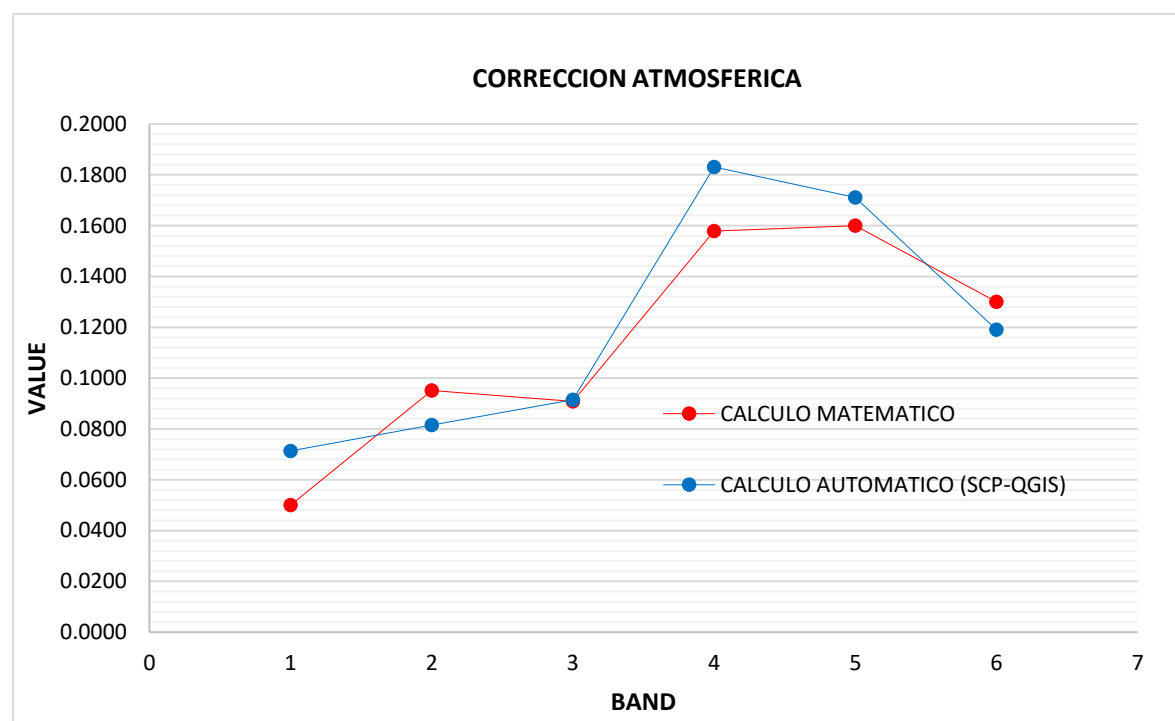
Nota. Elaboración propia.

Se realizo una comparación de los resultados obtenidos de la corrección atmosférica, la Figura 39 muestra la distribución por banda de los valores máximos de la corrección atmosférica, la línea roja pertenece a las imágenes corregidas con el método de Chávez, J. (1988), denominado cálculo matemático y la línea azul pertenece al cálculo automático con plugin SCP - QGIS, las dos líneas muestran una

distribución casi homogénea los rangos que se distinguen entre ellas son mínimos, los resultados generales de cada modelo nos entrega una alta satisfacción de valores óptimos requeridas en la corrección atmosférica.

Figura 39

Comparación de los resultados de la corrección atmosférica




Nota. Los resultados corresponden a la escena 8_66 de los años 2007 cálculo matemático (línea roja) y 2017 cálculo automático (línea azul). Elaboración propia.

En la Figura 40 se muestra un ejemplo visual del efecto atmosférico en la región visible, donde se observa la comparación entre una imagen en la que no se ha realizado la corrección atmosférica y una imagen en la que, si se ha corregido este efecto, podemos referir que la banda azul está más afectada por la atmósfera, de ahí el tono azulado en la imagen no corregida.

Figura 40

Comparación de las imágenes landsat8 composición en color natural RGB



Nota. Elaboración propia.

3.6.3 Etapa clasificación supervisada


La clasificación supervisada con (SVM = Support Vector Machines - Máquinas de Vectores de Soporte), es un proceso que está integrado en la interfaz en la OTB QGIS (Orfeo caja de herramientas) esta caja de herramientas contiene un conjunto de componentes algorítmicos, adaptados para imágenes multiespectrales de gran volumen, que permiten encontrar la forma óptima de clasificar entre varias clases.

Para el cálculo de áreas de bosque, no bosque, zonas deforestadas y tasas de deforestación en series de tiempo de 10 años utilizamos la clasificación supervisada usando el método SVM para un total de 32 imágenes Landsat (24 imágenes Landsat 5 TM y 8 imágenes Landsat 8 OLI) de los años 1987, 1997, 2007,2017.

Utilizaremos las 32 imágenes Landsat procesadas con nivel de corrección atmosférica, cada imagen contiene 7 bandas con el mismo rango de longitud de onda tanto para las Landsat 5 TM y Landsat 8 OLI, aplicando una misma combinación de bandas de RGB adecuado para la identificación y distinción de zonas como podemos observar en la Figura 41.

Figura 41

Combinación de bandas en falso color - RGB




Nota. Lado izquierdo imagen Landsat 5 TM del año 1987 combinación de bandas (NIR-MIR-RED) – 453 Lado derecho imagen Landsat 8 OLI del año 2017 combinación de bandas (NIR-MIR-RED) – 564, la combinación realizada con las bandas (NIR-MIR-RED) es sensible a la clorofila donde observamos las variaciones de la vegetación que aparecen en tonos rojos. Elaboración propia.

A continuación, describiremos los puntos más resaltantes para poder aplicar la clasificación supervisada:

- Elaboración de máscaras según el área de estudio para las escenas que forman el departamento de San Martín, este proceso tiene como objetivo garantizar el valor de pixel por banda agrupándolos en máscaras como valor único, en la Figura 42 muestra la máscara generada, donde el polígono en color blanco tiene valor uno y el contorno en color negro tiene valor cero.

Figura 42

Secuencia de generación de la máscara para la escena 8_66 del año 1987





Nota. Elaboración propia.

- Identificación de ocho clases de coberturas generales observables en la imagen satelital para cada path/row de cada año base, las regiones de interés (ROI's) generadas para cada clase deben estar distribuidos homogéneamente en las áreas de estudio correspondiente la Tabla 17 muestra las ocho clases definidas para la clasificación, en la Figura 43 se observa un área de la zona de estudio para la identificación y discriminación de áreas de interés específicas para la vectorización.
- La vectorización implica la identificación y delimitación de áreas de interés en una imagen satelital para convertirlas en datos vectoriales, como polígonos en un sistema de coordenadas geoespaciales.
- Respecto a la identificación y discriminación del área de estudio para la vectorización de áreas de interés específicas en imágenes satelitales, se aprovechó la herramienta de navegación Google Earth para explorar las imágenes satelitales donde se puede cambiar la perspectiva, acercarte o alejarte según la necesidad.

Tabla 17*Clases identificadas en el área de estudio*

Campo	Código de Clase
Bosque	10
Grass	21
Suelo Desnudo	22
Area Urbana	23
Agua	31
Sombra	41
Nube	42
Montaña	43

Nota. Elaboración propia.**Figura 43***Vectorización de las imágenes landsat***Identificación****Discriminación****Vectorización***Nota.* Elaboración propia.

- Pondremos en entrenamiento al clasificador SVM utilizando una imagen Landsat de entrada obtenemos un archivo estadístico de las características de la imagen Landsat. Utilizando el archivo estadístico y el Shapefile que contiene los ROI's obtendremos el modelo y la matriz de confusión del proceso de vectorización, el archivo modelo contiene la interpretación de las ecuaciones matemática del método SVM.

El método clasificador SVM fue aplicado a las 32 imágenes Landsat, los resultados obtenidos del entrenamiento son dos productos:

- Producto 1: El valor cuantitativo denominado índice kappa que nos indica la concordancia entre las clases, dicho de otra manera, es la precisión de la clasificación.
- Producto 2: La imagen de clasificación (mapa de clasificación por clase).

3.6.3.1 Precisión de la clasificación. Primer producto, La Figura 44 muestra la distribución del índice kappa por escena para los cuatro años base (1987-1997-2007-2017) donde se observa que el valor mínimo es 0.89% para la escena (9_65) del año 2017 y el valor máximo es 0.99% para la escena (8_66) del año 2007.

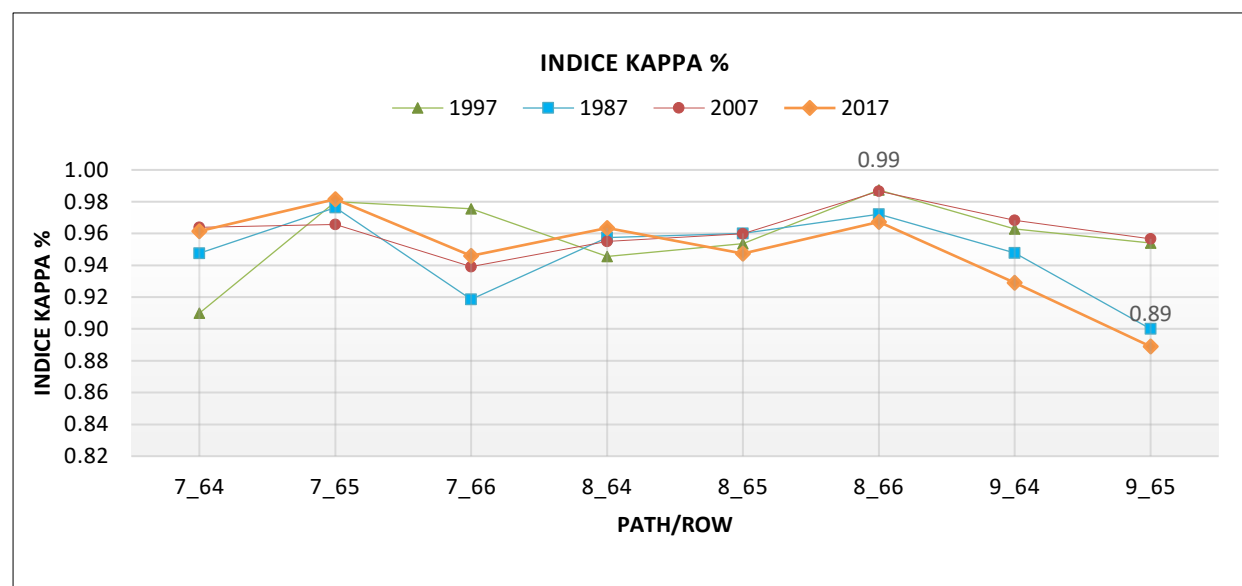
El valor mínimo resultante se da por dos motivos:

- El proceso de identificación de áreas para su vectorización no fue la más óptima porque el área de estudio presenta alta gamma de efectos de nubosidad.
- La cantidad de áreas vectorizadas por clase no son lo suficientemente necesarias para aplicar el método SVM.

El valor máximo obtenido nos indica que las condiciones de identificación de áreas y la cantidad de vectores digitalizados fueron las suficientemente necesarias para la precisión del SVM, este punto se observa en la Tabla 18 donde muestra la matriz de confusión generada durante el entrenamiento del método clasificador SVM que nos indica la cantidad correcta de áreas identificadas denominado error de omisión y la cantidad de áreas de una clase fuera de las clases denominado error de comisión, la cantidad de puntos a vectorizar obedecen a una ecuación lineal proporcional al área del estudio y al tamaño del pixel de la imagen.

Figura 44

Distribución del índice kappa por escena y año



Nota. Los resultados obtenidos se sitúan en la escala de valoración (0,81-1,00) de acuerdo con Landis y Koch (1977), esta escala indica un grado de acuerdo casi perfecto. Elaboración propia.

Tabla 18

Matriz de confusión de la escena 8_66 del año 2007 con índice kappa de 0.99%

		#REFERENCE LABELS (ROWS)								Σ
		Clase	10	21	22	23	31	41	42	
#PRODUCED LABELS (COLUMNS)	10	339	1	0	0	0	1	0	0	341
	21	0	351	5	0	0	0	0	0	356
	22	0	1	297	2	0	0	0	0	300
	23	0	0	16	318	0	0	0	0	334
	31	0	0	2	0	299	0	0	0	301
	41	0	0	0	0	0	302	0	0	302
	42	0	0	0	0	0	0	313	0	313
	43	0	0	0	0	0	0	2	311	313
		339	353	320	320	299	303	315	311	2560

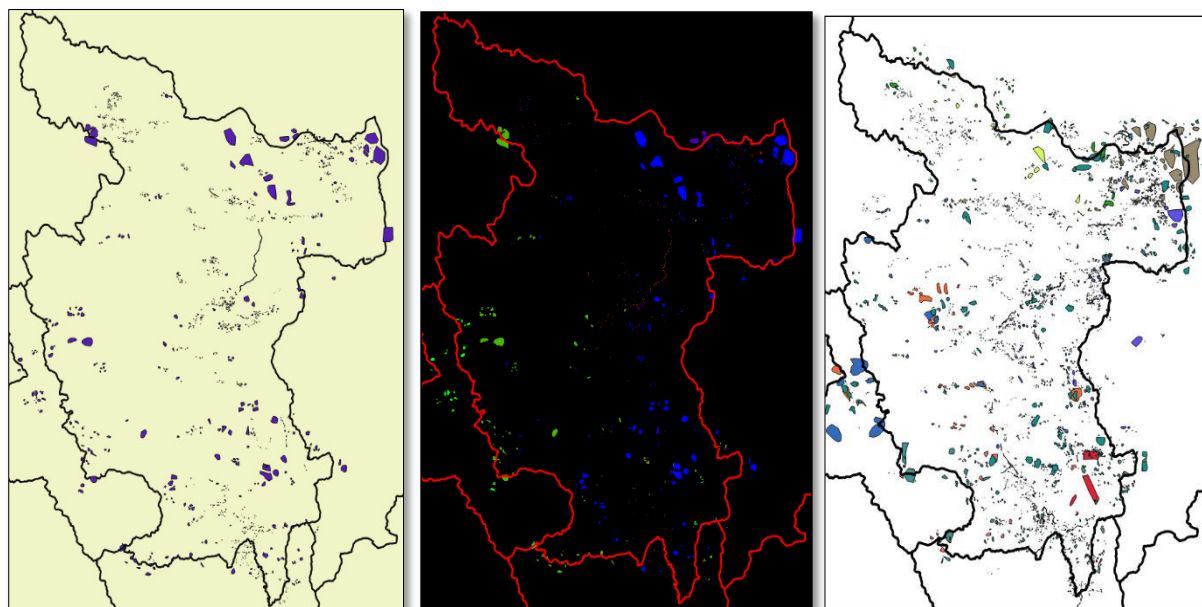
Nota. Se obtuvieron un total de 32 matrices de confusión que correspondían a cada escena de cada año, a modo de muestra del resultado de la matriz se coloca la matriz de la escena 8_66. Elaborado propia.

La Figura 45 muestra graficamente la distribucion total de los ROI's generados por clase para el Departamento de San Martin, este proceso de aplico a los cuatro mosaico que corresponden a los años 1987, 1997, 2007 y 2017, informacion obtenida del proceso de exactitud global con SCP.

El Semi-Automatic Classification Plugin (SCP) es un plugin de codigo abierto para QGIS que permite la clasificacion semiautomatica supervisada de imagenes satelitales y ofrece herramientas para el calculo de la exactitud global de la clasificacion.

Figura 45

Distribución total de los roi's generados por clase



Nota. Se observa la distribución total de las regiones de interés identificadas en la zona de estudio para el año 2017, de la misma manera se realizó para los años 1997, 2007 y 2017 información obtenida del proceso de exactitud global con el Plugin (SCP). Elaboración propia.

La exactitud global de clasificación se expresa como el porcentaje de píxeles clasificados correctamente. Se realizó la evaluación de la exactitud que requiere del muestreo de un número estadísticamente significativo de píxeles identificados homogéneamente en el área de estudio.

La evaluación de la exactitud global de la clasificación de coberturas es útil para identificar los errores de mapas, se ejecutó el interfaz SCP de QGIS como resultado se obtuvo el cálculo de la de la exactitud global de clasificación ver Tabla 19.

Tabla 19*Resultados de la exactitud global de la clasificación*

Año	Exactitud Global [%]
1987	94
1997	90
2007	96
2017	96

Nota. Los porcentajes resultantes indican una alta exactitud global por cada mosaico del área de estudio, Información obtenida del proceso de exactitud global con el Plugin (SCP). Elaboración propia.

Respecto al algoritmo utilizado, la precisión del productor nos mide que tan bien el algoritmo clasifico la muestra que realmente pertenecen a cada clase, ver Tabla 20.

Tabla 20*Precisión del productor*

Clase	Precisión del productor [%]
10	98.16
21	95.84
22	75.74
23	81.68
31	90.90
41	78.27
42	83.39
43	93.74
44	68.70

Nota. El resultado pertenece al año 1987, Información obtenida de los cálculos de la matriz de confusión.

Elaboración propia.

Asimismo se midió la precisión del usuario que se enfoca en la precisión con la que el algoritmo clasifica las muestras como pertenecientes a una clase específica desde la perspectiva del usuario, ver Tabla 21.

Tabla 21

Presición del usuario

Clase	Precisión del Usuario [%]
10	98.29142276
21	66.19414412
22	91.05660995
23	40.23796647
31	92.35950294
41	74.75126172
42	91.92334632
43	89.07385064
44	60.37247163

Nota. El resultado pertenece al año 1987, Información obtenida de los cálculos de la matriz de confusión.

Elaboración propia.

3.6.3.2 Imagen clasificada. El segundo producto del método SVM es la imagen clasificada la Figura 46 muestra a detalle la clasificación obtenida con el método SVM, se observa que las áreas urbanas identificadas en las imágenes Landsat 8 OLI RGB 564 de color celeste en la imagen clasificada es color rosado, las áreas deforestadas se muestran en color verde en la imagen Landsat y en la clasificada son color

rojas, el río que atraviesa la imagen se muestra en color oscuro y en la clasificación se puede apreciar en color azul, siendo así una clasificación coherente a los patrones de identificación establecidos.

Figura 46

Comparación de áreas clasificadas



Imagen Google satellite




Imagen Landsat RGB






Imagen clasificada método SVM

Nota. Elaboración propia.

Un aspecto crucial a considerar es la influencia de la morfología del terreno en la selva alta, la cual se caracteriza mayormente por presentar cobertura nubosa, tal como se aprecia en la Figura 47. Además, la topografía, la presencia de nubes y las sombras contribuyen a la ocultación de información, lo que dificulta la tarea de clasificación y puede afectar la precisión de los resultados finales en cuanto a la distinción entre áreas boscosas y no boscosas.

Figura 47

Identificación de coberturas nubosas



Nota. Se presentan los resultados de la clasificación SVM aplicada a la escena 8_65 del año 2007. En la imagen de la izquierda, se muestra la combinación de bandas RGB 543, mientras que en la imagen de la derecha se exhibe la imagen clasificada. En esta última, es posible notar que las estructuras de nubes están representadas en tonos de color celeste. Elaboración propia.

Para concluir con los procedimientos realizados en este estudio de investigación, se le aplicara el proceso de filtrado a las imágenes clasificadas, este filtrado tiene como propósito eliminar pequeños grupos de píxeles que carecen de significado, y el umbral para llevarlo a cabo se denomina UMM (Unidad Mínima de Mapeo), el cual se calcula mediante la ecuación 2.14.

La unidad mínima de mapeo se refiere a la mínima superficie (ha) de una unidad de vegetación que se puede determinar al realizar el proceso de interpretación de las imágenes satelitales.

$$UMM = \frac{\text{tamaño mínimo de la unidad muestral}}{\text{area del pixel}} \dots\dots\dots (2.14)$$

Luego se elabora los mosaicos y obtenemos los mapas de deforestación para los años 1987, 1997, 2007 y 2017 como se muestra en la Figura 48.

3.7 Análisis de datos

El análisis de datos se llevó a cabo en las etapas de procesamiento y clasificación supervisada. En este proceso, se destacó que los resultados obtenidos se encuentran dentro de los rangos óptimos en términos de exactitud global y coeficiente Kappa, garantizando una exitosa clasificación. Los resultados de la clasificación supervisada se presentan en forma de mapas utilizando el software QGIS, lo que permitió visualizar claramente los cambios en la cobertura forestal para los años 1987, 1997, 2007 y 2017.

Además, se proporcionan gráficos elaborados en Excel que resumen de manera concisa la evolución y la tasa de la deforestación en el Departamento de San Martín durante el período estudiado.

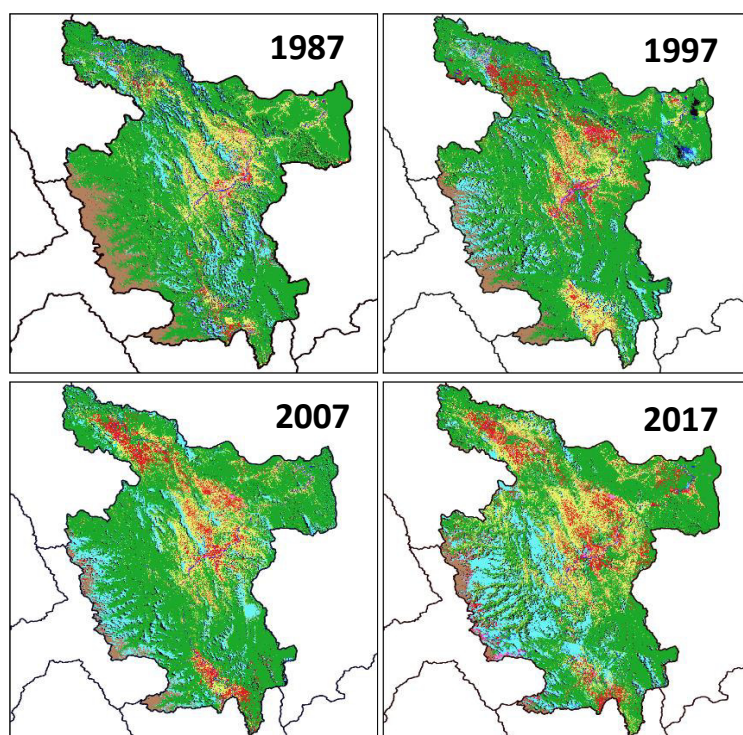
Para complementar la presentación de resultados, se incluyen tablas estadísticas elaboradas en Excel que contienen los cálculos de las áreas y porcentajes de cobertura forestal. Estas tablas brindan datos precisos y cuantitativos que respaldan el análisis cualitativo y visual de los cambios en la cobertura forestal.

IV. RESULTADOS

Los resultados, detallados en la Figura 48 y ampliados en los Anexos D, E, F y G, proporcionan información valiosa sobre la evolución de la cobertura forestal en el Departamento de San Martín a lo largo de las últimas tres décadas. La interpretación de estos mapas de deforestación desempeña un papel esencial en la comprensión de la dinámica de cambio en la cobertura forestal. Además, permite la identificación de áreas críticas que demandan atención y orienta las futuras acciones de conservación y gestión forestal.

Figura 48

Mapas de deforestación del departamento de San Martín



Nota. En los mapas se observa que el color rojo representa las áreas deforestadas, el color verde indica superficie cubierta de bosque, el color celeste corresponde a áreas con cobertura nubosa, y el color amarillo representa superficie de grass. Elaboración propia.

A partir de los mapas de deforestación, se llevó a cabo un proceso de cálculo para determinar las áreas deforestadas en hectáreas utilizando el método SVM, lo que resultó en la generación de un reporte de clasificación detallado que presenta las áreas finales correspondientes a las diversas coberturas.

Es importante destacar que los resultados de clasificación están vinculados a la estación en la que se capturaron las imágenes. En consecuencia, es fundamental que las imágenes de entrada se adquieran durante el mismo período temporal para evitar discrepancias ocasionadas por las variaciones en el estado fenológico de la vegetación o los cambios en la cobertura terrestre. La Tabla 22, 23, 24 y 25 proporciona un informe de clasificación para cada año de estudio, en el que se detallan el recuento de píxeles, el área y el porcentaje correspondiente a cada clase de cobertura.

Tabla 22

Reporte de clasificación de mapa de deforestación - año 1987

Clase	Cod.Clase	PixelSum	Porcentaje %	Área (ha)
Bosque	10	33595472	59.38	3023852.60
Grass	21	7326066	12.95	726657.17
Deforestación	22	1595058	2.82	143567.57
Area Urbana	23	728726	1.29	65590.98
Agua	31	1287197	2.28	115857.70
Sombra	41	3180204	5.62	286242.98
Nube	42	4827443	8.53	434507.25
Montaña	43	4036333	7.13	363301.22

Nota. Datos calculados con el método SVM. Elaboración propia.

Tabla 23*Reporte de clasificación de mapa de deforestación año 1997*

Clase	Cod.Clase	PixelSum	Porcentaje %	Área (ha)
Bosque	10	34262468	60.52	3082781.19
Grass	21	6693698	11.82	602268.53
Deforestación	22	3211875	5.67	288989.92
Área Urbana	23	453523	0.80	40805.94
Agua	31	1263037	2.23	113642.33
Sombra	41	2980038	5.26	268130.28
Nube	42	5281894	9.33	475240.82
Montaña	43	2470454	4.36	222280.23

Nota. Datos calculados con el método SVM. Elaboración propia.

Tabla 24*Reporte de clasificación de mapa de deforestación año 2007*

Clase	Cod.Clase	PixelSum	Porcentaje %	Área (ha)
Bosque	10	33477500	59.15	3012394.79
Grass	21	7457610	13.18	671055.65
Deforestación	22	3707403	6.55	333602.02
Área Urbana	23	196390	0.35	17671.70
Agua	31	553992	0.98	49849.68
Sombra	41	2453042	4.33	220731.27
Nube	42	7109681	12.56	639748.07
Montaña	43	1637505	2.89	147347.07

Nota. Datos calculados con el método SVM. Elaboración propia.

Tabla 25*Reporte de clasificación de mapa de deforestación año 2017*

Clase	Cod.Clase	PixelSum	Porcentaje %	Área (ha)
Bosque	10	27232878	48.13	2451459.85
Grass	21	10248207	18.11	922527.10
Deforestación	22	4908563	8.67	441860.94
Área Urbana	23	675938	1.19	60846.85
Agua	31	630545	1.11	56760.65
Sombra	41	2838234	5.02	255493.26
Nube	42	8880242	15.69	799385.09
Montaña	43	1169593	2.07	105284.88

Nota. Datos calculados con el método SVM. Elaboración propia.

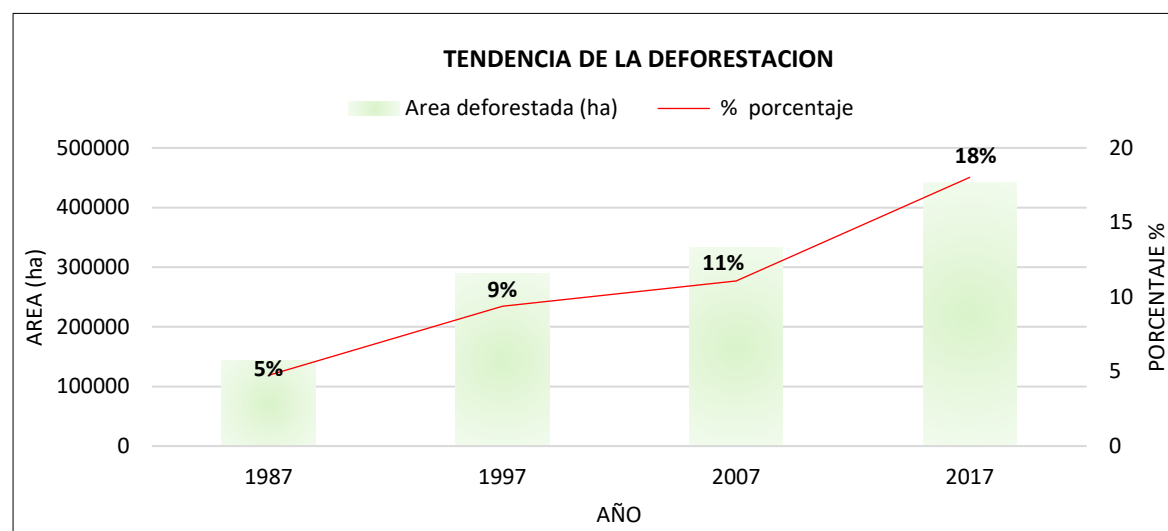
La Figura 49 presenta los reportes de clasificación que ilustran la tendencia de la deforestación en los años 1897, 1997, 2007 y 2017. Se observa claramente que el año 2017 experimentó la máxima cifra de deforestación, como lo indica la tendencia ascendente de la línea a lo largo del periodo en estudio. Para ofrecer una perspectiva más detallada, en 1987 se identificó una superficie deforestada de 143,567.5698 hectáreas, equivalente al 5% del área total. Diez años después, en 1997, esta cifra aumentó a 288,989.9183 hectáreas, representando el 9% del total. Otros diez años después, en 2007, la superficie deforestada continuó creciendo, alcanzando las 333,602.0157 hectáreas, que corresponden al 11% de área total deforestada. Finalmente, para el año 2017, se registró un brusco incremento en la superficie deforestada,

llegando a 441,860.9413 hectáreas, lo que representa el 18% de área total deforestada, estos valores expresan el porcentaje de cambio de la vegetación por año de estudio.

Al examinar las estadísticas presentadas en los mapas de deforestación, que se muestran en la Figura 48 y se expresan en forma de porcentaje es posible concluir que los resultados obtenidos resultan sumamente sugerentes ya que permiten verificar localmente donde y como se han ido dando los cambios de cobertura a lo largo del tiempo.

Figura 49

Tendencia de la deforestación para el departamento de san martin



Nota. Se observa un aumento continuo en la deforestación a lo largo del período estudiado (1987-2017), con un aumento más pronunciado en los últimos años. Esto indica un patrón preocupante de pérdida de cobertura forestal en la región. Elaboración propia.


Se aplicó el proceso de reclasificación a los mapas de deforestación con el objetivo de generar mapas distintivos de áreas boscosas y no boscosas, al mismo tiempo que se permitió la eliminación de nubes y sombras según el año de estudio. Respecto a esta eliminación de nubes y sombras, se presenta una

comparación visual en la Figura 50, mostrando una superposición entre la imagen original y la imagen resultante de la reclasificación. En esta representación, las nubes aparecen en blanco y las sombras en negro, siendo estas áreas vacías como se detalla en la Figura 51. Este proceso de eliminación es crucial para obtener una representación precisa de las zonas de bosque y no bosque, al excluir las interferencias de nubes y sombras en los datos. Los mapas resultantes servirán para generar mapas que reflejarán los cambios en la cobertura a lo largo de las series temporales (1987-1997, 1997-2007, 2007-2017). Estos mapas de cambio de cobertura proporcionarán una visión clara y detallada de cómo ha evolucionado la región en términos de su cobertura boscosa y no boscosa a lo largo de estas décadas específicas.

El proceso de reclasificación del mapa de entrada se basa en las reglas predefinidas para las clases. Como se muestra en la Figura 51, se aplican estas reglas en cada mapa para obtener los mapas de bosque y no bosque, al mismo tiempo que eliminan las áreas con nubes y sombras, asignándoles un valor de cero (0). Esto se hace con el propósito de que estas áreas no se incluyan en el proceso de generación de los mapas de cambio de cobertura en las series temporales.

Figura 50


Eliminación de nubes y sombras



Nota. Una vez identificadas las áreas de nubes y sombras, las eliminamos de la imagen, de modo que no interfiera con el análisis posterior. Elaboración propia.

Figura 51

Mapas de bosque y no bosque del departamento de San Martín



Nota. Se observa que las áreas en color verde representan superficies boscosas, las áreas en color amarillo indican superficies no boscosas y las áreas en color negro representan superficies cubiertas por nubes y sombras, que se consideran sin valor. Elaboración propia.


En la Tabla 26, se presenta un reporte estadístico que detalla la superficie total de áreas boscosas y no boscosas en los mapas correspondientes. También se proporciona información sobre la superficie cubierta por nubes en cada año, como se ilustra en la Figura 52. Es interesante notar que, en el año 2017, a pesar de que las escenas seleccionadas para este período se tomaron durante épocas secas y dentro del mismo rango de tiempo que las de otros años de estudio, se observa una mayor cantidad de superficie nubosa. Esta situación puede impactar la precisión de la estimación de áreas boscosas y no boscosas, ya que la presencia de nubes puede ocultar o distorsionar las características de la superficie terrestre, afectando así la precisión de las mediciones. Este factor debe ser tenido en cuenta al interpretar los resultados y puede requerir medidas adicionales en el análisis de datos para corregir posibles sesgos causados por la presencia de nubes en las imágenes.

Tabla 26

Reporte de la reclasificación de mapa bosque y no bosque

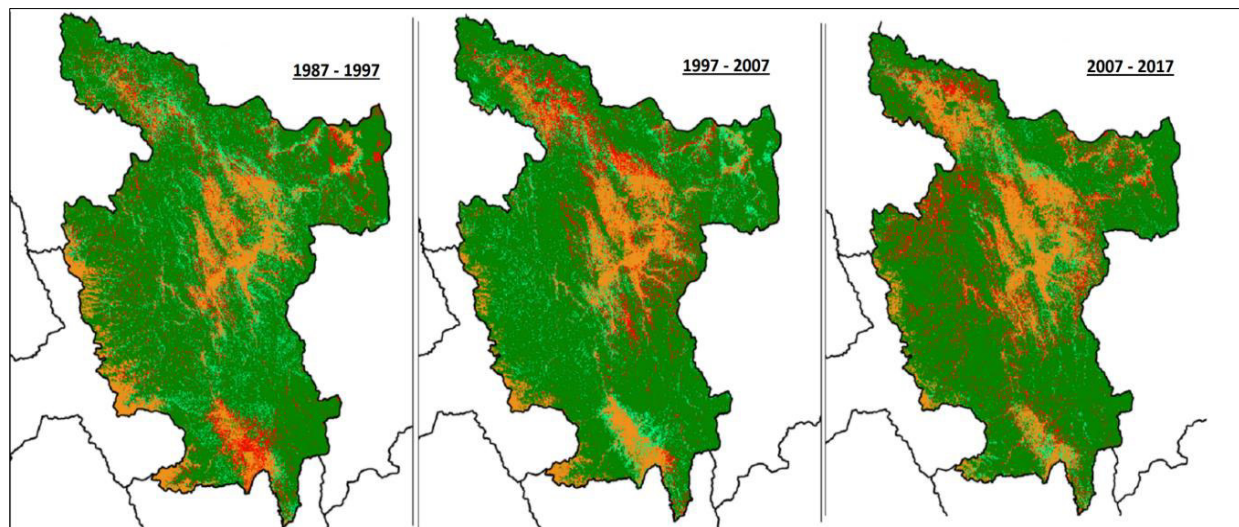
Año	Cod.Clase	PixelSum	Porcentaje %	Área (ha)	Clase
1987	1	34075342	68.93	3067044.61	bosque
	2	15362354	31.07	1382730.80	no bosque
1997	1	34959397	70.87	3145487.69	bosque
	2	14366741	29.13	1292654.08	no bosque
2007	1	34190407	71.48	3076544.06	bosque
	2	13644754	28.52	1227791.38	no bosque
2017	1	27696941	60.96	2493234.05	bosque
	2	17737945	39.04	1596741.26	no bosque

Nota. Elaboración propia.

Figura 52*Cantidad de cobertura nubosa y sombra*

Nota. Se puede observar las áreas en las que las condiciones atmosféricas, como nubes y sombras, impidieron la captura de datos precisos de cobertura terrestre en los mapas de bosque y no bosque. Elaboración propia.

Finalmente, aplicamos el plugin SCP – Land Cover Change a los mapas de bosque y no bosque, lo que generó los mapas de cambio de cobertura del suelo en las series temporales (1987 – 1997, 1997 – 2007, 2007 - 2017), como se muestra en la Figura 53. Para detalles ver los Anexos H, I y J.

Figura**53***Mapas de cambio de cobertura del suelo*

Nota. En los mapas de series de tiempo (1987 – 1997, 1997 – 2007, 2007 - 2017) se observa que cada color representa una clase de cobertura diferente, y los cambios en la cobertura a lo largo del tiempo son claramente visibles. El color verde oscuro representa las áreas de cobertura boscosa, el color rojo indica la superficie deforestada, el color verde claro corresponde a las áreas reforestadas, y el color naranja representa las áreas estables como zonas urbanas que denominaremos áreas de no bosque. Elaboración propia.

Los mapas de cambio de cobertura del suelo obtenidos son el resultado de la comparación entre dos mapas de bosque y no bosque de distintos periodos con el fin de evaluar los cambios de la cubierta terrestre, donde cada pixel presenta una categoría de comparación.

Los resultados obtenidos del cambio de cobertura del suelo en el periodo de 1987 - 2017 sugiere una nueva interpretación como se muestra en la Tabla 27 y los resultados son una matriz de cambio y un reporte de la cuantificación del área en los mapas de cambio de cobertura de suelo para las tres series de tiempo establecidas como se observa en la Tabla 28.

Tabla 27*Interpretación de las nuevas clases resultantes*

Código	Clase	Clase	Descripción
resultante	Referencia	Nueva	
1	1 bosque	1 bosque	No cambia - bosque estable (bosque)
2	1 bosque	2 no bosque	Deforestación
3	2 no bosque	1 bosque	Volvió a crecer (reforestación)
4	2 no bosque	2 no bosque	Áreas estables sin bosque (no bosque)

Nota. La cobertura boscosa se representa en color verde con código (1), la superficie deforestada en color rojo con código (2), las áreas reforestadas el color verde claro con código (3), y las áreas estables como zonas urbanas en el color naranja con código (4). Elaboración propia.

Tabla 28*Reporte de la matriz de cambio*


Periodo	Código	Clase	Clase	Área (ha)		
	resultante	Referencia	Nueva	PixelSum	Porcentaje %	
1987 - 1997	1	1	1	25346343	57.92	2280548.77
	2	1	2	4934541	11.28	443987.58
	3	2	1	5299956	12.11	476865.96
	4	2	2	8180382	18.69	736033.6
1997 - 2007	1	1	1	26244411	60.18	2361352.85
	2	1	2	4932915	11.31	443841.28
	3	2	1	4434368	10.17	398984.28
	4	2	2	7996820	18.34	719517.53
2007 - 2017	1	1	1	21816594	54.12	1963115.35
	2	1	2	6163761	15.29	554631.66
	3	2	1	2656321	6.59	239022.85
	4	2	2	9677510	24.01	870808.18

Nota. Se muestra el reporte de cambios en la cobertura del suelo expresado en hectáreas para las tres series de tiempo. De esta manera podemos interpretar cuantitativamente las áreas de los cambios globales de cobertura del suelo, así como las ganancias y pérdidas de cada clase entre los periodos definidos. Elaboración propia.

Los datos registrados en la Tabla 28 muestra los cambios positivos y negativos de la cobertura de suelo en las últimas 3 décadas vemos que la vegetación en el departamento de San Martín se ha incrementado de 2280548.77 ha en el periodo (1987 - 1997) a 2361352.85 ha en el periodo (1997 - 2007) y en el periodo (2007 - 2017) sufrió una decrecimiento a 1963115.35 ha esta reducción de superficie boscosa se puede dar por el incremento de la deforestación o por el aumento de las áreas urbanas, interpretamos también que la cuantificación de la deforestación en el periodo (1987 - 1997) es de 443987.58 ha y en el periodo (1997 - 2007) es de 443841.28 ha, a pesar de haber pasado una década entre estos periodos la deforestación fue mínima, decreció 146.30 ha, esto se debe que las escenas seleccionadas para la parte de selva baja del área de estudio hay mayor cantidad de superficie nubosa que oculta datos cuantificables, sin embargo se deduce que entre estas dos décadas la deforestación en general no tubo rangos elevados, la deforestación para el periodo (2007 - 2017) es de 554631.66 ha, en comparación de las últimas dos décadas ha sufrido un desmesurado incremento, se observa también que la reforestación en las últimas tres décadas su cuantificación ha ido decreciendo esto indica que los pastizales, grass, áreas de cultivo, etc, han ido en disminución esta tendencia se relaciona directamente con el sector agrícola que se ha visto dañado en las últimas décadas, dentro de las áreas estables sin bosque se encuentran las áreas urbanas, lagos, ríos, etc, donde en el periodo (1987 - 1997) es de 736033.60 ha y en el periodo (1997 - 2007) es de 719517.53, se aprecia una disminución somera, cabe resaltar que en esta categoría el crecimiento sería por el aumento de áreas urbanas o por el desborde de los ríos o nuevos canales de agua como se muestra en el periodo (2007 - 2017) teniendo un valor de 870808.18 ha, la descripción realizada se ilustra esquemáticamente en la Figura 54.

Figura 54

Ilustración esquemática del cambio de cobertura del suelo



Nota. La ilustración correspondiente a las series de tiempo (1987 – 1997, 1997 – 2007, 2007 - 2017) del Departamento de San Martín permite visualizar de cómo ha evolucionado la cobertura terrestre a lo largo del tiempo, identificando cambios como la deforestación, la reforestación, la expansión urbana y otros procesos relevantes. Esta herramienta es fundamental para comprender y comunicar las tendencias de uso de la tierra. Elaboración propia.


Finalmente se calculó la tasa de deforestación (%) que se refiere a la medida de la pérdida de cobertura forestal, Esta métrica es fundamental para evaluar el ritmo al que los bosques están siendo degradados o destruidos en nuestra área de estudio, nos proporciona información valiosa sobre desafíos de conservación que enfrenta el Departamento de San Martín.

Los datos mostrados en la Figura 55 revela una progresión constante de la deforestación, destacándose un marcado incremento en el periodo 2007 - 2017. Esta tendencia refleja la creciente presión

sobre los recursos forestales y subraya la necesidad de implementar medidas de conservación y gestión sostenible para revertir este preocupante patrón.

Figura 55

Tasa de deforestación



Nota. Se muestra la evolución de la tasa de deforestación en el Departamento de San Martín durante tres períodos clave: 1987-1997, 1997-2007 y 2007-2017. Durante estos años, observamos tasas de deforestación del 14%, 15% y 18%, respectivamente. Estos porcentajes representan la proporción de pérdida de cobertura forestal en relación con la superficie forestal inicial al comienzo de cada período. Elaboración propia.

V. DISCUSIÓN DE RESULTADOS

En el estudio de investigación se propuso como objetivo general cuantificar y analizar la variación de la deforestación durante el periodo 1987 - 2017 en el Departamento de San Martín. En este sentido mediante el método clasificador SVM - Support Vector Machines, se logró desarrollar mapas de deforestación para los años 1987, 1997, 2007 y 2017 donde podemos observar la dinámica de cambio de la cobertura forestal e información cuantitativa del área deforestada para el año 1987 se identificó una superficie deforestada de 143,567.6 ha, equivalente al 5% del área total. Diez años después, en 1997, esta cifra aumentó a 288,989.9 ha, representando el 9% del total. Otros diez años después, en 2007, la superficie deforestada continuó creciendo, alcanzando las 333,602.0 ha, que corresponden al 11% del área total. Finalmente, para el año 2017, se registró un brusco incremento de la superficie deforestada, llegando a 441,860.9 ha, lo que representa el 18% de área total deforestada. Esto indica un patrón preocupante de pérdida de cobertura forestal en la región.

También se obtuvo los mapas de cambio de cobertura del suelo en las series temporales (1987 – 1997, 1997 – 2007, 2007 - 2017). Estos mapas son herramientas fundamentales para evaluar y comprender la dinámica de la deforestación, estos mapas nos proporcionan una representación visual y cuantitativa de cómo ha evolucionado la cobertura del suelo a lo largo de las tres décadas. Nos permiten identificar áreas que han experimentado cambios significativos, como la deforestación y reforestación. Los resultados obtenidos nos muestra los cambios positivos y negativos de la cobertura de suelo en las últimas 3 décadas se observa que la cobertura forestal en el departamento de San Martín se ha incrementado de 2280549 ha en el periodo (1987 - 1997) a 2361353 ha en el periodo (1997 - 2007) y en el periodo (2007 - 2017) sufrió un decrecimiento a 1963115 ha esta reducción de superficie boscosa se puede dar por el incremento de la deforestación o por el aumento de las áreas urbanas y expansión agrícola , interpretamos también que la

cuantificación de la deforestación en el periodo (1987 - 1997) es de 4439878 ha y en el periodo (1997 - 2007) es de 443841 ha, a pesar de haber pasado una década entre estos periodos la deforestación fue mínima, decreció 146 ha, esto se debe que las escenas seleccionadas para la parte de selva baja del área de estudio hay mayor cantidad de superficie nubosa que oculta datos cuantificables, sin embargo se deduce que entre estas dos décadas la deforestación en general no tubo rangos elevados, la deforestación para el periodo (2007 - 2017) es de 554632 ha, en comparación de las últimas dos décadas ha sufrido un desmesurado incremento, se observa también que la reforestación en las últimas tres décadas su cuantificación ha ido decreciendo esto indica que los pastizales, grass, áreas de cultivo, etc, han ido en disminución esta tendencia se relaciona directamente con el sector agrícola que se ha visto dañado en las últimas décadas, dentro de las áreas estables sin bosque se encuentran las áreas urbanas, lagos, ríos, etc, donde en el periodo (1987 - 1997) es de 736034 ha y en el periodo (1997 - 2007) es de 719518 ha, se aprecia una disminución somera, cabe resaltar que en esta categoría el crecimiento sería por el aumento de áreas urbanas o por el desborde de los ríos o nuevos canales de agua como se muestra en el periodo (2007 - 2017) teniendo un valor de 870808 ha, para este último periodo un valor elevado corroborando lo descrito en la sección antecedes de esta investigación, en el Departamento de San Martín, la tala ilegal de árboles representa una de las principales preocupaciones, provocando un impacto significativo en la cubierta forestal de la región. Los hallazgos de la investigación indican que esta actividad ha sido una causa importante de la deforestación observada entre 1987 y 2017. La tala ilegal de árboles es un problema complejo que va más allá de la simple pérdida de recursos naturales; también conlleva consecuencias ambientales negativas, como la degradación del suelo, la pérdida de hábitats y la alteración de los ecosistemas. Además, tiene implicaciones económicas y sociales, afectando a las comunidades que dependen de los recursos forestales para su subsistencia.

Además, los mapas de cambio de cobertura del suelo obtenidos nos brindan una base sólida para calcular y analizar la tasa de deforestación durante los períodos 1987-1997, 1997-2007 y 2007-2017, lo que

contribuye a evaluar el impacto ambiental y las tendencias en la pérdida de bosques en el Departamento de San Martín. La tasa de deforestación ha experimentado un aumento constante a lo largo de estos tres períodos. Comenzó en un 14% en la década de 1987-1997 y aumentó al 15% en la década siguiente (1997-2007). El período más reciente (2007-2017) muestra un aumento significativo en la tasa de deforestación, llegando al 18%. Esta tendencia al alza sugiere un problema creciente de pérdida de cobertura forestal en la región. El hecho de que la tasa de deforestación haya aumentado más rápidamente en el último período (2007-2017) en comparación con los dos períodos anteriores indica una aceleración en la pérdida de bosques durante los últimos años. Esto puede ser motivo de preocupación debido a los impactos ambientales negativos que conlleva. Un aumento constante en la tasa de deforestación sugiere una creciente presión sobre los recursos forestales en el Departamento de San Martín. Puede ser el resultado de actividades como la tala ilegal, la expansión agrícola no sostenible o el desarrollo urbano no planificado, entre otros factores.

De acuerdo con la escala de valoración de Landis y Koch (1977), ampliamente empleada para evaluar la concordancia en procesos de clasificación, este estudio logró índices kappa en un rango de (0,81-1,00) para los años 1987, 1997, 2007 y 2017. Estos resultados, indicativos de una excelente concordancia, sugieren que los métodos de clasificación empleados son sumamente precisos y confiables. Esta información es esencial para tomar decisiones fundamentadas en relación con la gestión forestal y la conservación ambiental en el Departamento de San Martín.

En este estudio las imágenes satelitales landsat seleccionadas corresponden a épocas secas en la región y dentro del mismo rango de tiempo, se toma esta medida con el fin de evitar discrepancias ocasionadas por las variaciones en el estado fenológico de la vegetación, los cambios en la cobertura terrestre y sobre todo el tema de la cobertura nubosa. Esto implicó el uso de técnicas de corrección atmosférica como las del cálculo matemático y las del cálculo automático para minimizar los efectos de la

dispersión de la luz en la atmósfera, lo que puede hacer que las nubes sean menos opacas. Sin embargo, para el año 2017 se observa mayor cantidad de superficie nubosa en comparación con los otros años de estudio que se muestran despejados de nubes, pues la presencia de nubes oculta y distorsiona las características de la superficie terrestre, afectando así la precisión de las mediciones.

VI. CONCLUSIONES

- En el proceso de monitoreo, se logró medir y analizar de forma eficaz la variación en la deforestación en el Departamento de San Martín durante el período de investigación de 1987 a 2017. Los mapas que representan los cambios en la cobertura del suelo proporcionaron una visión detallada de este fenómeno. Durante el lapso de estudio (1987-2017), se identificó una inquietante tendencia al aumento de la deforestación en el Departamento de San Martín.
- Este estudio validó de manera efectiva la aptitud de las imágenes satelitales Landsat para analizar la deforestación en la zona. La accesibilidad gratuita a estas imágenes y sus atributos temporales, radiométricos, espectrales y espaciales jugaron un papel crucial en el logro de los resultados de esta investigación.
- Es importante considerar el impacto de las condiciones climáticas en las imágenes satelitales y en el proceso de clasificación, lo cual puede necesitar una evaluación adicional.
- La utilización del método clasificador Máquinas de Vectores de Soporte (SVM) permitió una identificación precisa de las diversas coberturas de suelo en la zona analizada. Los procedimientos empleados se mostraron sólidos y altamente eficaces en este contexto específico de estudio.
- La calidad de los procedimientos empleados se evaluó mediante índices globales, el estadístico kappa y la matriz de confusión, confirmando la notable precisión de las clasificaciones efectuadas. Los resultados revelaron un nivel de acuerdo prácticamente perfecto, lo que respalda la solidez de la metodología utilizada.

- Este estudio subraya la eficacia de la teledetección como herramienta para supervisar la deforestación, ofreciendo datos cruciales para orientar las decisiones en la gestión ambiental y forestal. La información recopilada en esta investigación enriquece nuestra comprensión de la dinámica de cambios en la cobertura forestal en el Departamento de San Martín y puede constituir un fundamento esencial para futuras políticas de conservación y uso sostenible de los recursos naturales.
- Los resultados enfatizan la imperativa necesidad de implementar medidas efectivas para hacer frente a la deforestación en el Departamento de San Martín y mitigar su impacto en el medio ambiente y la biodiversidad.
- La colaboración entre entidades gubernamentales, organizaciones ambientales y comunidades locales se vuelve fundamental para abordar de manera efectiva el problema de la deforestación. Además, es crucial considerar las limitaciones de este estudio y explorar áreas para investigaciones futuras.

VII. RECOMENDACIONES

- Se sugiere mantener un monitoreo continuo de la deforestación en el Departamento de San Martín utilizando técnicas de teledetección. Esto facilitará la evaluación de las tendencias a lo largo del tiempo y permitirá tomar medidas oportunas para la conservación del área. Para mejorar la precisión de los resultados, se recomienda combinar imágenes de mayor resolución espacial con datos de Landsat, especialmente en zonas críticas de deforestación.
- Además, se aconseja llevar a cabo investigaciones adicionales para identificar las causas subyacentes de la deforestación en la región. Esto podría implicar el análisis de factores socioeconómicos, políticos y culturales que impulsan este fenómeno. También se insta a fomentar la colaboración y el intercambio de información con otras entidades gubernamentales, organizaciones no gubernamentales y comunidades locales involucradas en la gestión forestal y la conservación ambiental.
- Es esencial desarrollar e implementar políticas y programas que promuevan prácticas forestales sostenibles y la restauración de áreas deforestadas. Se recomienda mantener actualizada la base de datos geoespacial con nuevos datos de teledetección y realizar análisis periódicos para evaluar la evolución de la deforestación en la zona.
- Se sugiere considerar la implementación de una gestión integrada del territorio que tenga en cuenta tanto la conservación forestal como el desarrollo sostenible en el Departamento de San Martín.

VIII. REFERENCIAS

- Alonso, C., Moreno, V., & Rodríguez, E. (1999). *Determinación experimental de la firma espectral de la vegetación*. una sencilla práctica de introducción a la teledetección. (pp. 429–432).
- Ariza, A. (2013). *Descripción y Corrección de Productos Landsat 8 LDCM*. Landsat Data Continuity Mission. Bogotá
- Benediktsson J.A. and Arnason K. (1995). *Classification and feature extraction of aviris data*, IEEE Trans. on Geoscience and Remote Sensing, vol.33, p. 1194 – 1205.
- Boca, T., & Rodríguez, G. (2012). *Métodos estadísticos de la evaluación de la exactitud de productos derivados de sensores remotos*. Instituto de Clima y Agua, INTA Castelar.
- Bravo Morales, N. F. (2017). *Teoría - Teledetección espacial* (1a Ed. Perú, pp. 18 -21). Geomática Ambiental S.R.L.
- Candel, C. D. (2011). *Algoritmo Tipo Smo Para La Ad-Svm Aplicado A Clasificación Multicategoría*. Universidad Técnica Federico Santa María - Valparaíso – Chile.
- Chander, Brian L. Markham, Dennis L. Helder. (2009) *Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors - Remote Sensing of Environment*, Volume 113, (pp. 893-903). Disponible en <https://doi.org/10.1016/j.rse.2009.01.007>
- Chavez, J. (1988). *An Improved Dark-Object Subtraction Technique for Atmospheric Scattering Correction of Multispectral Data*. Remote Sensing of Environment, 24, 459-479. Disponible en [http://dx.doi.org/10.1016/0034-4257\(88\)90019-3](http://dx.doi.org/10.1016/0034-4257(88)90019-3)
- Chuvieco, E. (1995a). *Sistemas Espaciales De Teledetección*. En Fundamentos de teledetección espacial (1.a. ed., pp. 100-120). RIALP S.A.
- Chuvieco, E. (1995b). *Principios físicos de la Teledetección*. En Fundamentos de teledetección espacial (2.a. ed., pp. 27-58). RIALP S.A.

- Chuvieco, E. (1995c). *Principios físicos de la Teledetección*. En Fundamentos de teledetección espacial (3.a. ed., pp. 62-78). RIALP S.A.
- Chuvieco, E. (1996). *Fundamentos de Teledetección espacial*. En Procesamiento De Imágenes Satelitales (pp. 326-374). RIALP, S.A. Madrid, España.
- Chuvieco, E. (2002). *Teledetección Ambiental*. En La observación de la Tierra desde el Espacio (3.a ed., pp. 42-96). Editorial Ariel Ciencia, S. A.
- Chuvieco, E. (2010). *Teledetección Ambiental. La observación de la tierra desde el espacio* (1.a ed., pp. 120 - 125). Editorial Ariel. Barcelona España.
- Condoy, G., & Silva, S. D. (2006). *Análisis y tendencia de la deforestación de la provincia de Zamora Chinchipe, en base a la interpretación de imágenes satelitales (Tesis (Ingeniero Forestal))*. Universidad Nacional de Loja. Área agropecuaria y de recursos naturales renovables. Loja. Ecuador. 105 p.
- Dev Acharya, T., & Yang, I. (2015). *Exploring Landsat 8*. International Journal of IT, Engineering and Applied Sciences Research, 1-4.
- Eggleston, S., Buendia, L., Miwa, K., Ngara, T., & Tanabe, K. (2006). *Agricultura, silvicultura y otros usos de la tierra*. Intergovernmental Panel on Climate Change - IPCC, 4, (pp. 30–33).
- FAO. (2001). *El papel de la silvicultura en la mitigación de la pobreza*. Foro. Italia. 4-6 de setiembre del 2001, Roma, Italia.
- FAO. (2003). *Situación de los bosques del mundo*. Roma. 468 pp. Disponible en <https://www.redalyc.org/pdf/481/48101405.pdf>
- Gao, J. (2009). *Digital Analysis of Remotely Sensed Imagery*. 1st ed. New York. Disponible en <https://www.accessengineeringlibrary.com/content/book/9780071604659>

- Hofmann, T., Schölkopf, B. y Smola, AJ (2008). *Kernel Methods in Machine Learning*. Annals of Statistics, 36(3), 1171-1220. Disponible en <https://arxiv.org/pdf/math/0701907.pdf>
- https://www.ipccnggip.iges.or.jp/public/2006gl/spanish/pdf/4_Volume4/V4_02_Ch2_Generic.pdf
- Instituto de Investigaciones de la Amazonía Peruana. (2009). *Las potencialidades y limitaciones del departamento de San Martín* (p. 40). Disponible en <http://repositorio.iiap.gob.pe/handle/IIAP/153>
- Instituto nacional de recursos naturales. (2005). *Mapa de deforestación de la amazonia peruana – 2000* (pp. 43–74). PROCLIM.
- Jensen, J. R. (1996). *Introductory digital image processing: a remote sensing perspective* (2.a.ed., p. 316). Upper Saddle River: Prentice-Hall Inc. Disponible en <https://www.cabdirect.org/cabdirect/abstract/20001911540>
- Kramer, H. J. (2016). *Observation of the Earth and its Environment*. En Survey of Missions and Sensors (pp. 67-77). Springer - Verlag.
- Landis, J. R., & Koch, G. G. (1977). *The Measurement of Observer Agreement for Categorical Data*. Biometrics, 33(1), 159–174. Disponible en <https://doi.org/10.2307/2529310>
- Layza Castañeda, R. R., Gonzales Veintimilla, F., & Terán Iparraguirre, J. R. (2018). *La deforestación y el cambio climático en la provincia de San Martín periodo: 1973 al 2014*. Revista Ciencia Y Tecnología, (ISSN 1810-6781), 19–30. Disponible en <https://revistas.unitru.edu.pe/index.php/PGM/article/viewFile/2072/1973>
- Lobo, A. (1995). *La observación remota de los ecosistemas*. En “Análisis de la variabilidad espacio-temporal y procesos caóticos en ciencias ambientales”. Geoforma Ediciones. Logroño.
- Macedo Cruz, A., Pajares Martin Sanz, G., & Santos Peñas, M. (2010). *Clasificación no supervisada con imágenes a color de cobertura terrestre*. Agrociencia, 44(6), 711-722. Disponible en

http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S1405-31952010000600010&lng=es&tlng=es

Ministerio del Ambiente. (2012). *Memoria técnica de la cuantificación de los cambios de la cobertura de bosque a no bosque por deforestación en el ámbito de la Amazonía peruana: periodo 2009-2010-2011*. Disponible en:

http://geoservidor.minam.gob.pe/geoservidor/archivos/memoria/MEMORIA_TECNICA_ANALISIS_2009_2011.pdf

Ministerio del Ambiente. (2015). *Cuantificación y análisis de la deforestación en la amazonia peruana en el periodo 2010- 2011- 2013- 2014* (pp. 45–50). Lima: Dirección General de Ordenamiento Territorial. Disponible en [http://infobosques.com/portal/wp-](http://infobosques.com/portal/wp-content/uploads/2017/03/Memoria_Descriptiva_Cambios_Cobertura_Bosque_2014.pdf)

[content/uploads/2017/03/Memoria_Descriptiva_Cambios_Cobertura_Bosque_2014.pdf](http://infobosques.com/portal/wp-content/uploads/2017/03/Memoria_Descriptiva_Cambios_Cobertura_Bosque_2014.pdf)

Miranda, L. (2013). *Monitoreo de la deforestación mediante técnicas geomáticas en una porción de la región centro-norte de México* (Tesis Grado de Doctor). Universidad Autónoma de Nuevo León.

Disponible en <http://cienciauanl.uanl.mx/wp-content/uploads/2014/01/Monitoreo-deforestacion.pdf>

Newton, A. (2007). *Forest Ecology and Conservation: A Handbook of Techniques*. Oxford University Press. Disponible

[https://oxford.universitypressscholarship.com/view/10.1093/acprof:oso/9780198567448.001.0001/acprof-9780198567448.](https://oxford.universitypressscholarship.com/view/10.1093/acprof:oso/9780198567448.001.0001/acprof-9780198567448)

Rodríguez, O. & Arredondo, H. (2005). *Manual para el manejo y procesamiento de imágenes satelitales obtenidas del sensor remoto MODIS de la NASA, aplicado en estudios de Ingeniería Civil*: Tesis Bogotá: Pontificia Universidad Javeriana.

Servicio Nacional Forestal y de Fauna Silvestre. (2012). *Plan de Implementación de la Zonificación Forestal del Departamento de San Martín*. Disponible en

http://geo.serfor.gob.pe/geoserfor/images/Archivos_Web/Catastro_Zonificacion/SanMartin/Preparacion/pizf.pdf

Sobrino, J. A. (2000). *Teledetección* (pp. 19–89). Valencia - España: Universidad de València Servicio de Publicaciones. ISBN 84-370-4220-8.

Van Oort, P.A.J. (2007) *Interpreting the change detection error matrix*. Remote Sensing of Environment, 108(1), 1-8. <https://doi.org/10.1016/j.rse.2006.10.012> Disponible en

<https://www.sciencedirect.com/science/article/pii/S0034425706004226>

Vapnik, V. N., Sep 1999. *An overview of statistical learning theory*. IEEE Transactions on Neural Networks 10 (5), 988–999. Disponible en <https://doi.org/10.1109/72.788640>

IX. ANEXOS

Anexo A. Código de Distribución de Dos Clases en SVM

Anexo B. Lista de Imágenes Satelitales Landsat Descargadas (1987-1997-2007-2017)

Anexo C. Lista de Imágenes Master Descargadas

Anexo D. Mapa de Deforestación Año 1987

Anexo E. Mapa de Deforestación Año 1997

Anexo F. Mapa de Deforestación Año 2007

Anexo G. Mapa de Deforestación Año 2007

Anexo H. Mapa de Cambio de Cobertura del Suelo – Periodo (1987 – 1997)

Anexo I. Mapa de Cambio de Cobertura del Suelo – Periodo (1997 – 2007)

Anexo J. Mapa de Cambio de Cobertura del Suelo – Periodo (2007 – 2017)

Anexo A. código de distribución de dos clases en SVM

```
#Código de muestra de la técnica SVM
#Se carga a librería e1071
library(e1071)
set.seed(1)
#Se generan los datos
x=matrix(rnorm(100*2), ncol=2)
y=c(rep(-1,10), rep(1,10))
x[y==1,]=x[y==1,] + 1
#Se hace la gráfica de los puntos generados en el plano
plot(x, col=(3-y),main="Datos mezclados",xlab="Eje X",ylab="Eje y")
#Se construye un Data.Frame
dat=data.frame(x=x, y=as.factor(y))
#Se calcula SVM para el kernel lineal
svmfit=svm(y~., data=dat, kernel="linear", cost=10)
plot(svmfit, dat)
#Se puede revisar los valores y el resumen de los estimado en R project para el modelo SVM
#svmfit$index
#summary(svmfit)
#Se estima el modelo SVM con kernel polinomial
svmfit=svm(y~., data=dat, kernel="polynomial", cost=10)
plot(svmfit, dat)
#Se estima el modelo SVM con el kernel sigmoid
svmfit=svm(y~., data=dat, kernel="sigmoid", cost=10)
plot(svmfit, dat)
#Se estima el modelo SVM con el kernel radial
svmfit=svm(y~., data=dat, kernel="radial", cost=10)
plot(svmfit, dat)
```

Anexo B. Lista de imágenes satelitales landsat descargadas

Año 1987

Imagen	Escena	Fecha
LT50070641987224XXX01	7/64.	12 de agosto 1987
LT50070651987208XXX02	7/65.	27 de julio 1987
LT50070661987240XXX08	7/66.	28 de agosto 1987
LANDSAT_5_TM_19870515_008_064	8/64.	15 de mayo 1987
LANDSAT_5_TM_19870515_008_065	8/65.	15 de mayo 1987
LT50080661987151XXX02	8/66.	31 de mayo 1987
LT50090641987222XXX01	9/64.	10 de agosto 1987
L5009065_06519870623	9/65.	23 de Junio 1987

Nota. Elaboración propia.

Año 1997

Imagen	Año	Fecha
LANDSAT_5_TM_19971026_007_064	7/64.	26 de octubre 1997
LT50070651997299AAA01	7/65.	26 de octubre 1997
LT50070661997251XXX02	7/66.	8 de septiembre 1997
LT50080641998181XXX02	8/64.	30 de junio 1998
LT50080651998277CUB00	8/65.	4 de octubre 1998
LT50080661997242XXX03	8/66.	30 de agosto 1997
LT50090641998140XXX02	9/64.	20 de mayo 1998
LANDSAT_5_TM_19970704_009_065	9/65.	04 de julio 1997

Nota. Elaboración propia.

Año 2007

Imagen	Año	Fecha
LT50070642007199CUB01	7/64.	18 de julio 2007
LT50070652007199CUB01	7/65.	18 de julio 2007
LT50070662007247CUB00	7/66.	4 de septiembre 2007
LT50080642007030CUB00	8/64.	31 de enero 2007
LT50080652008225CUB00	8/65.	13 de agosto 2008
LT50080662008225CUB00	8/66.	13 de agosto 2008
LT50090642007213CUB00	9/64.	1 de agosto 2007
LT50090652007213CUB00	9/65.	1 de agosto 2007

Nota. Elaboración propia.

Año 2017

Imagen	Año	Fecha
LC08_L1TP_007064_20170814_20170825	7/64.	14 de agosto 2017
LC08_L1TP_007065_20171001_20171013	7/65.	01 de octubre 2017
LC08_L1TP_007066_20170830_20170915	7/66.	30 de agosto 2017
LC08_L1TP_008064_20180824_20180829	8/64.	24 de agosto 2018
LC08_L1TP_008065_20180909_20180913	8/65.	09 de septiembre 2018
LC08_L1TP_008066_20180909_20180913	8/66.	09 de septiembre 2018
LC08_L1TP_009064_20181018_20181031	9/64.	18 de octubre 2018
LC08_L1TP_009065_20181205_20181211	9/65.	5 de diciembre 2018

Nota. Elaboración propia.

Anexo C. Lista de imágenes master descargadas

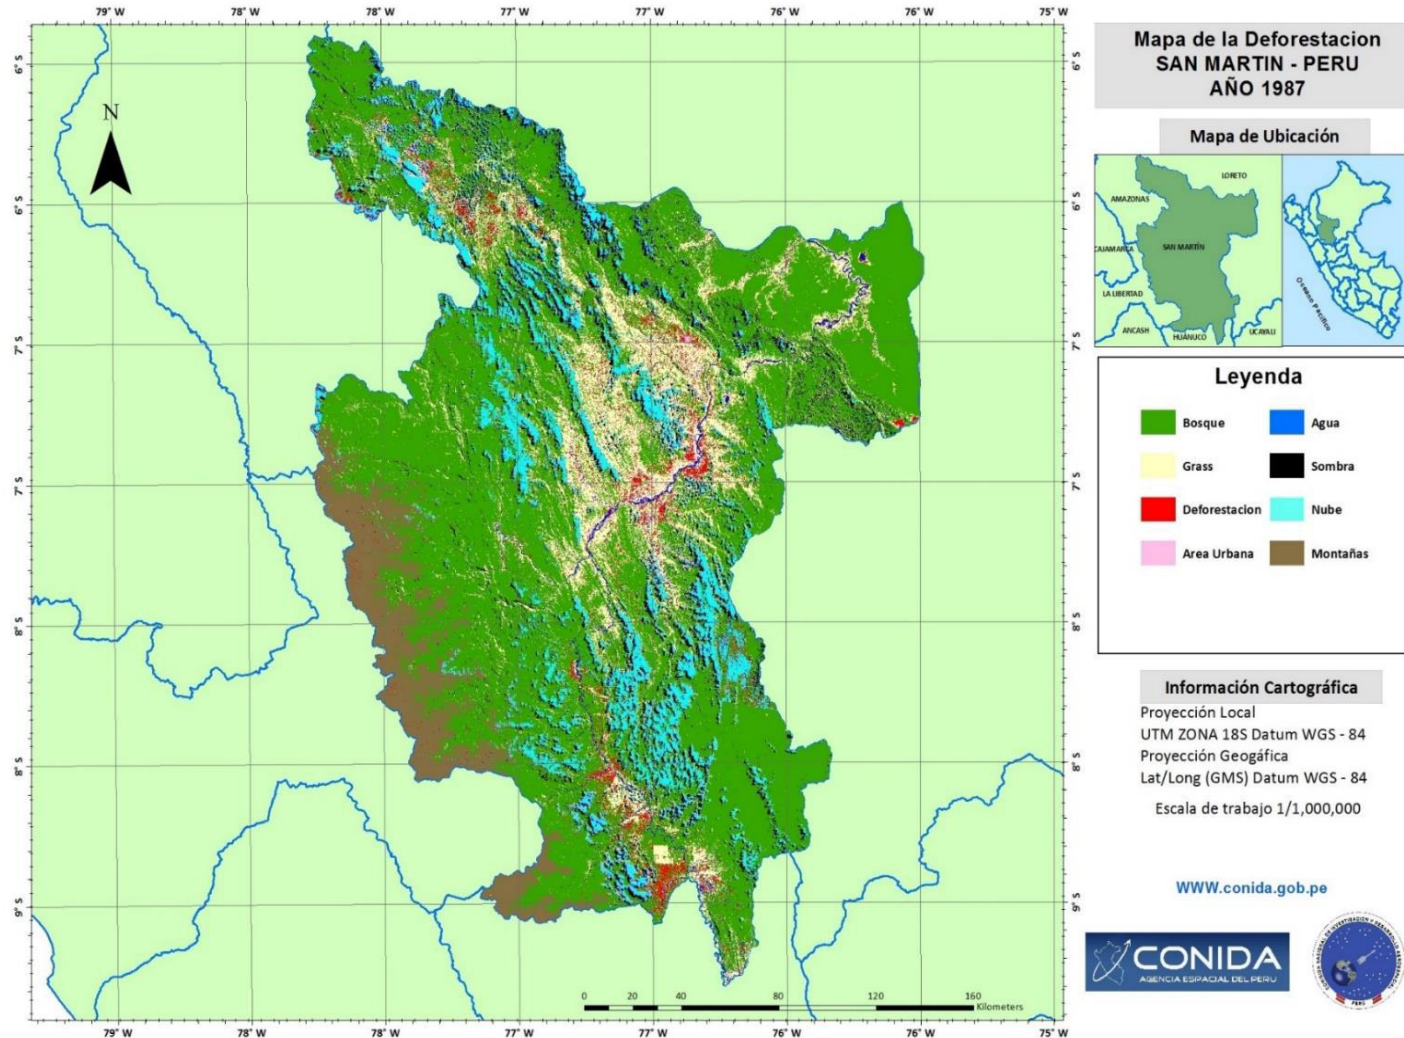
9_64	8_64	7_64
GLOVIS	GLOVIS	GLOVIS
ID: LT50090642010045CUB00	ID: LT50080642010230CUB00	ID: LT50070642011258CUB00
CC: 44%	CC: 6%	CC: 1%
Date: 2010/2/14	Date: 2010/8/18	Date: 2011/9/15
Qty: 9 Product: TM L1T	Qty: 9 Product: TM L1T	Qty: 9 Product: TM L1T

9_65	8_65	7_65
GLOVIS	GLOVIS	GLOVIS
ID: LT50090652011160CUB00	ID: LT50080652010230CUB00	ID: LT50070652009284CUB00
CC: 12%	CC: 35%	CC: 2%
Date: 2011/6/9	Date: 2010/8/18	Date: 20/10/11
Qty: 9 Product: TM L1T	Qty: 9 Product: TM L1T	Qty: 9 Product: TM L1T

	8_66	7_66
	GLOVIS	GLOVIS
	ID: LT50080662011249CUB00	ID: LT50070662011210CPE00
	CC: 30%	CC: 6%
	Date: 2011/9/6	Date: 2011/7/29
	Qty: 9 Product: TM L1T	Qty: 9 Product: TM L1T

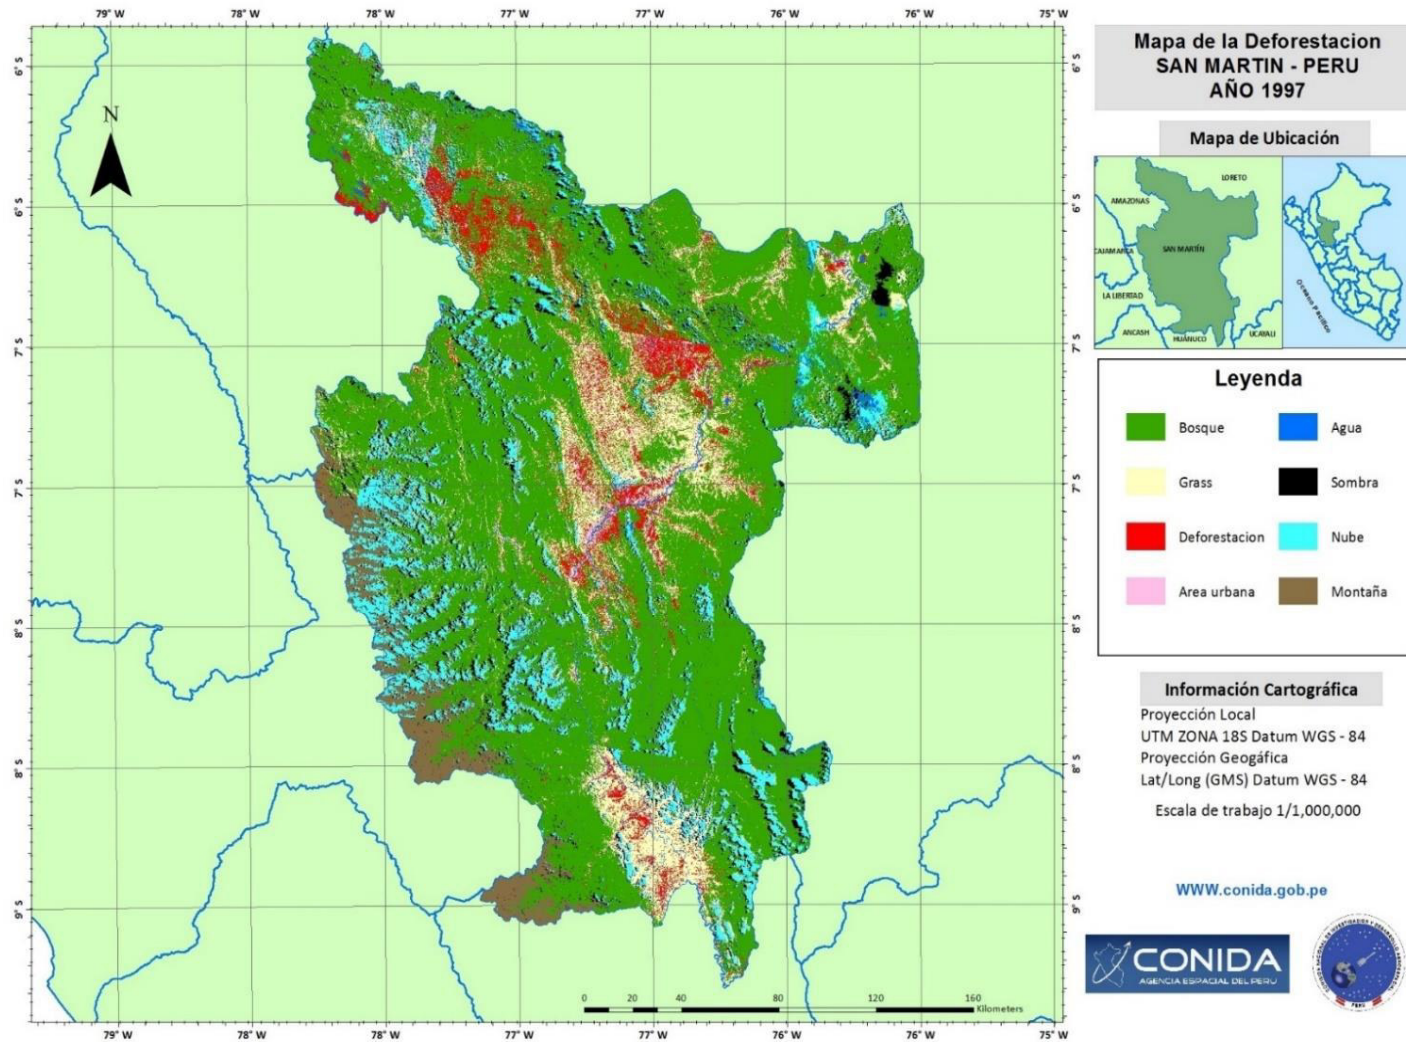
Nota. Elaboración propia.

Anexo D. mapa de deforestación año 1987



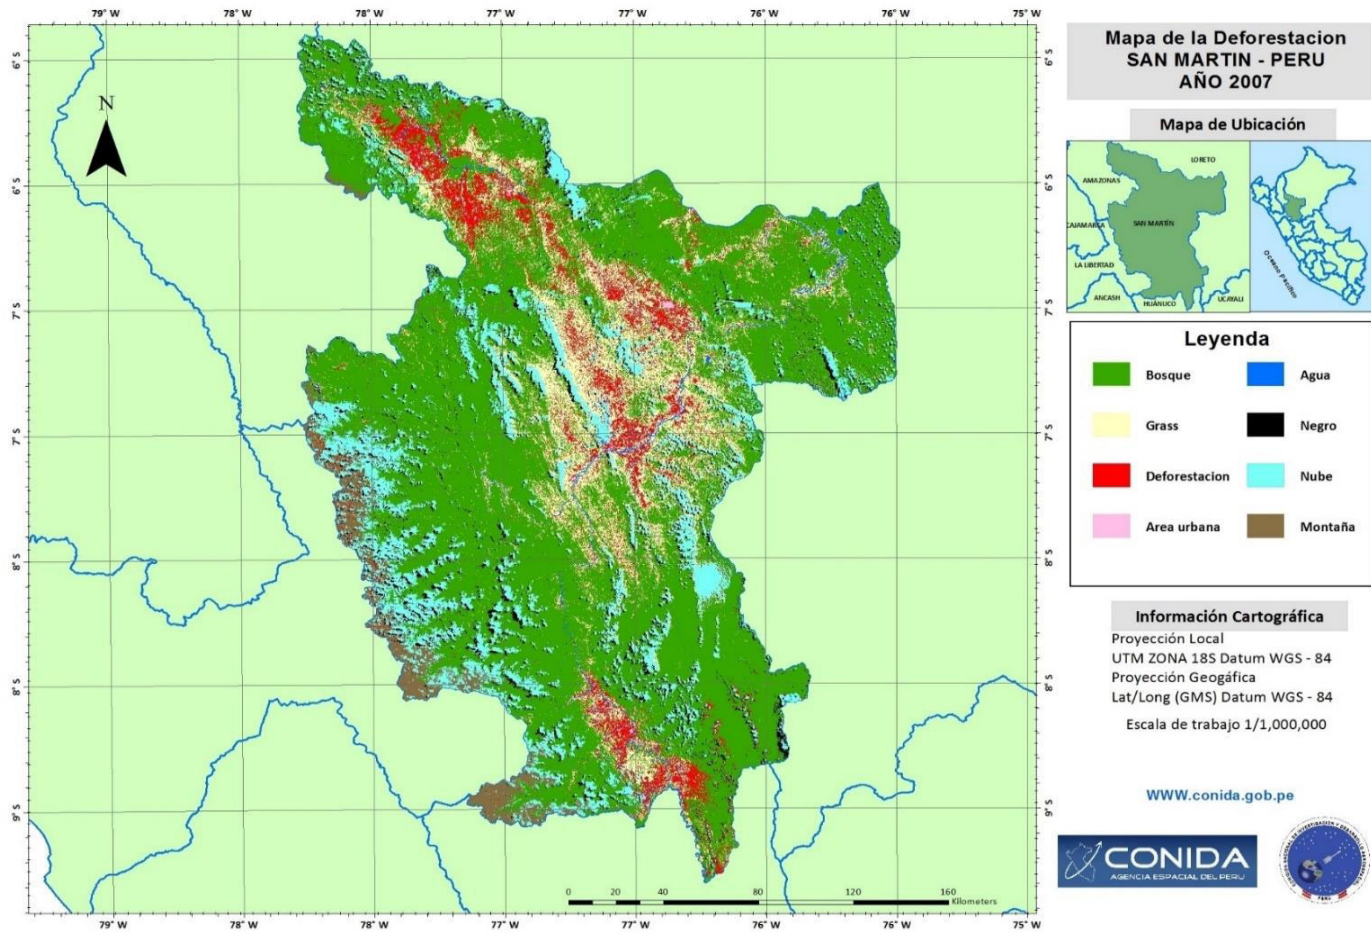
Nota. Elaboración propia.

Anexo E. mapa de deforestación año 1997



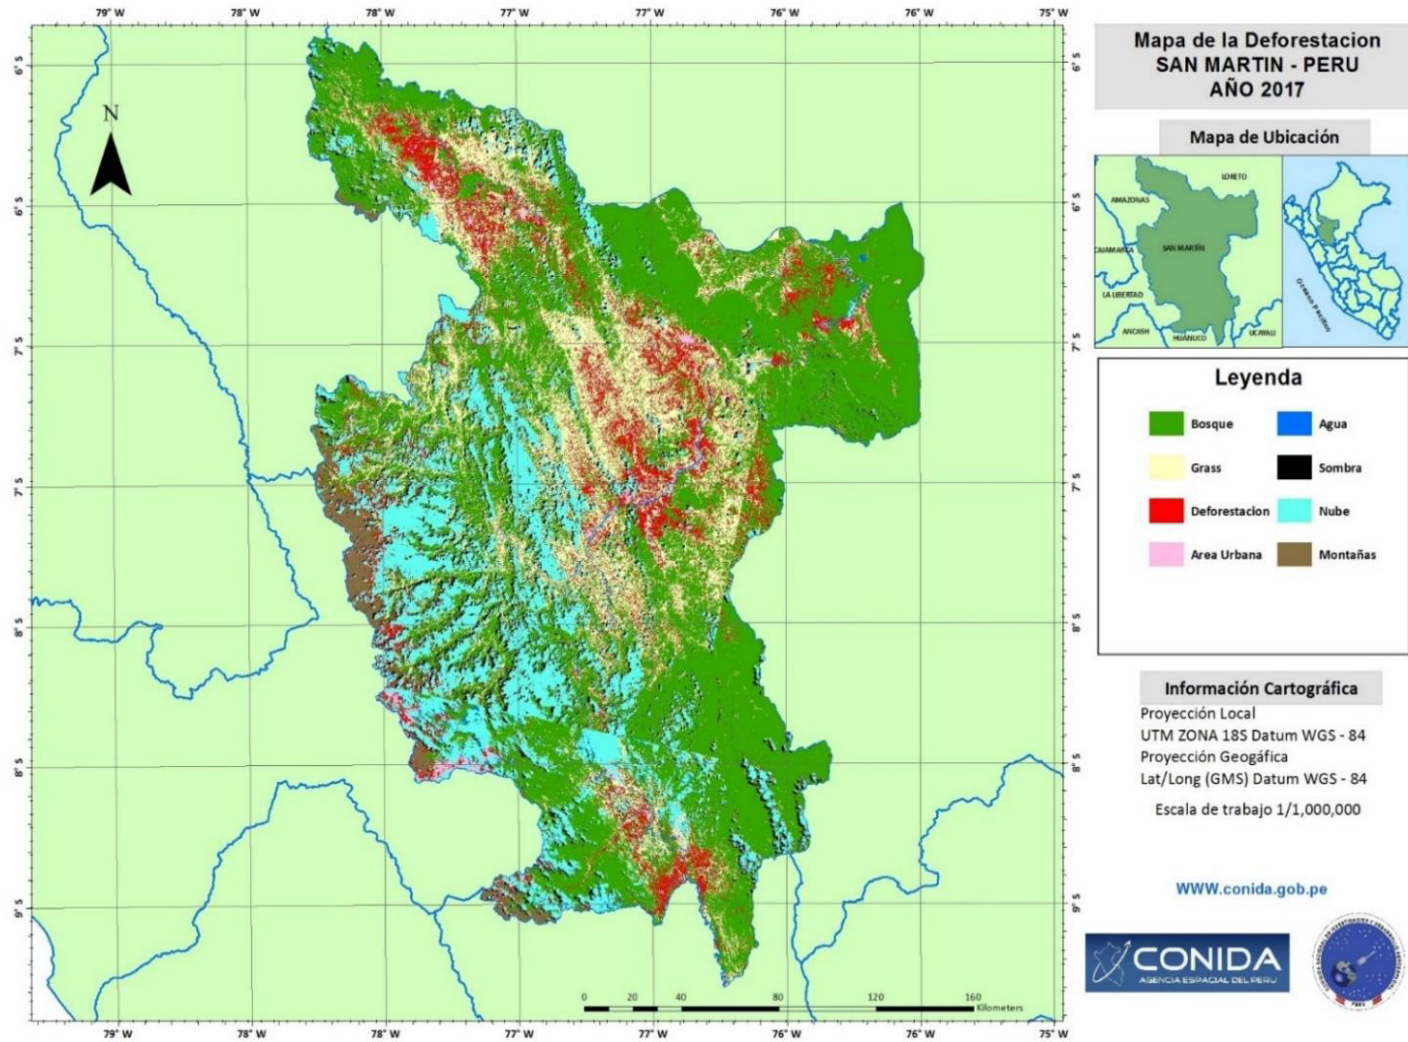
Nota. Elaboración propia.

Anexo F. mapa de deforestación año 2007



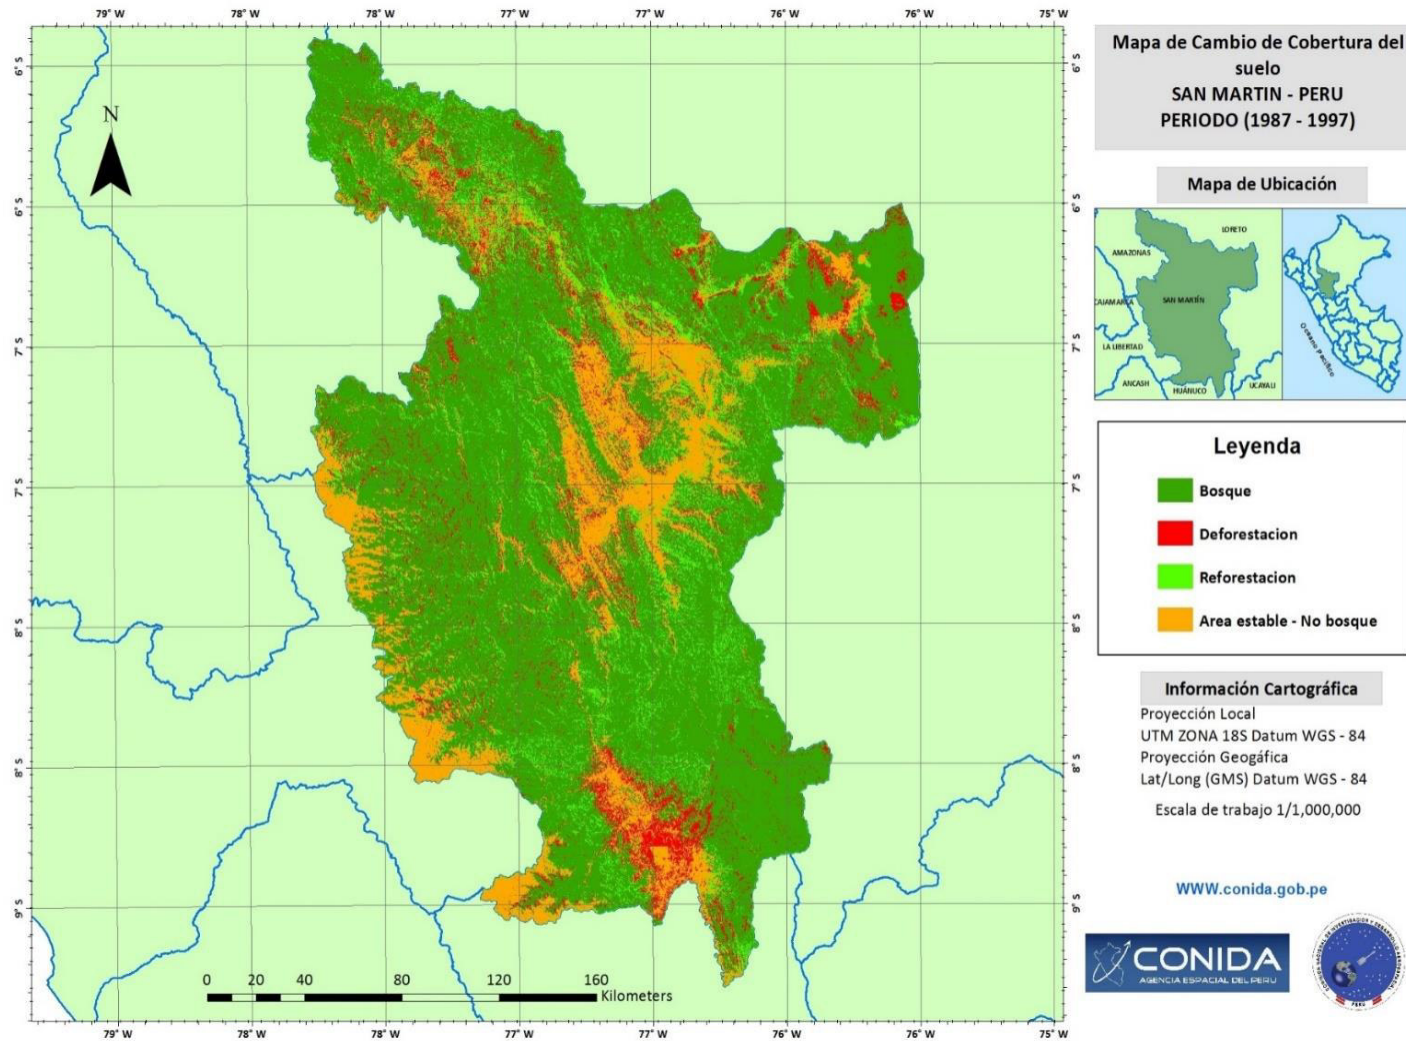
Nota. Elaboración propia.

Anexo G. Mapa de Deforestación Año 2017



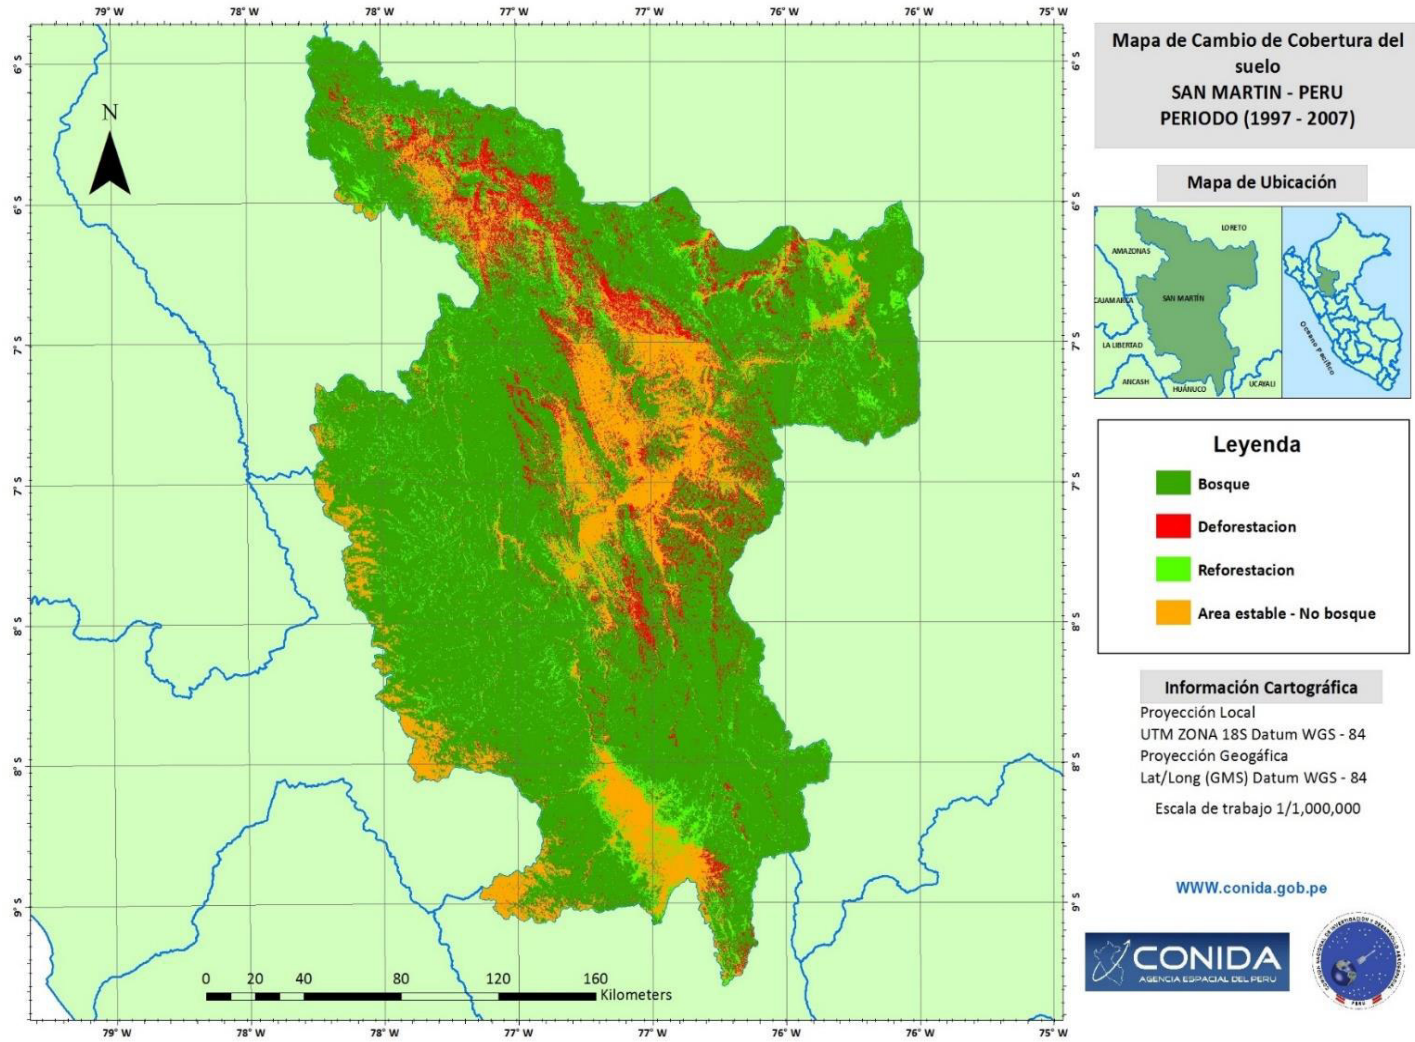
Nota. Elaboración propia.

Anexo H. Mapa de Cambio de Cobertura del Suelo – Periodo (1987 – 1997)



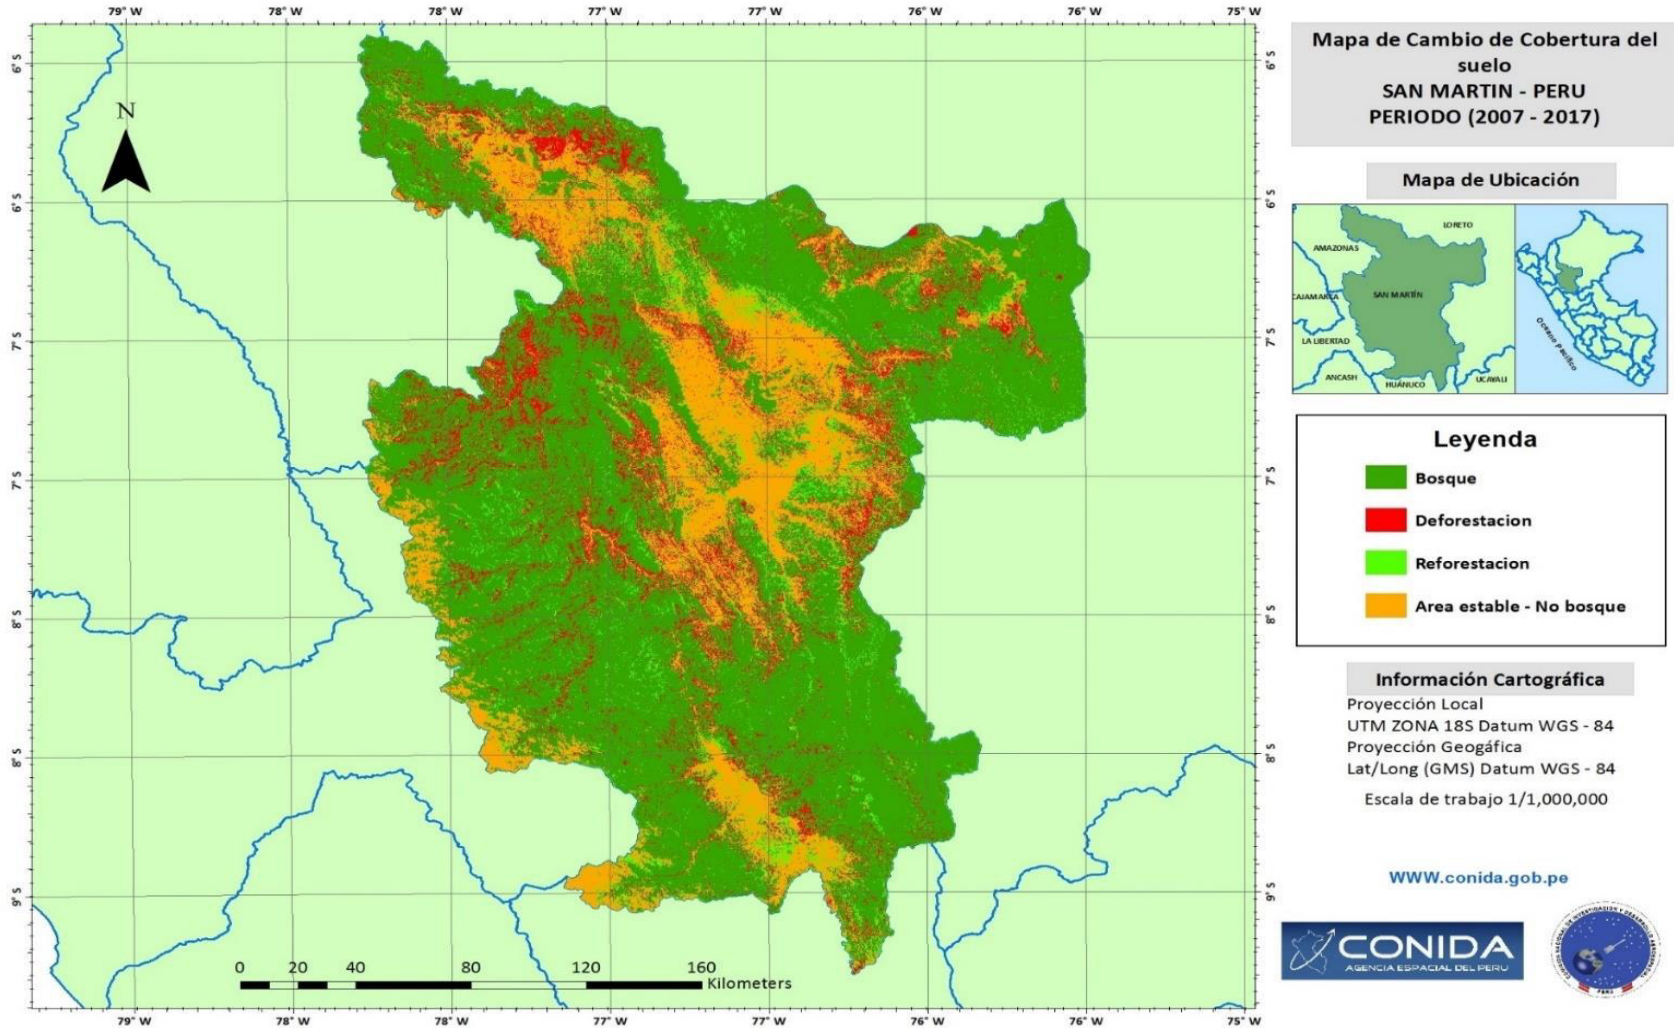
Nota. Elaboración propia.

Anexo I. Mapa de Cambio de Cobertura del Suelo – Periodo (1997 – 2007)



Nota. Elaboración propia.

Anexo J. Mapa de Cambio de Cobertura del Suelo – Periodo (2007 – 2017)



Nota. Elaboración propia.

