

Guía metodológica para el estudio de procesos de desertificación por salinización empleando imágenes de satélite

Elaborado por:



Con el apoyo de:



Ministerio
del Ambiente

GUÍA METODOLÓGICA PARA EL ESTUDIO DE PROCESOS DE DESERTIFICACIÓN POR SALINIZACIÓN EMPLEANDO IMÁGENES DE SATÉLITE

Autores:

Bram Willems, Ph.D. (Autor principal)	Centro de Competencias del Agua E-mail: bwillems@cca.org.pe
Eleazar Rufasto, Ing. M.Sc.	Facultad de Agronomía Universidad Nacional Pedro Ruíz Gallo de Lambayeque
Renee Badarracco, M.Sc.	Facultad de Ciencias Físicas Universidad Nacional Mayor de San Marcos
Mervin Becerra, Ing.	Facultad de Agronomía Universidad Nacional Pedro Ruíz de Montoya

La presente guía fue diseñada y aplicada por el Programa Agua-Andes del CCA, dentro de un marco colaborativo con la Universidad Nacional Mayor de San Marcos y la Universidad Nacional Pedro Ruíz Gallo de Lambayeque. Contó con el financiamiento de los proyectos USAID-PEER: “Strengthening resilience of Andean river basin headwaters facing global change” (PGA 084063), International Water Security Network (IWSN) auspiciado por el Lloyd’s Register Foundation y el Ministerio del Ambiente, a través del estudio: “Elaboración de un mapa de desertificación por salinización en la región Piura”. Adicionalmente, se tuvo los aportes de los profesionales del Gobierno Regional de Piura, la Autoridad Nacional del Agua y Juntas de Regantes.

Favor citar este documento de la siguiente forma:

Willems, B., Rufasto, E., Badarracco, R., & Becerra, M. (2014). Guía metodológica para el estudio de procesos de desertificación por salinización empleando imágenes de satélite. *Centro de Competencias del Agua (CCA), Lima, 40p.*

Nota de los autores: El presente documento no ha pasado por una revisión exhaustiva de pares ni proceso de edición, por lo que no está exento de errores gramaticales y/o omisiones involuntarias de referencias. Pedimos a los lectores que pudieran identificarlos, nos lo hagan saber. Asimismo, todo aporte, corrección, consulta y/o comentarios son más que bienvenidos.

TABLA DE CONTENIDO

RESUMEN EJECUTIVO	1
I. INTRODUCCIÓN	2
II. METODOLOGÍA	5
III. PROCESAMIENTO Y ANÁLISIS DE IMÁGENES DE SATÉLITE	11
3.1 ADQUISICIÓN DE IMÁGENES DE SATÉLITE	11
3.1.1 Imágenes MODIS	11
3.1.2 Imágenes de la serie LANDSAT	12
3.2 GENERACIÓN DE PRODUCTOS (MAPAS DE NDVI)	15
3.2.1 Pre-procesamiento de imágenes OLI	15
3.2.2 Obtención de imágenes-producto NDVI	19
3.3 ESTADÍSTICA DE IMÁGENES: PROMEDIO, MÁXIMO Y MÍNIMO COMPUESTO.....	20
IV. PREDICCIÓN DE ÁREAS DEGRADADAS: MODIS → OLI → RAPIDEYE	23
4.1 ANÁLISIS DE SERIES TEMPORALES DE LAS IMÁGENES-PRODUCTO NDVI DE MODIS	23
4.1.1 Vector de áreas degradadas en imágenes MODIS	27
4.2 ANÁLISIS DE SERIES TEMPORALES DE LAS IMÁGENES NDVI LANDSAT	30
4.2.1 Vector de áreas degradadas en imágenes OLI (LANDSAT 8).....	33
4.3 GENERACIÓN DE VECTORES.....	34
V. ESTUDIOS DE SUELOS	35
5.1 Recopilación de muestras.....	35
5.2 Preparación y análisis de muestras.	37
Sistematización y discusión de resultados.....	39
REFERENCIAS	40

RESUMEN EJECUTIVO

Se presenta una guía metodológica para la generación de mapas de predicción de tierras degradadas (escala de 1:25,000), a partir del procesamiento y análisis de imágenes de satélite. Ésta emplea como insumos principales imágenes-producto MODIS (Moderate Resolution Imaging Spectroradiometer) y OLI (Operational Land Imager), las que son de libre distribución. Por un lado, son elaborados mapas de cobertura vegetal a partir del Índice de Vegetación de Diferencia Normalizada (NDVI, por sus siglas en inglés), parámetro que sirve de proxy para la producción neta primaria (NPP, por sus siglas en inglés). La predicción de áreas degradadas se realiza a partir del análisis de series de tiempo del NDVI. Para la validación de los resultados se emplean imágenes de alta resolución espacial (RapidEye y aquellos disponibles en el aplicativo Google-Earth) y datos de muestras de suelos (conductividad eléctrica y pH).

En el presente documento se detalla, además, una metodología sencilla, efectiva y de bajo costo para la recopilación y análisis de muestras de campo.

Se toma como caso estudio la región Piura, sin embargo, la metodología puede ser aplicable a cualquier otra región.

I. INTRODUCCIÓN

La desertificación sigue siendo la mayor amenaza para los ecosistemas y el bienestar de las poblaciones de las tierras secas, las que cubren cerca del 40% del planeta y alberga al 30% de la población mundial (MEA, 2005). Ello implica que, o bien, no han sido implementadas prácticas de manejo sostenible de suelos en tierras degradadas, fueron puestas en operación recientemente de modo que sus efectos aún no son visibles, o simplemente no son sostenibles (Buenemann, 2011). Cualquiera fuere el caso, los formuladores de políticas y decisores requieren de información acerca de qué prácticas de manejo sostenible funcionan, cuáles no y por qué, y qué estrategias pueden ser implementadas bajo circunstancias específicas y sistemas de gestiones vigentes, entre otros (Buenemann, 2011). La creciente demanda por sistemas de monitoreo¹ y evaluación de la sostenibilidad de las prácticas de manejo y gestión de suelos (y ecosistemas en general), resaltan la importancia de las tecnologías geo-espaciales, tales como las imágenes de satélite y los sistemas de información geográfica (SIG).

La degradación de tierras es un fenómeno complejo, causado principalmente por factores humanos, ya sea de forma directa (p.ej., mala práctica de riego, deforestación) o indirecta (p.ej., crecimiento poblacional), y que es exacerbado por eventos climáticos extremos, tales como la sequía, precipitaciones torrenciales y heladas (MEA, 2005). El enmarañado de interacciones entre forzadores antrópicos y naturales, que mantienen a su vez relaciones de retroalimentación entre sí, hacen de la degradación de tierras un problema global y a la vez particular a un contexto dado: sus causas e impactos varían de forma espacial y temporal. Ello complica aún más la planificación y ejecución de intervenciones orientadas a detener y, en última instancia, revertir este flagelo, lo que implica que los formuladores de políticas y decisores (gobiernos, juntas, comisiones, agricultores) deben tomar decisiones en medio de muchas incertidumbres (MEA, 2005).

En esencia, reducir la incertidumbre es disminuir las posibilidades de que algo salga mal. En ese sentido, responder a la pregunta de qué tan mal nos puede ir al tomar una decisión específica nos

¹ Monitoreo es el proceso de llevar a cabo observaciones estructuradas o mediciones de variables antrópicas o ambientales de forma periódica.

da una idea del grado de incertidumbre al que nos estamos enfrentando. Esta crece al escalar de una parcela de cultivo a una cuenca, región y país, en vista de que las decisiones involucran a un número cada vez mayor de actores y tienen implicancias que no pueden ser previstas en su totalidad debido al desconocimiento de las condiciones iniciales, los procesos que subyacen y/o nuevos que puedan desencadenarse.

La complejidad del fenómeno de degradación de tierras, su carácter global y específico, y el escalamiento de la incertidumbre, demandan del soporte científico para la toma de decisiones. Esto significa que las políticas y acciones emprendidas dentro del marco de la lucha contra la desertificación deberán estar basadas en información cuantitativa y cualitativa acerca del estado de los suelos agrícolas y ecosistemas, y el entendimiento de las cadenas de causa-efecto – y sus respectivas retroalimentaciones – con procesos climáticos y socio-económicos, entre otros, de modo que permitan vislumbrar diferentes escenarios de “qué-pasaría-si”.

Durante la Primera Conferencia Científica de la Convención de las Naciones Unidas de Lucha contra la Desertificación (UNCCD) en el 2009, se estableció que las necesidades de información por parte de los formuladores de políticas y tomadores de decisiones están básicamente centrados en establecer (Vogt, 2011):

1. Tipos de degradación, extensión espacial, grado de severidad y tendencias en el tiempo.
2. Riesgos de ocurrencia de eventos de degradación en áreas no afectadas.
3. Causas que subyacen a los procesos de degradación (antrópicas, institucionales, biofísicos, climáticos).
4. Acciones para contrarrestar los efectos de la degradación, sus resultados e impactos.
5. Costos/beneficios para prevenir o revertir los procesos de degradación, así como costos/beneficios de la inacción.

El desarrollo del mapa de desertificación a una escala de 1:25,000 obedece a la necesidad por contar con información más precisa – por ende, menos incierta – acerca del estado de degradación de los suelos agrícolas del país. Si bien todas las regiones cuentan con sus respectivos estudios de Zonificación Ecológica y Económica, la información que proveen acerca de las tierras degradadas tienen por lo general una escala gruesa (por ejemplo, 1:100,000), por lo que constituyen una

primera aproximación². De otro lado, la desertificación es un proceso dinámico, lo que demanda, cada cierto periodo de tiempo, actualizar los mapas para poder evaluar su avance/retroceso. El acceso a imágenes de satélite de libre distribución abre la posibilidad de desarrollar herramientas de soporte para la actualización de la información de una forma periódica y a un bajo costo, y que tiene el potencial de servir de base para la implementación de un sistema de monitoreo de la desertificación a nivel nacional. Es importante resaltar la utilidad del sistema en mención en vista de que 1) posibilita el seguimiento de la evolución de la degradación de tierras desde una perspectiva integral, 2) ayuda a identificar áreas prioritarias para las intervenciones específicas orientadas a revertir el proceso, y 3) permite evaluar los impactos de éstos.

Finalmente, está claro que el factor humano es clave para detener y, eventualmente, revertir la degradación de tierras. No basta con entender los mecanismos que la subyacen, sino que resulta imprescindible articular a los diferentes actores (gobiernos, organizaciones civiles, la academia y usuarios) alrededor de acciones efectivas y que conduzcan a soluciones eficientes y sostenibles. Es por ello que en el proceso de elaboración del mapa de desertificación se requiere aplicar mecanismos innovadores de interacción, lográndose maximizar el trabajo colectivo a través de una articulación eficiente de los esfuerzos individuales. El elemento clave constituye el rol protagónico por parte de la academia, a través de la participación activa de investigadores y estudiantes, los que actúan de eslabones entre los distintos actores.

² Los procesos de desertificación son muy heterogéneos espacialmente, variando su intensidad inclusive dentro de una misma parcela de cultivo. En ese sentido, mapas al 1:100,000 no capturan estos detalles y heterogeneidad, menos permiten establecer los áreas prioritarias de intervención.

II. METODOLOGÍA

La metodología empleada se basa en la predicción de áreas degradadas³ a partir del estudio temporal de la cobertura vegetal de suelos agrícolas. Dicha evolución es cuantificada a través del Índice de Vegetación de Diferencia Normalizada (NDVI, por sus siglas en inglés), parámetro obtenido del procesamiento y análisis de imágenes de satélite.

El procedimiento toma como punto de partida lo observado en el campo: las áreas degradadas presentan vegetación escasa y dispersa, y poco vigorosa. Por lo tanto, se espera que generen valores bajos de NDVI durante periodos extensos respecto a las áreas en buen estado.



Figura 2.1: Degradación por salinización (izquierda) y erosión hídrica (derecha) en Tambo Grande.

³ Las imágenes de satélite son registradas por sensores a muchos kilómetros de distancia, sin entrar en contacto directo con las áreas de estudio. Ello implica que la información que es recabada viene a ser una aproximación de lo que ocurre sobre la superficie. La degradación de tierras constituye un fenómeno complejo y difícil de identificar, inclusive a través de estudios de campo; menos aún establecer las causas que la subyacen, las que son múltiples. En ese sentido, las imágenes de satélite permiten a lo mucho predecir áreas de probable degradación y los resultados que se deriven de éstas deberán ser analizadas en correlación con otras fuentes de información (parámetros de suelos, datos de producción, etc.).



Figura 2.2: Vistas de suelos que evidencia degradación por sodificación (izquierda) y salinización (ambos) en la zona del Bajo Piura.

Si bien la ausencia de cobertura vegetal no necesariamente implica procesos de degradación (tampoco lo opuesto), la persistencia de esta situación en el tiempo, o la evolución hacia dicho estado, puede ser asumido como un indicador de procesos de degradación. Sobre todo si ello ocurre en zonas de intensa actividad agrícola⁴.

La metodología se basa en la predicción de áreas degradadas⁵ a partir del estudio temporal de la cobertura vegetal de suelos agrícolas. Dicha evolución es cuantificada mediante el Índice de Vegetación de Diferencia Normalizada (NDVI, por sus siglas en inglés), parámetro obtenido del procesamiento y análisis de imágenes de satélite. Para el caso de las áreas degradadas, se esperan valores bajos de NDVI durante periodos extensos respecto a los terrenos en buen estado. Las imágenes de satélite posibilitan la predicción de tierras degradadas, elaborar diagnósticos de rendimiento de suelos agrícolas y evaluar los impactos de la degradación y/o intervenciones; de una

⁴ Como argumento que refuerza este criterio está el hecho de que el agricultor tiende a maximizar su producción, sobre todo para el caso de la pequeña y mediana agricultura, en vista de que su economía depende directamente del área cultivada. En ese sentido, el desuso de parcelas o partes de éstas, tienen una alta probabilidad de estar asociado a procesos de degradación. Esta situación puede ser distinta en aquellos lugares donde se practique la rotación de suelos.

⁵ Las imágenes de satélite son registradas por sensores a muchos kilómetros de distancia, sin entrar en contacto directo con las áreas de estudio. Ello implica que la información que es recabada viene a ser una aproximación de lo que ocurre sobre la superficie. La degradación de tierras constituye un fenómeno complejo y difícil de identificar, inclusive a través de estudios de campo; menos aún establecer las causas que la subyacen, las que son múltiples. En ese sentido, las imágenes de satélite permiten a lo mucho predecir áreas de probable degradación y los resultados que se deriven de éstas deberán ser analizadas en correlación con otras fuentes de información (parámetros de suelos, datos de producción, etc.).

manera económica y abordan amplias áreas (visión sinóptica) y sobre periodos de décadas (Abbas, 2013).

A fin de eliminar los efectos de las nubes, atmósfera y potenciales errores de índole técnico de las imágenes, a la vez de minimizar la ocurrencia de “falsos positivos” (p.ej., confusión de parcelas cosechadas o en descanso (sin vegetación) con zonas degradadas), son analizadas series de tiempo del máximo compuesto anual del NDVI ($NDVI_{Max}$). Dicho parámetro se obtiene seleccionando el valor más alto del NDVI del conjunto de imágenes correspondientes a un mismo año, píxel por píxel. Una de las premisas sobre las que se basa el presente estudio es que la persistencia de valores bajos de $NDVI_{Max}$ constituye un indicador de ocurrencia de degradación de suelos.

El NDVI es un parámetro de amplio uso en estudios de degradación de tierras (p.ej. Bai, 2008), en vista de que puede ser empleado como proxy para medir la producción neta primaria (Rasmussen, 1998). Entre otros, es un buen indicador para identificar áreas agrícolas por riego debido a su alta sensibilidad a la presencia de biomasa y correlación positiva con la humedad de las plantas (Pervez, 2014). Ello hace que las áreas de cultivos por riego presenten valores más elevados en el $NDVI_{Max}$, por encima de aquella vegetación alimentada por lluvias (Pervez, 2014). De otro lado, Maxwell y colegas (Maxwell, 2012) emplearon productos $NDVI_{Max}$, obtenidos en imágenes Landsat, para la identificación de áreas cultivadas durante el periodo 1984-2010 en Kansas, USA. Se pudo observar que las áreas que nunca fueron empleados con fines agrícolas (pastizales, bosques, vegetación permanente alrededor de los campos) presentan un $NDVI_{Max}$ estable (entre 0.3 y 0.6), con una desviación estándar baja. De otro lado, áreas con cultivos presentan valores altos (>0.7), al menos en uno de los años, así como una desviación estándar alta.

En síntesis, la metodología para la predicción de las potenciales áreas degradadas involucra los siguientes pasos:

1. Adquisición de las imágenes productos NDVI (MOD 13) del sensor MODIS (satélite Terra) y OLI (satélite LANDSAT 8).
2. Para los datos imágenes NDVI del sensor MODIS (250 m por 250 m de resolución espacial, 6.25 ha/píxel), se generaron estadísticas, tales como los máximos compuestos anuales ($NDVI_{Max}$) y NDVI promedio, de un total de 322 imágenes NDVI correspondientes al periodo

2000-2013, a razón de 23 imágenes por año. Estas estadísticas fueron implementados en el lenguaje de programación IDL (Interactive Data Language).

3. A partir del análisis temporal del $NDVI_{Max}$, se seleccionaron los píxeles que correspondían a los sectores agrícolas para ver su comportamiento temporal. Estos píxeles fueron seleccionados aplicando la técnica de clasificación ISODATA a las 14 imágenes anuales de $NDVI_{Max}$. Para el caso de Piura, se obtuvieron un total de 6 clases.
4. Se seleccionó la clase cuyas series temporales de $NDVI_{Max}$ mostraban una tendencia negativa o una alta variabilidad. Dicha clase fue convertido en vector.
5. Los datos imágenes OLI (nivel L1T, ortorectificadas y de resolución espacial 30 m por 30 m – 0.09 ha/píxel) del LANDSAT 8 fueron procesados usando códigos en IDL y el software ENVI. Se llevó a cabo la calibración radiométrica, corrección atmosférica para la obtención de la reflectancia de la superficie (Modulo FLAASH del software ENVI) y el cálculo del NDVI.
6. La máscara resultante de los datos NDVI-MODIS es aplicada a los productos NDVI-OLI, los que cubren el periodo 2013-2014 (uno por mes), para obtener la correspondiente imagen de $NDVI_{Max}$.
7. Los valores máximos de NDVI son comparados con aquellos identificados como potenciales áreas degradadas en el paso anterior. Se descartan aquellos píxeles cuyo $NDVI_{Max}$ sea mayor a 0.45, obteniéndose una nueva máscara con los restantes.
8. De los píxeles de $NDVI_{Max}$ con valores entre 0.3 y 0.45, se generan polígonos (en formato *.shp), los que corresponden a las áreas de probable degradación.
9. Como paso final, a través de una interpretación monoscópica sobre las imágenes ortorectificadas RapidEye de nivel 3A (resolución espacial 5 m, registradas entre el año 2012 y 2013) y aquellas disponibles en la plataforma del Google-Earth, se editaron los polígonos empleando el software ARCGIS 10.1, a una escala numérica de 1:25000.

Es importante resaltar el sentido de la metodología propuesta, la que involucra el empleo de tres fuentes de datos con diferentes resoluciones espaciales, temporales y espectrales, frente a la opción de simplemente extraer las áreas degradadas directamente de imágenes de alta resolución espacial. Para éste último, en vista de su baja frecuencia temporal (una imagen cada 1-2 años), no permite distinguir terrenos cosechados o en preparación de las áreas degradadas. Asimismo, únicamente se detectaría casos severos de desertificación, mientras que dificultaría identificar aquellos que están evolucionando hacia dichos estados, que es lo que finalmente interesa más al agricultor y

tomadores de decisiones en vista de la posibilidad de realizar intervenciones tempranas. A ello habría que mencionar que no se disponen imágenes de alta resolución para todo el país.

Tabla 2.1: Criterio de selección de áreas de probable degradación a partir del análisis de series temporales del producto NDVI de MODIS (MOD 13) e imágenes OLI.

Tendencia $NDVI_{Max}$ 2000-2013 (MODIS)	$NDVI_{Max}$ 2013-2014 (OLI – Landsat)	Probabilidad de degradación
Negativa	> 0.4	Baja
Negativa	< 0.4	Alta

El proceso de validación de los resultados requiere de visitas de campo para la adquisición de puntos GPS y el registro fotográfico de las áreas de interés – esto para fines de corroborar la predictabilidad de los mapas y descartar falsos positivos. Asimismo, es importante recopilar información secundaria y validar los avances a través del desarrollo de talleres/reuniones con agricultores, representantes de las juntas de usuarios y funcionarios del Gobierno Regional, entre otros. De otro lado, es imprescindible contar con datos actualizados de propiedades físicas, químicas y/o biológicas de muestras de suelos. Para efectos del estudio de procesos de salinización y sodificación, son de utilidad conductividad eléctrica (proxy para medir la salinidad de suelos) y pH.

Los datos de campo proveen información que no puede ser recabada con las imágenes. Mientras que la última nos permite visualizar los cambios de cobertura vegetal, es a través de los trabajos de campo que se pueden establecer el contexto, causas y percepciones, entre otros, de los fenómenos que subyacen dichos cambios (Buenemann, 2011).

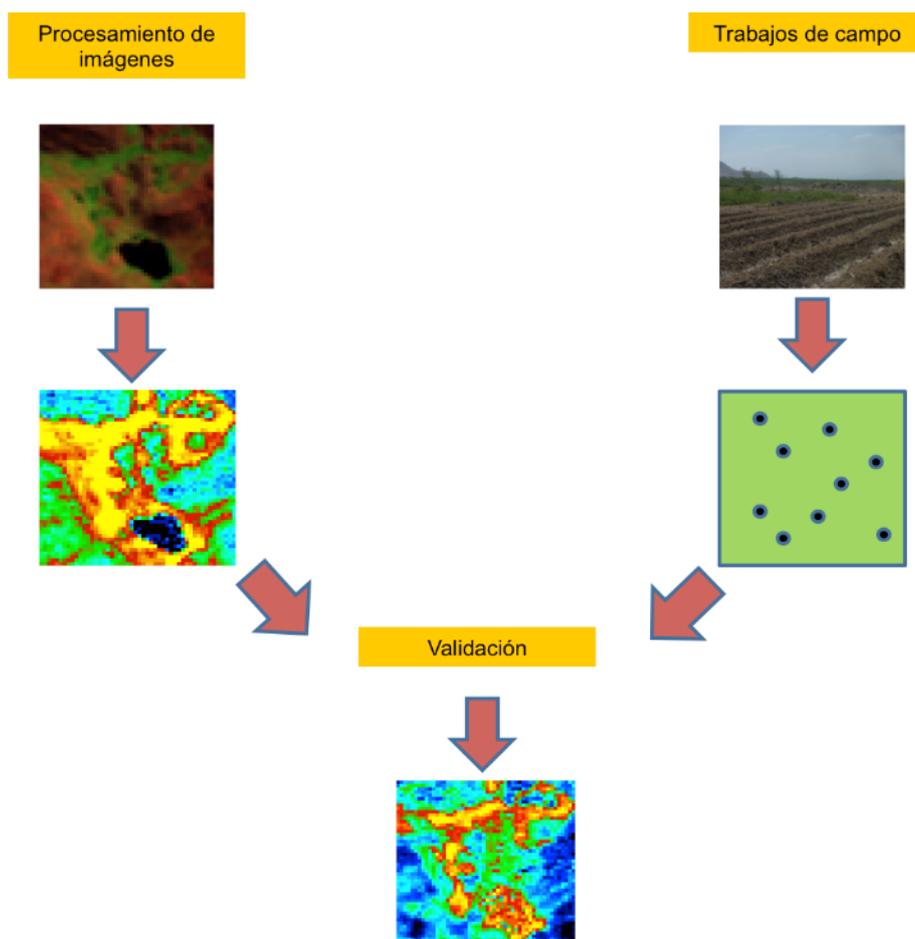


Figura 2.3: Representación esquemática del proceso de elaboración del mapa de predicción de degradación de suelos.

III. PROCESAMIENTO Y ANÁLISIS DE IMÁGENES DE SATÉLITE

En la presente sección, se abordan conceptos básicos de la teledetección por satélite, tales como la adquisición de imágenes, sensores y plataformas, procesamiento, generación de productos y estadísticas. Estos constituyen las secuencias usuales a seguir en la generación de los mapas.

3.1 ADQUISICIÓN DE IMÁGENES DE SATÉLITE

3.1.1 Imágenes MODIS

Los sensores MODIS (Moderate Resolution Imaging Spectroradiometer) se encuentran a bordo de los satélites Aqua y Terra, y proveen una vasta gama de aplicaciones para el estudio de procesos de degradación de tierras. El satélite Terra recopila datos durante el día, mientras que el Aqua lo hace en la tarde/noche. Entre las principales ventajas que ofrecen los datos MODIS está su alta frecuencia temporal, lo que permite disponer de datos y productos de forma diaria hasta mensual. Para periodos mayores a un día, los productos son compuestos formados a partir de los máximos valores registrados en los píxeles, removiendo en gran medida los efectos atmosféricos y de las nubes. Asimismo, la resolución espacial varía entre los 250 m, 500 m, 1 km y 5.6 km. Las imágenes productos MODIS son de distribución libre. En la Tabla 2.1 se detallan los principales productos derivados a partir del análisis de las imágenes MODIS, que son de relevancia para el estudio de los RRHH.

Para fines del caso estudio, se adquirieron un total de 330 imágenes productos de NDVI (MOD 13), con resolución espacial de 250 metros (6.25 ha/píxel) y cubriendo el periodo 2000-2013. El hecho de que cada imagen es un compuesto de 16 imágenes diarias (lo que tiene la ventaja de reducir el número de píxeles cubiertos por nubes), permite llevar a cabo estudios de evolución temporal y espacial de la cobertura vegetal.

Las imágenes-productos MOD 13, así como una amplia gama de productos diversos generados a partir del análisis de imágenes MODIS, pueden accederse forma libre a través del portal web: <http://edcdaac.usgs.gov/modis/dataproduct.html>.

Tabla 3.1: Principales productos MODIS con aplicaciones para estudios de degradación de tierras y sequías. MOD y MYD corresponden a los sensores MODIS del satélite Terra y Aqua, respectivamente.

Producto	Código	Resolución espacial	Resolución temporal	Aplicación
Agua Precipitable Total	MOD 05	1 km	Diaria	Climatología del ciclo hidrológico
Reflectancia	MOD 09	250m-1km	1-8 días	Modelamiento del balance de energía de la superficie, tipo de uso de suelos. Permite calcular los índices de vegetación y agua (NDVI y NDWI, respectivamente)
	MYD 09			
Temperatura de la superficie de suelo	MOD 11	1-5.6 km	5 min, diario, 8 días, 1 mes	Insumo para modelos hidrológicos. Conjuntamente con el NDVI permite estimar el estrés hídrico
	MYD 11			
NDVI & EVI	MOD 13	250 m, 500 m, 1 km, 5.6 km	16 días, 1 mes	Modelado hidrológico, tipos de uso de suelos, estudios de degradación de tierras.
	MYD 13			
LAI/FPAR	MOD 15	1 km	diaria, 8 días	Estimación de la producción neta primaria, evapotranspiración
	MYD 15			
ET	MOD 16	1 km	8 días, 1 año	Balance de agua global, producción neta primaria

3.1.2 Imágenes de la serie LANDSAT

Las imágenes TM (*Thematic Mapper*), ETM+ (*Enhanced Thematic Mapper Plus*) y OLI (*Operational Land Imager*), a bordo de los satélites Landsat (<http://landsat.gsfc.nasa.gov/>), son de libre acceso y tienen una frecuencia temporal de 15 días a un mes. Sin embargo, para zonas con relativa alta presencia de nubes, en la práctica se consiguen en promedio una imagen de calidad por año.

Las imágenes TM y ETM+ son empleadas para la ubicación y delimitación de cuerpos de agua (aguas superficiales, humedales, bofedales), así como en estudios de la calidad de lagunas/lagos, principalmente. Asimismo, en vista de que cuentan con una banda en el rojo térmico (banda 6),

permiten la obtención de mapas de la temperatura de superficie de suelos (LST) y evapotranspiración (ET).

El 11 de febrero del 2013 fue puesta en órbita la misión LANDSAT 8 (Landsat Data Continuity Mission - LDCM), cuyas características técnicas se encuentran en la siguiente tabla. A partir de mayo del 2013 se encuentran accesibles las imágenes registradas por el sensor OLI. Estas cuentan con 13 bandas espectrales, abarcando desde el rango del visible hasta el infrarrojo térmico. Por su parte, la resolución espacial mínima para las bandas multiespectrales es de 30 m (900 m²/píxel o 0.09 ha/píxel) y 15 m (225 m²/píxel o 0.023 ha/píxel) para la banda pancromática. Las imágenes pueden descargarse libremente a través del portal web de la *United States Geological Survey* – USGS (<http://glovis.usgs.gov/>).

Tabla 3.2: Especificaciones técnicas de las imágenes OLI

Banda	Longitud de onda (μm)	Resolución espacial (m)
Band 1 - Coastal aerosol	0.43 - 0.45	30
Band 2 - Blue	0.45 - 0.51	30
Band 3 - Green	0.53 - 0.59	30
Band 4 - Red	0.64 - 0.67	30
Band 5 - Near Infrared (NIR)	0.85 - 0.88	30
Band 6 - SWIR 1	1.57 - 1.65	30
Band 7 - SWIR 2	2.11 - 2.29	30
Band 8 - Panchromatic	0.50 - 0.68	15
Band 9 - Cirrus	1.36 - 1.38	30
Band 10 - Thermal Infrared (TIRS) 1	10.60 - 11.19	100
Band 11 - Thermal Infrared (TIRS) 2	11.50 - 12.51	100

Para el caso del área de estudio, se descargó un total de 101 imágenes del sensor OLI (*Operational Land Imager*) a bordo del satélite LANDSAT 8. El detalle del número de escenas por Path/Row están dadas en el siguiente cuadro:

Número de escenas	Path	Row
27	10	63
26	10	64
26	11	63
22	11	64

Las fechas de adquisición comprendió el periodo entre mayo del 2013 y abril del 2014, obteniéndose una imagen de buena calidad por mes.

3.2 GENERACIÓN DE PRODUCTOS (MAPAS DE NDVI)

3.2.1 Pre-procesamiento de imágenes OLI

Con el propósito de generar los mapas de NDVI, así como otros parámetros de interés para el estudio de la degradación de tierras (p.ej. reflectancia y el índice de salinidad), las imágenes provenientes de los satélites LANDSAT deben ser pre-procesadas para eliminar las distorsiones y contribuciones espurias producto de las interacciones fuente – atmósfera – objeto – sensor. Cabe resaltar que esto no es necesario para el caso de las imágenes-producto MODIS (MOD 13), en vista de que ya cuentan con el pre-procesamiento respectivo.

Las imágenes OLI, al igual que las ETM+, cuentan con una corrección geométrica (e.d. los píxeles están geo-referenciados). Para el presente estudio, las tareas de pre-procesamiento involucraron la calibración radiométrica (conversión de los números digitales a radiancia) y corrección atmosférica (conversión de radiancia a reflectancia). A continuación, se describe cada uno de los pasos seguidos. Mayores detalles técnicos están disponibles en una serie de textos y tutoriales relevantes al tema (p.ej. http://lms.seos-project.eu/learning_modules#2).

CALIBRACIÓN RADIOMÉTRICA

Durante el registro de las imágenes se producen distorsiones radiométricas relacionadas con la iluminación, la composición y estructura de la atmósfera. Para que sean válidas las comparaciones entre imágenes satelitales de diferentes fechas de adquisición, éstas deben ser corregidas radiométricamente. Uno de los procedimientos más comunes para este fin, consiste en convertir los números digitales *ND* de cada píxel a valores de radiancia espectral. Las imágenes obtenidas de los sensores TM, ETM+ y OLI a bordo de los satélites Landsat 5, Landsat 7 y Landsat 8, respectivamente, contienen números digitales. El proceso de conversión de números digitales a valores de radiancia espectral requiere de la información de la ganancia (Gain) y del sesgo (Bias) del sensor para cada banda. Éstas constantes forman parte de un conjunto de información técnica que acompaña a cada imagen (metadatos). El valor del Gain representa la pendiente de la recta de

calibración que se muestra en la Figura 2.1, mientras que el Bias define la radiancia espectral del sensor para un valor de ND igual a cero.

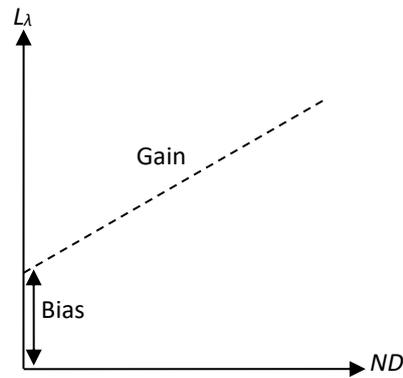


Figura 3.1: Representación gráfica de radianza (L_{λ}) versus ND

El valor de radiancia espectral para cada pixel se obtiene usando la ecuación de una recta (Markham y Barker, 1986), cuyas unidades están expresadas como $W/m^2 \cdot sr \cdot \mu m$.

$$L_{\lambda} = Gain(ND) + Bias \quad (1)$$

CORRECCIÓN ATMOSFÉRICA

Los números digitales de los pixeles en una imagen contienen los efectos de la interacción de la radiación con la atmósfera, por lo tanto, si se desea obtener información acerca de las superficies de interés (que en nuestro caso viene a ser el suelo y la cobertura de éste), es necesario eliminarlos a través de una corrección atmosférica de los datos imagen. Para el presente trabajo, se empleó el módulo FLAASH disponible en el software ENVI. Los parámetros ingresados se encuentran señalados en los cuadros en rojo (Figura 3.2).

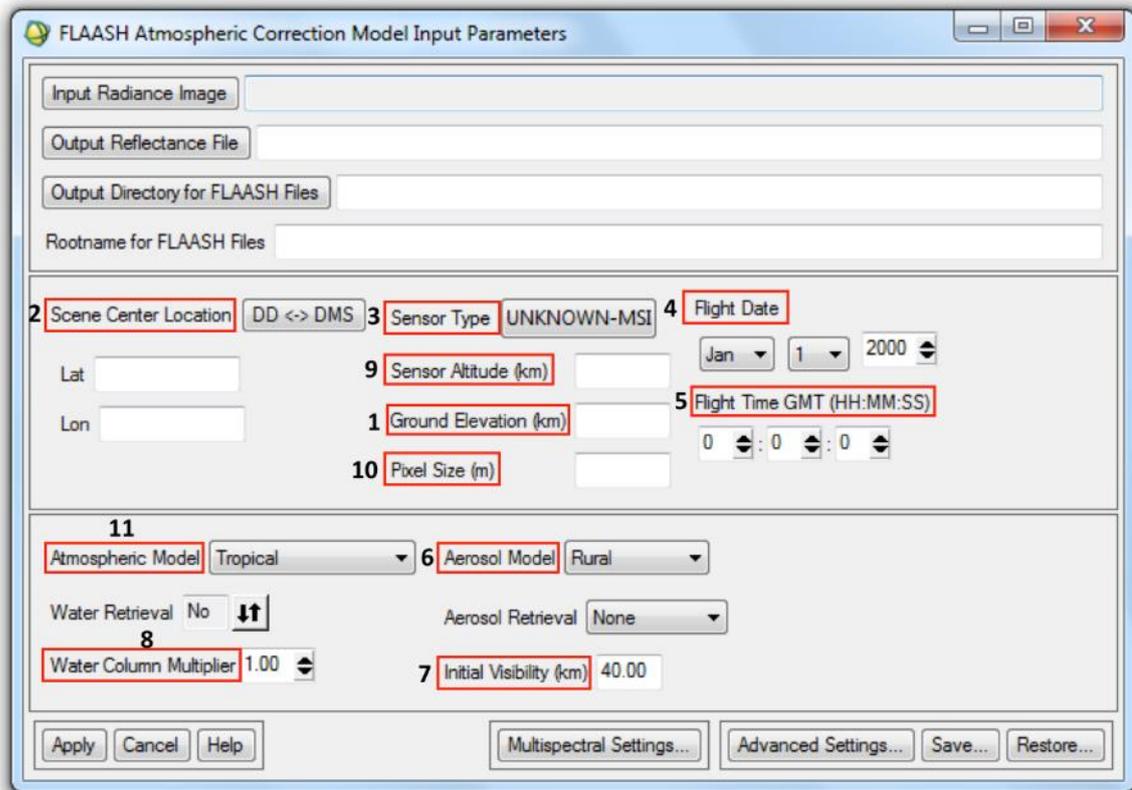


Figura 3.2: Vista del módulo FLAASH disponible en el software ENVI®.

El módulo FLAASH usa los datos de la librería espectral de los sensores para hacer la corrección atmosférica, los que pueden ser adquiridos a través del portal de la USGS (<http://speclab.cr.usgs.gov/>). En la Figura 3.3 se muestran como ejemplo, las librerías de los sensores TM, ETM+ y OLI.

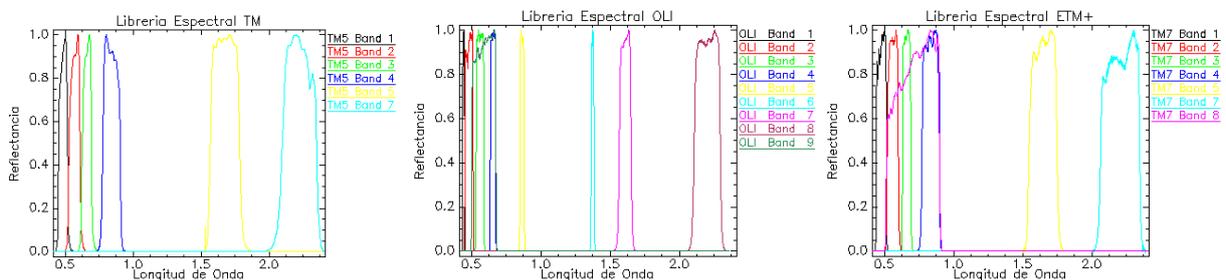


Figura 3.3: Librerías espectrales de los sensores TM, ETM+ y OLI

Como resultado del procesamiento, son generados los datos de reflectancia de las imágenes. Estos permiten identificar los tipos de superficie que generan la información registrada. La firma espectral, que viene a ser la reflectancia en función de la longitud de onda de la radiación incidente, constituye

una especie de huella dactilar de los cuerpos. A modo de ejemplo, en la Figura 2.4 se muestran 5 firmas espectrales correspondientes a diferentes tipos de superficie.

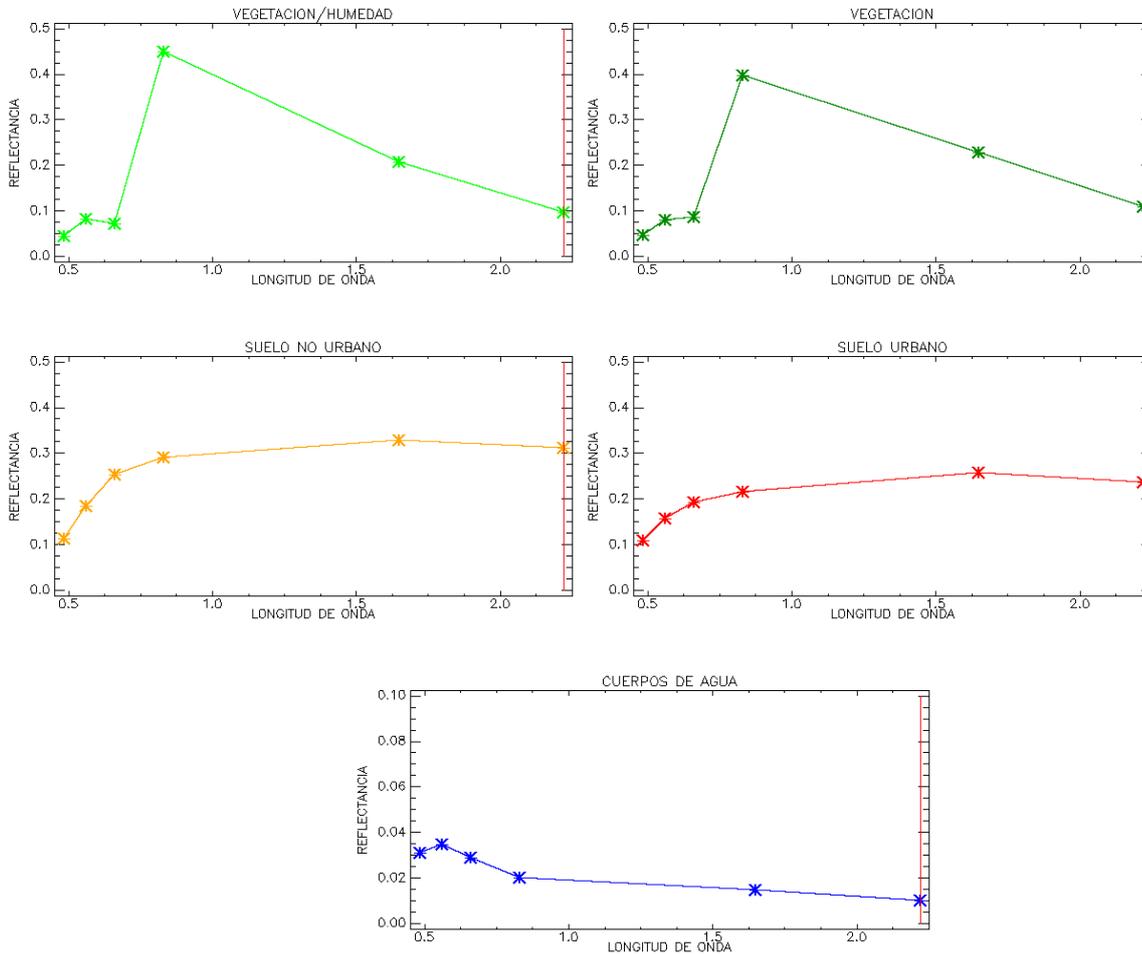


Figura 3.4: Firma espectral de una superficie de vegetación húmeda, vegetación, suelo, suelo urbano y cuerpos de agua.

OBTENCIÓN DE LA REFLECTANCIA PLANETARIA EN LAS IMÁGENES DE LA SERIE LANDSAT

Para el caso de imágenes libres de nubes y con baja presencia de aerosoles, una alternativa constituye la reflectancia planetaria, la cual puede ser obtenida a través de la siguiente fórmula (Williams, 2004).

$$\rho_p = \frac{\pi x L x d^2}{ESUN_\lambda x \cos \theta} \quad (2)$$

Donde:

- ρ_p es la reflectancia planetaria
- L es la radianza espectral en la apertura del sensor
- $ESUN_\lambda$ es la irradiancia exo-atmosférica solar promedio de cada banda
- θ es el ángulo cenital solar
- d_n es el día del año
- d es la distancia Tierra- Sol, que es a su vez calculada por de la ecuación.

$$d = (1 - 0.01672x \cos(\text{RADIAN}(0.9856x(d_n - 4))))^2 \quad (3)$$

3.2.2 Obtención de imágenes-producto NDVI

En percepción remota existen un conjunto de parámetros e índices numéricos que pueden ser empleados como proxy para estimar y evaluar el estado de salud de la vegetación, en base a la medición de la radiación que las plantas emiten o reflejan. Uno de éstos es el Índice de Vegetación de Diferencia Normalizada (NDVI), el cual ha demostrado su utilidad para la discriminación de tipos de coberturas vegetales, medición del vigor de las plantas y la producción de la biomasa. El NDVI aprovecha el comportamiento radiométrico de la vegetación relacionado con la actividad fotosintética y la estructura foliar de las plantas; a saber, las hojas absorben la luz visible, mientras emiten en el infrarrojo cercano.

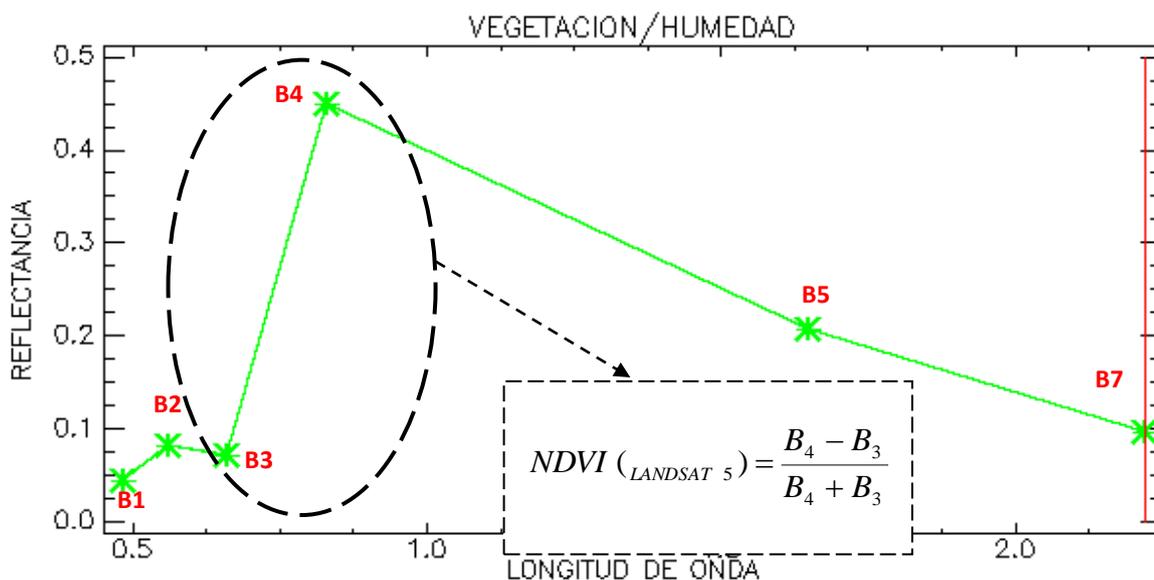


Figura 3.5: Firma espectral de una superficie de vegetación húmeda. Observe la diferencia notoria entre los valores de reflectancia de las bandas 3 y 4.

La ecuación general del NDVI está dada por (Chen et al., 2005):

$$NDVI = \frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + \rho_R} \quad (4)$$

donde ρ_{NIR} es la reflectancia en el infrarrojo cercano y ρ_R en el rojo visible. El NDVI permite determinar si la vegetación se encuentra sana o si tiene algún grado de estrés, y sus valores oscilan entre -1 y 1. Las superficies cubiertas por agua tienen baja reflectividad en ambas bandas espectrales así que serán caracterizadas por valores de NDVI cercanas a cero. Por su parte, el suelo desnudo en general presenta una reflectividad en la banda del infrarrojo cercano ligeramente superior a la de la banda del rojo así que tendrá valores de NDVI ligeramente positivos.

Para el caso de las imágenes OLI, el NDVI debe ser obtenido a partir de la combinación de las bandas 4 y 3:

$$NDVI = \frac{B4 - B3}{B4 + B3} \quad (5)$$

3.3 ESTADÍSTICA DE IMÁGENES: PROMEDIO, MÁXIMO Y MÍNIMO COMPUESTO

La alta frecuencia temporal de los productos MOD 13 de MODIS (compuestos de cada diez días y mensuales) posibilita llevar a cabo análisis de series de tiempo con el fin de establecer información relevantes a la evolución de los ecosistemas de interés. Ordenando las imágenes de forma cronológica, el valor de cada píxel varía en el tiempo lo que a su vez está relacionada con la dinámica de la cobertura del área que representa. De esta manera, es posible recabar información acerca de las tendencias, valores medios, anomalías, valores máximos y mínimos, entre otros parámetros estadísticos de interés.

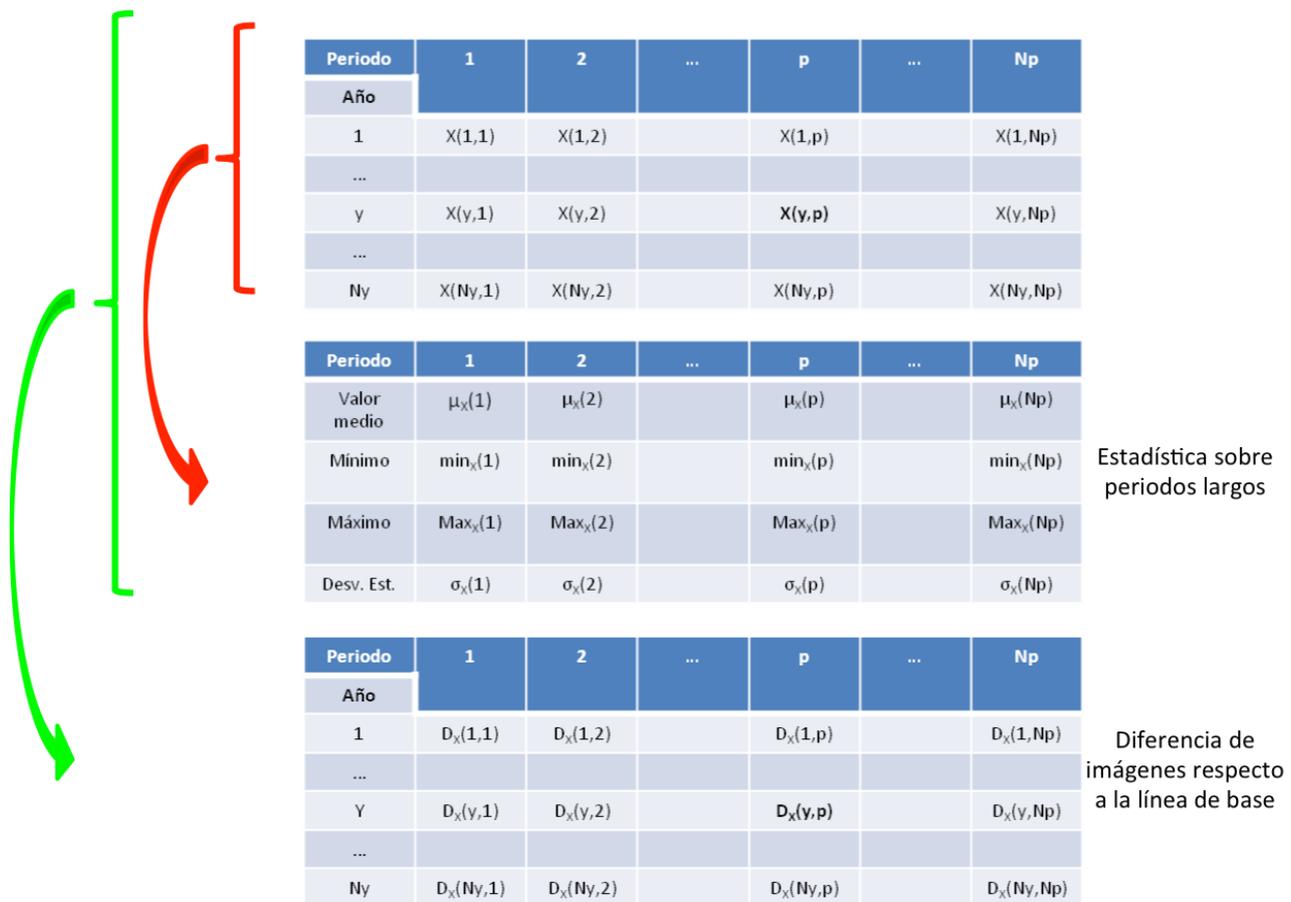


Figura 3.6: Las imágenes son apiladas según el orden cronológico y con un espacio temporal constante entre sí. Dependiendo si son imágenes mensuales o de cada diez días, Np puede ser 23 o 12. El cálculo de los parámetros estadísticos conlleva hacia la generación de una información de línea de base (flecha roja), la que en combinación con las series de imágenes permite a su vez determinar anomalías y tendencias (flecha verde).

Una escena típica del área de estudio, vista a través de una imagen de satélite, resalta la presencia de zonas agrícolas, arbustos y vegetación perenne que rodea a las chacras, cuerpos de agua y canales, centros poblados, carreteras y nubes, entre otros. De todos estos, los elementos más dinámicos vienen a ser las nubes (no nos interesa) y cultivos (sí nos interesa). La cobertura de las áreas agrícolas evolucionan de manera estacional, siguiendo los ciclos propios de cada cultivo (dos veces al año, anual o multi-anual), por lo que el NDVI presenta valores máximos (vegetación en su plenitud) y mínimos (p.ej. después de la cosecha).

La obtención del máximo (mínimo) compuesto de un conjunto de imágenes da como resultado una nueva imagen, cuyos píxeles corresponden a los de mayor (menor) valor de la serie. Por su parte, la

imagen promedio se obtiene a partir de la suma de los píxeles en el tiempo dividida, entre el número total de imágenes. A modo de observación, la estadística debe realizarse con los píxeles que coinciden geográficamente, es decir, corresponden a la misma posición.

Para propósitos del estudio, se han analizado la evolución de imágenes del máximo valor compuesto, los que han sido generados para cada año. Partiendo del hecho de que las áreas degradadas presentan una vegetación dispersa y/o poco vigorosa, se espera que los correspondientes valores máximos del NDVI sean siempre menores respecto a los que presentan los terrenos en buen estado. Por su parte, las imágenes de mínimo compuesto nos permiten identificar la vegetación perenne, mientras que las imágenes promedio el estado “normal” del área. En la figura siguiente se muestra gráficamente las diferentes estadísticas.

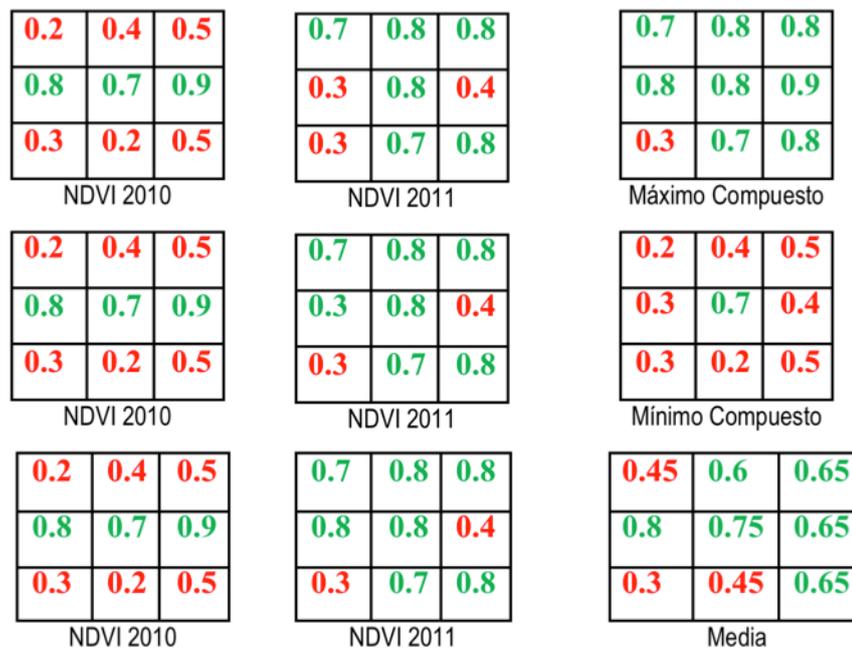


Figura 3.7: El ejemplo muestra los valores del NDVI de cada píxel correspondientes a dos años distintos, así como las estadísticas generadas. Para el caso del máximo (mínimo) compuesto, se genera una nueva imagen comparando los valores de cada píxel en los dos años, seleccionándose el mayor (menor). Por su parte, la imagen media se obtiene de promediar los valores.

IV. PREDICCIÓN DE ÁREAS DEGRADADAS: MODIS → OLI → RAPIDEYE

A continuación, se discute la aplicación de la metodología descrita en la sección anterior, tomando como caso estudio la región Piura.

4.1 ANÁLISIS DE SERIES TEMPORALES DE LAS IMÁGENES-PRODUCTO NDVI DE MODIS

Primero, fueron generados un total de 14 imágenes de máximos compuestos anuales ($NDVI_{Max}$), cada una a partir de un promedio de 23 imágenes por año. Se cubrió el periodo comprendido entre los años 2000 y 2013, con una frecuencia temporal de 16 días. De la misma manera, se obtuvieron las imágenes de mínimo compuesto y promedio. En la Figura 4.1 se presenta las 14 imágenes de promedio anual, correspondientes a la región de Piura. Una comparación entre las imágenes del 2000 y 2013 resalta la expansión de terrenos agrícolas en el valle del río Chira a partir del 2007.

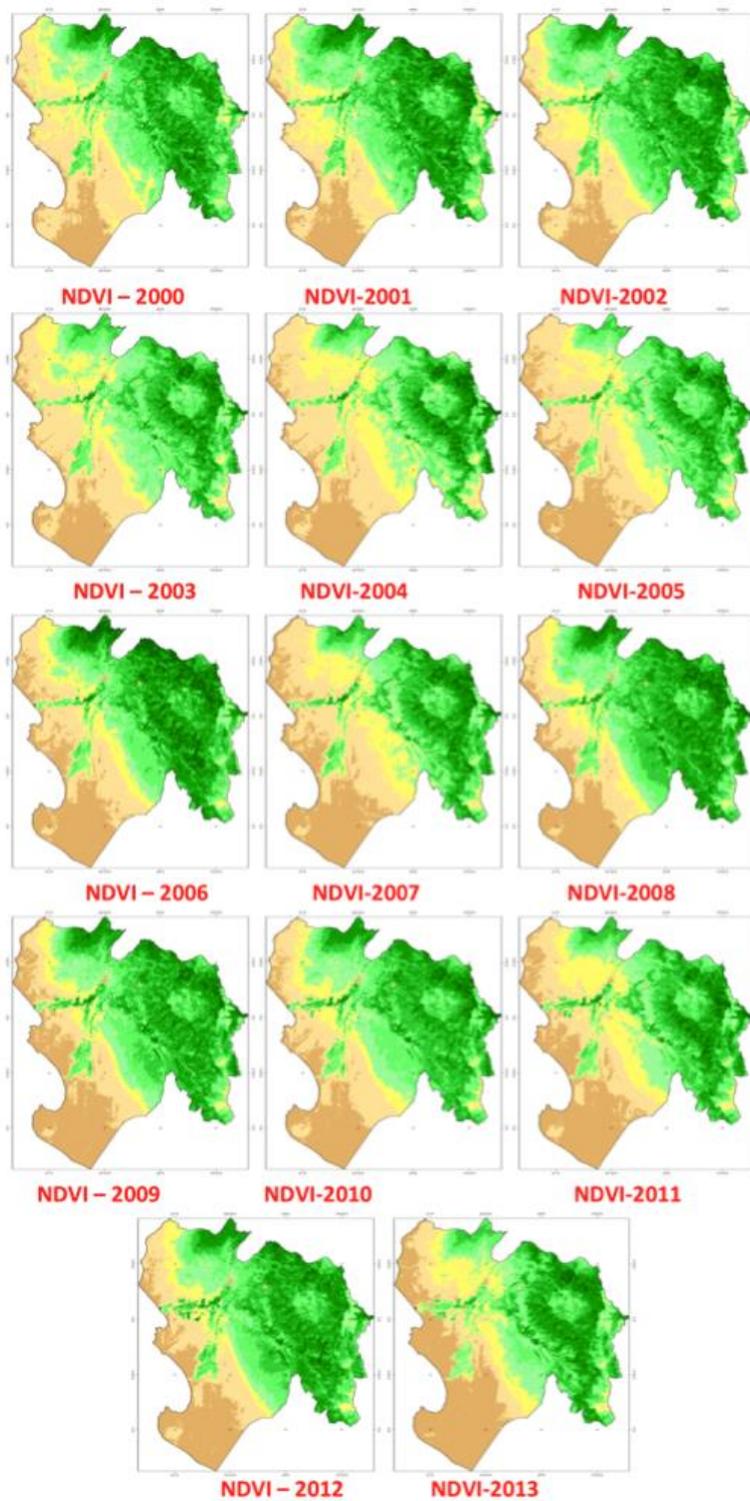


Figura 4.1: Imágenes del NDVI (promedio anual) de la región de Piura los años 2000 al 2013. Cada imagen es un promedio de 23 imágenes MODIS (producto MOD 13).

De acuerdo a la información disponible en la base de datos de producción agrícola del Ministerio de Agricultura y Riego (MINAGRI)⁶, la región Piura viene experimentando un crecimiento sostenido en cuanto a la producción agrícola desde el año 2000. La relación entre el NDVI correspondiente a las áreas agrícolas y el rendimiento agrícola a escala regional puede apreciarse en la Figura 4.2. Como puede apreciarse, el NDVI promedio no muestra una tendencia notoria durante el periodo 2000-2012, sino más bien un comportamiento estable que oscila alrededor de 0.7. Por su parte, el rendimiento agrícola total de la región Piura muestra un ligero incremento a razón de 0.13 toneladas/ha/año. Un aspecto resaltante es que, a medida que crece el rendimiento, el valor del NDVI promedio se acerca a 0.8, lo cual está en concordancia con la literatura (p.ej., Maxwell, 2012; Pervez, 2014).

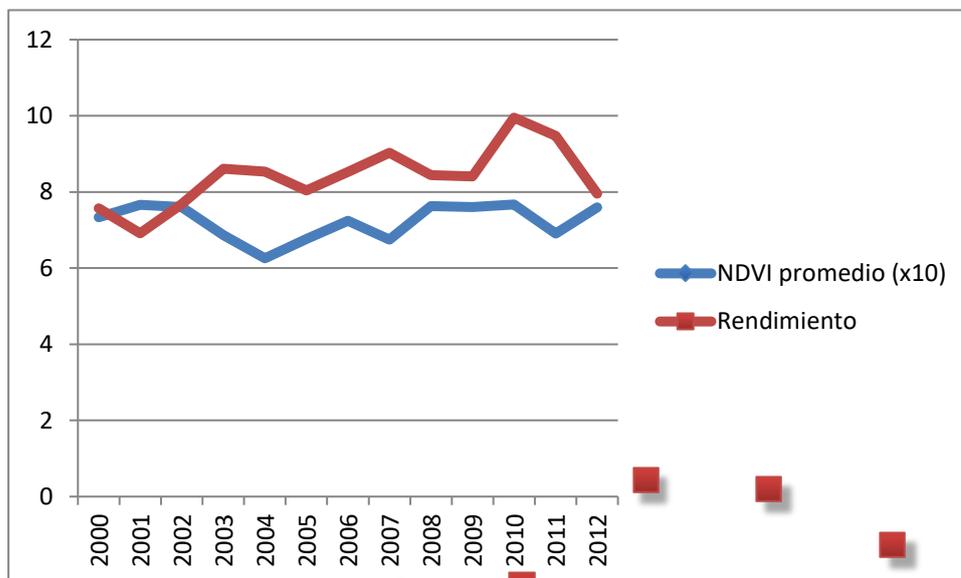


Figura 4.2: Evolución del NDVI promedio (azul) del total de áreas agrícolas de Piura y el rendimiento de los cultivos (tomados de la base de datos del MINAGRI). Con el propósito facilitar la comparación entre ambos parámetros, se multiplicó el valor del NDVI por 10.

Las imágenes de máximo compuesto fueron analizadas con el fin de establecer patrones característicos a los cambios de uso de suelos. En la Figura 4.3 se muestra un caso de urbanización, el cual tiene lugar dentro del área delimitada por la cuadrícula amarilla. La serie temporal del máximo compuesto correspondiente a esa área muestra una clara tendencia negativa, mientras que

⁶ <http://frenteweb.minagri.gob.pe/sisca/>

las imágenes de alta resolución disponibles en el aplicativo Google-Earth permiten confirmar el tipo de cambio de uso de cobertura.

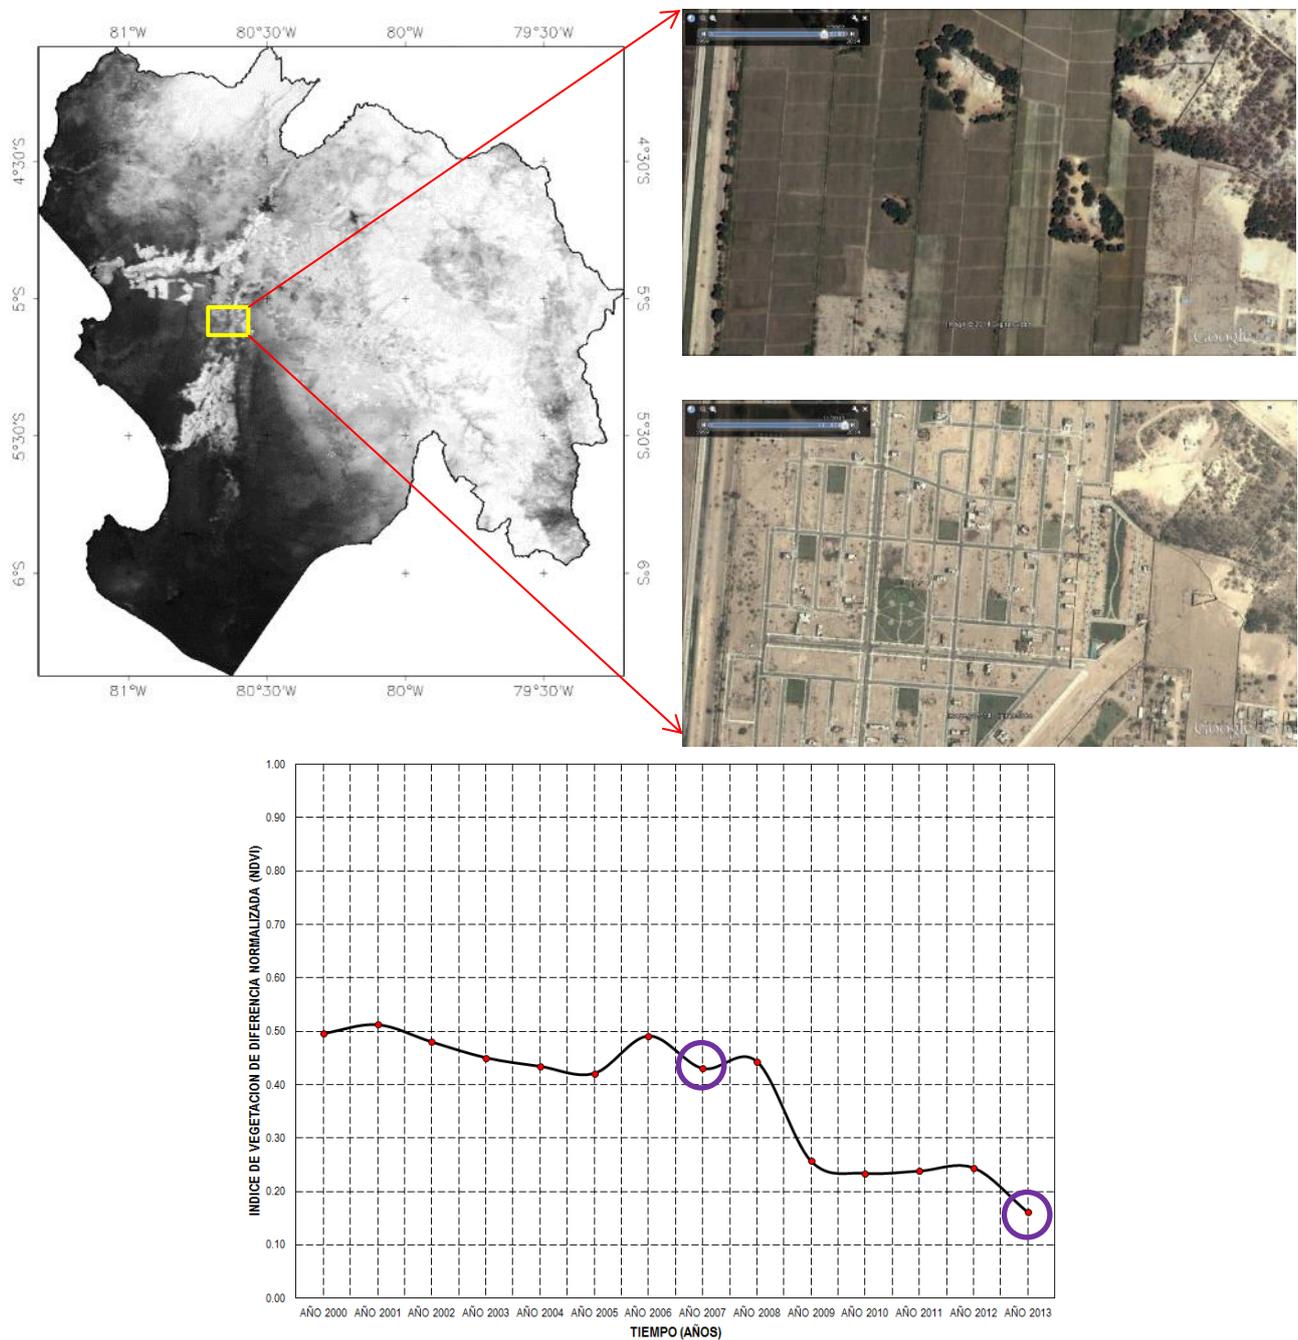


Figura 4.3: Ejemplo de la correlación existente entre la evolución negativa de las series de máximo compuesto y cambio de uso de suelos (urbanización). De acuerdo a la data, el punto de quiebre se da entre el 2008 y 2009.

En el siguiente gráfico (Figura 4.4) se muestran dos casos de evolución del $NDVI_{Max}$. Los círculos rojos denotan un evento de expansión agrícola en una área desértica, mientras que el rectángulo negro podría corresponder a una zona degradada (obsérvese la disminución del valor máximo del NDVI de > 0.5 a 0.1 , lo que denota pérdida total de cobertura vegetal).

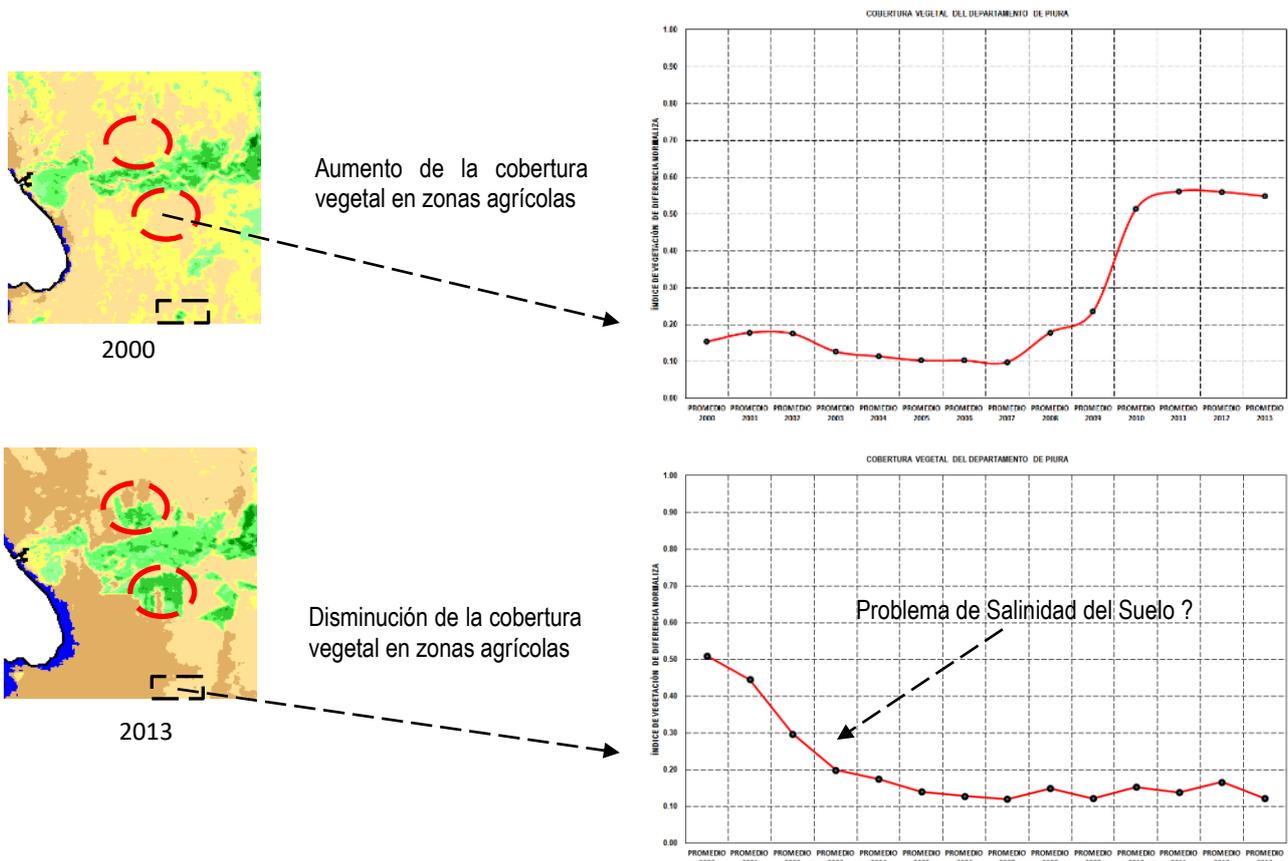


Figura 4.4: Casos de evolución positiva y negativa del máximo compuesto del NDVI. Tendencias negativas podrían estar relacionados a eventos de degradación de suelos.

Los resultados obtenidos claramente realzan la utilidad del NDVI para la identificación de áreas que hayan experimentado cambios de uso de suelos, así como potenciales zonas con procesos de degradación de tierras.

4.1.1 Vector de áreas degradadas en imágenes MODIS

Se aplica la técnica del ISODATA a las imágenes del máximo compuesto anual de la serie MODIS 2000-2013, a fin de generar conjunto de clases que agrupen a los pixeles según el grado de variación del NDVI (es decir, la cobertura vegetal cambia o no drásticamente de un año al otro). En la Figura 4.5 se presentan las 6 clases obtenidas.

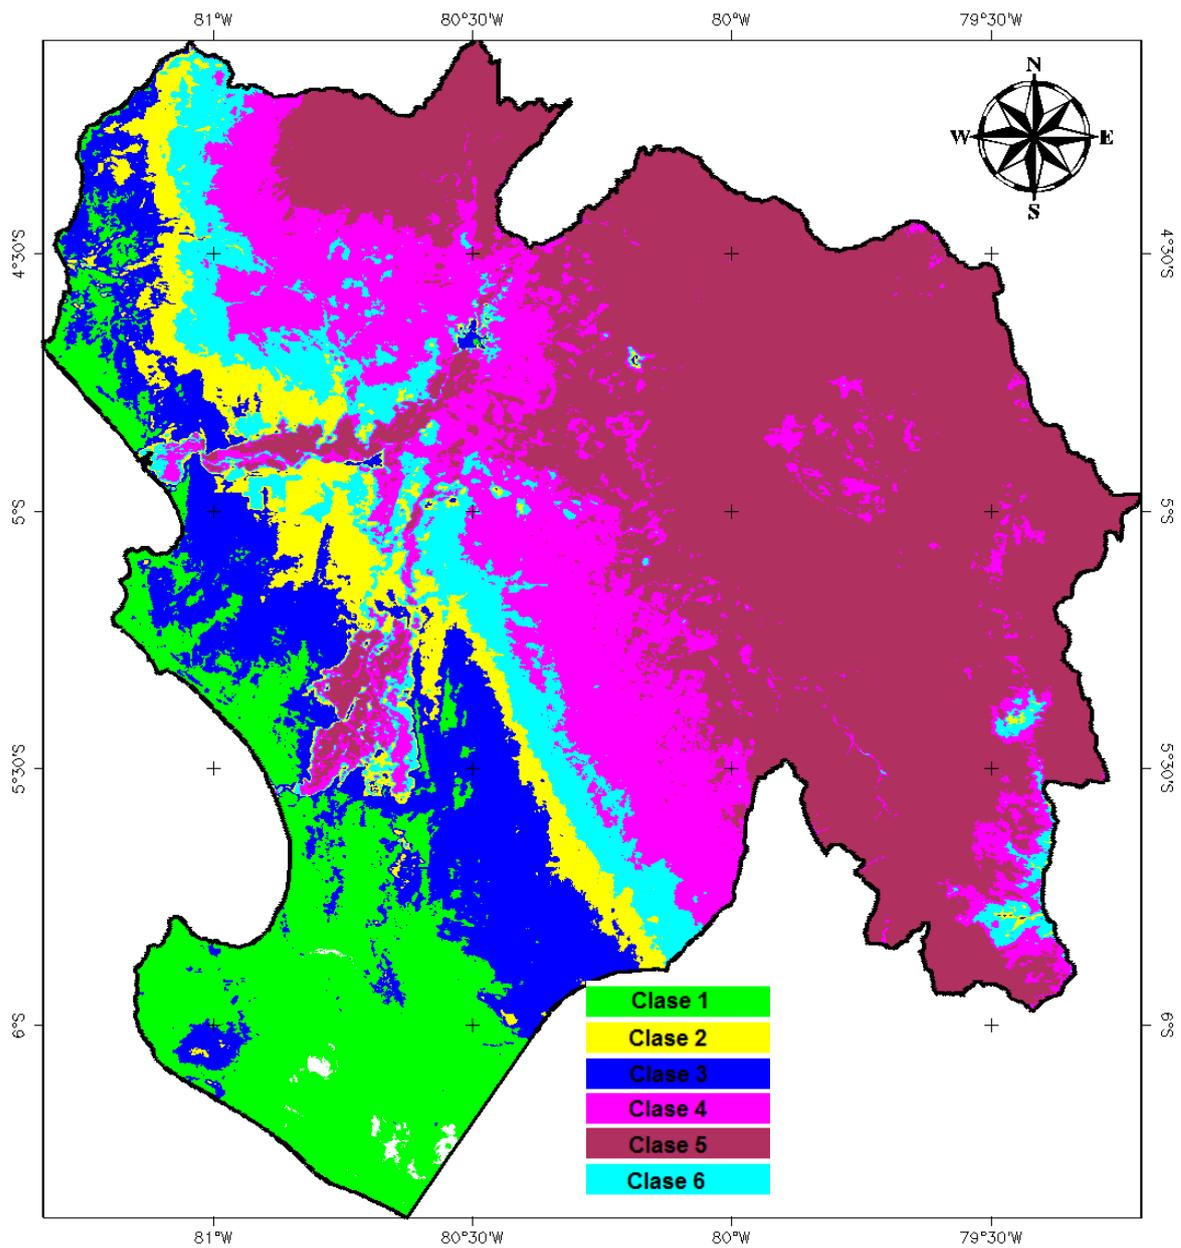


Figura 4.5: Mapa de clases obtenida aplicando la técnica del ISODATA a las imágenes $NDVI_{Max}$ correspondientes al periodo 2000-2013.

Se superponen los vectores correspondientes al área agrícola, las que, para el presente caso, fueron generados como parte del proceso del ZEE (ZEE, 2012). En la Figura 4.6 se presenta la imagen clasificada y filtrada.

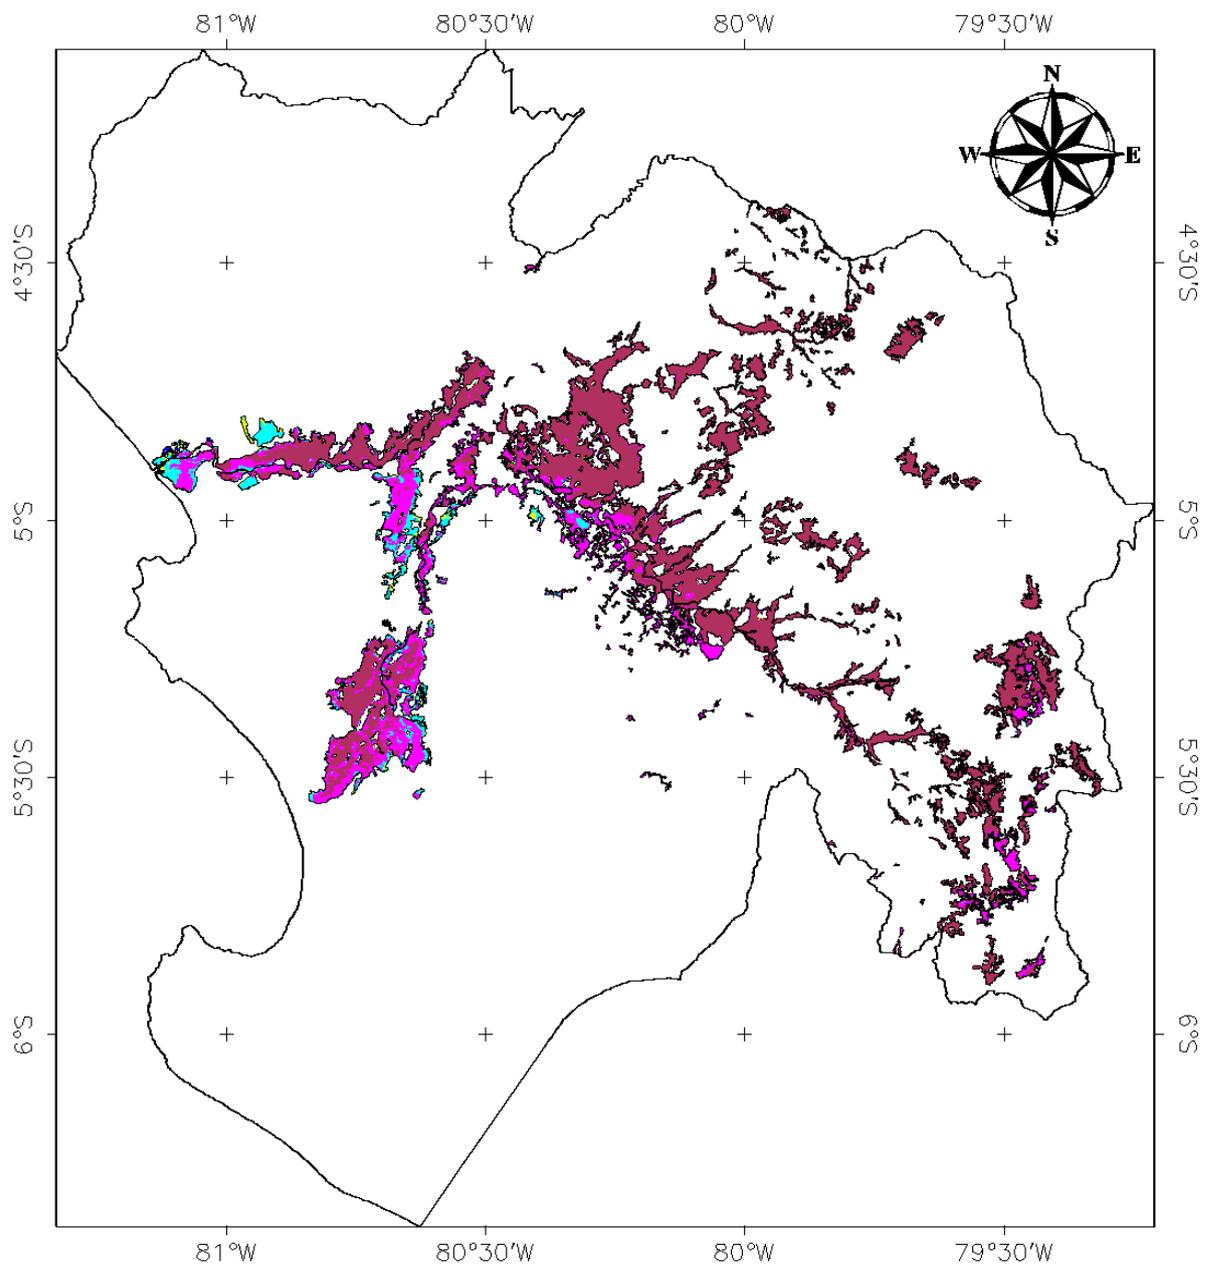


Figura 4.6: Mapa de clases de la Figura 4.5 correspondientes a las superficies agrícolas.

De estas clases se seleccionó la Clase 4 (Figura 3.7), en vista de que los valores del NDVI varían bruscamente de un año a otro año, característica asociada a procesos de degradación (p.ej., salinización y erosión). Los píxeles de la Clase 4 son segmentados y convertidos a formato vector.

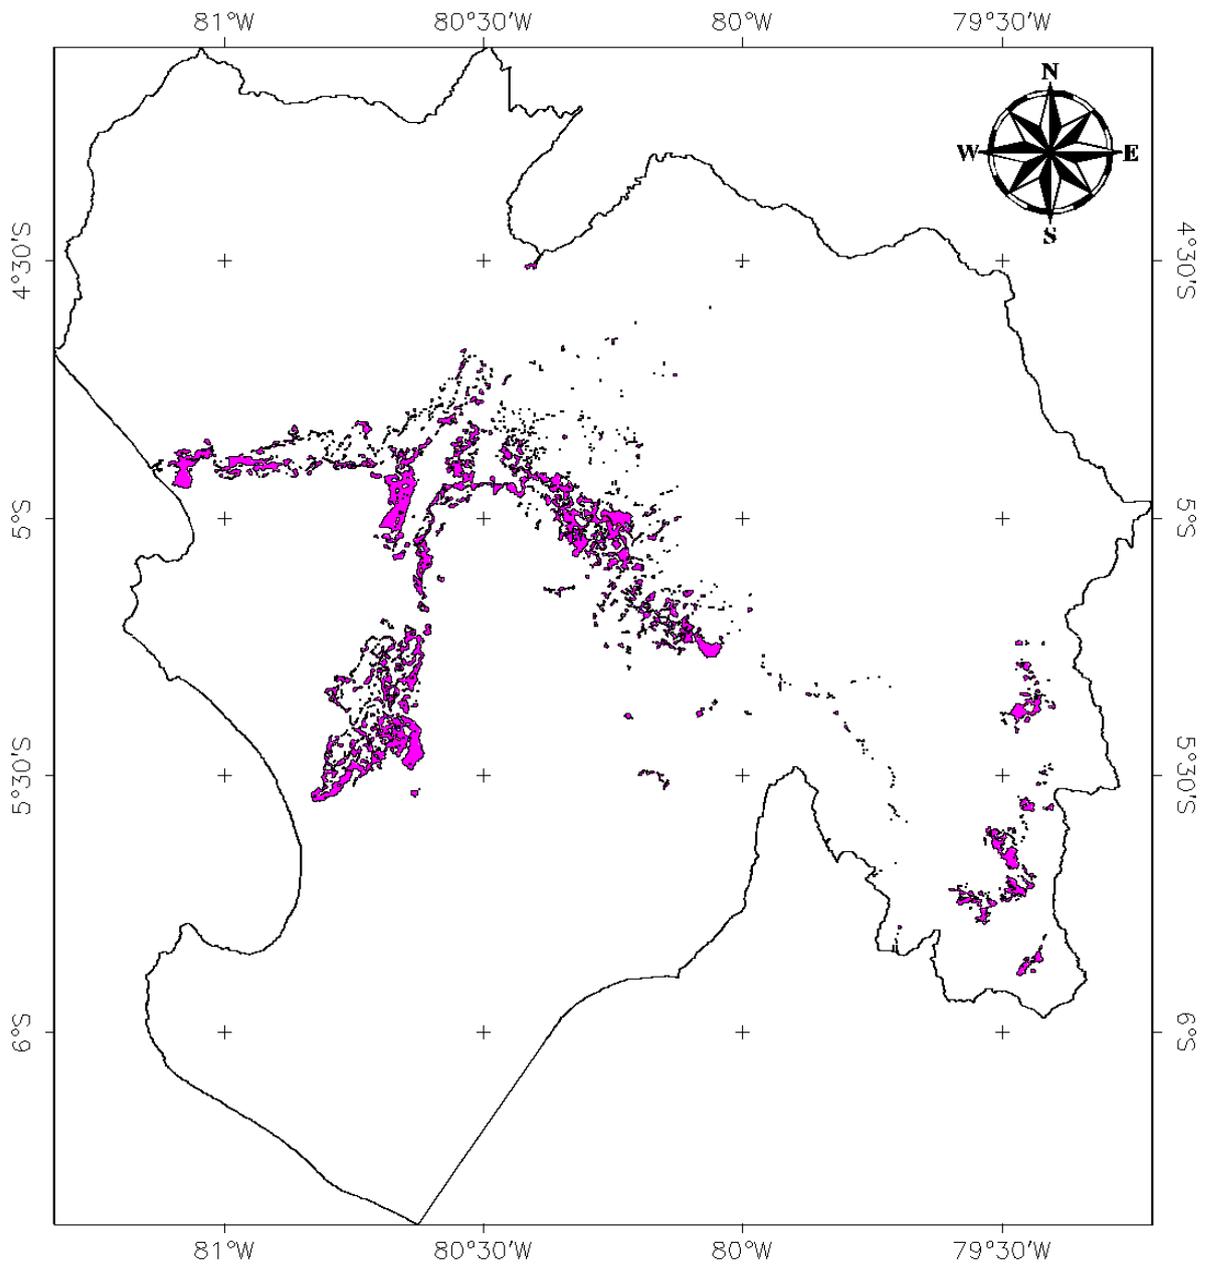


Figura 4.7: Segmentación de la Clase 4.

4.2 ANÁLISIS DE SERIES TEMPORALES DE LAS IMÁGENES NDVI LANDSAT

Las imágenes productos NDVI del sensor OLI (LANDSAT 8) fueron analizadas espacial y temporalmente entre los años 2013 al 2014. A modo de ejemplo, en la Figura 4.8 son presentadas las imágenes mensuales del NDVI para el sector del bajo Chira, correspondientes al área enmarcada dentro del círculo rojo de la Figura 4.5.

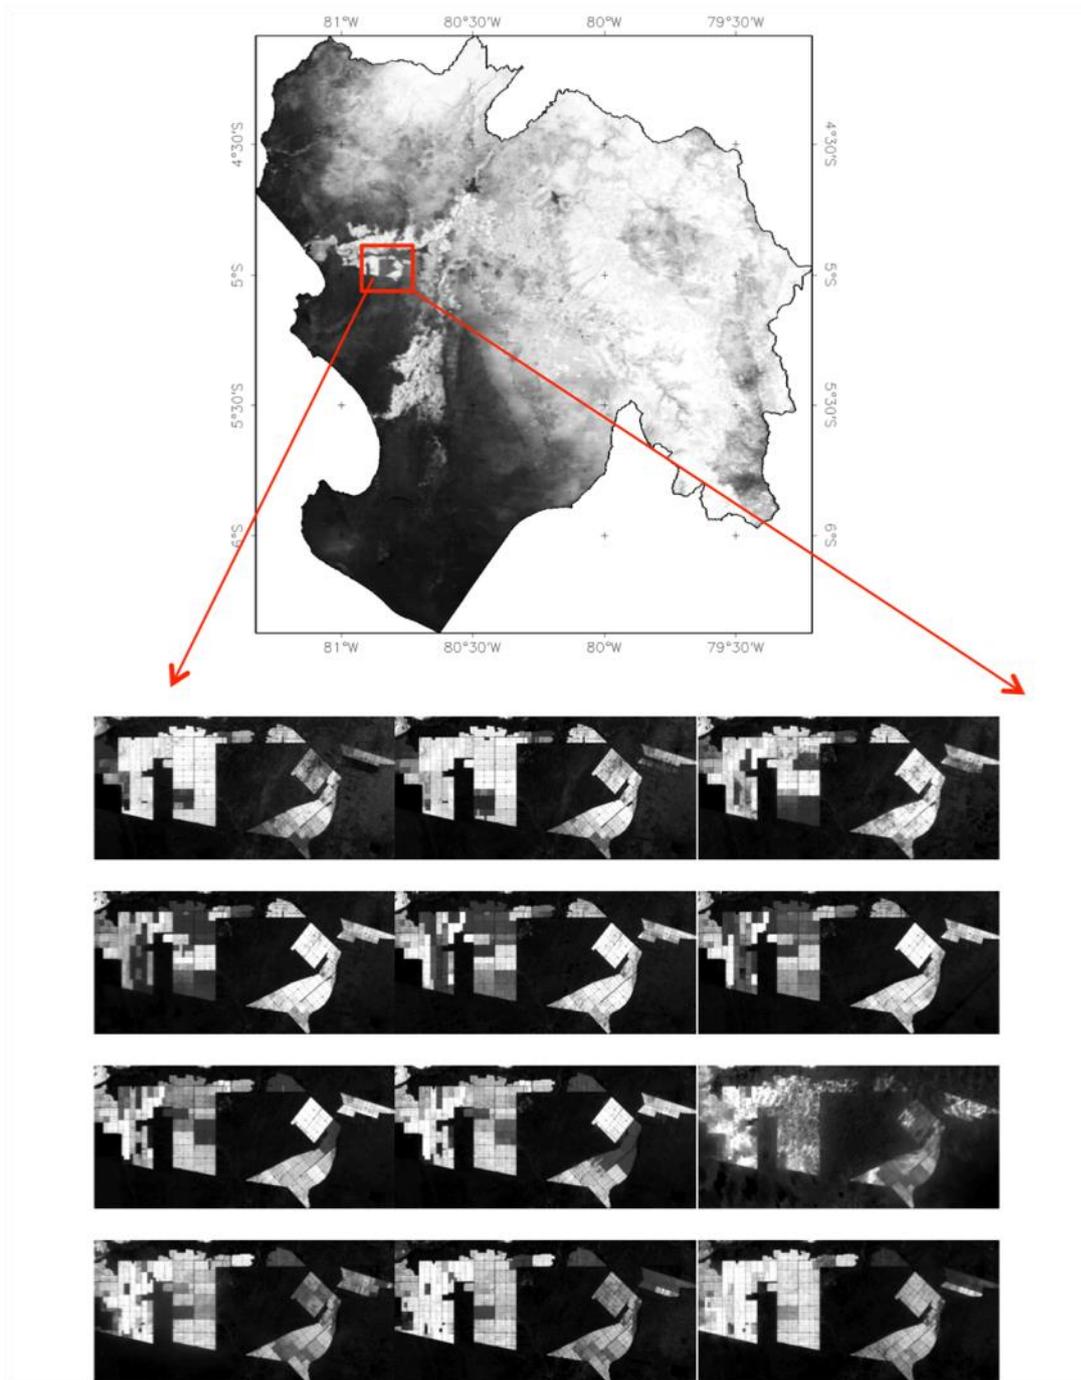


Figura 4.8: Imágenes mensuales del NDVI obtenidos de las imágenes OLI, que datan desde mayo del 2013 (extremo izquierdo arriba) hasta abril del 2014 (extremo derecho abajo).

En la escala de grises, el blanco representa a las superficies con cobertura vegetal, las que usualmente tienen valores de NDVI entre 0.3 y 1. Por su parte, los píxeles oscuros pueden corresponder a suelo desnudo o cuerpos de agua, entre otros. Uno de los problemas comunes en el estudio de eventos de degradación de suelos con imágenes de resolución espacial media, tal como

es el caso del satélite LANDSAT 8, constituye la presencia de nubes. Para solucionar este problema se analizaron imágenes de $NDVI_{Max}$. En la siguiente gráfica, se muestran las imágenes del NDVI promedio, máximo compuesto y mínimo compuesto, los que fueron obtenidos a partir de las imágenes de la Figura 4.8.

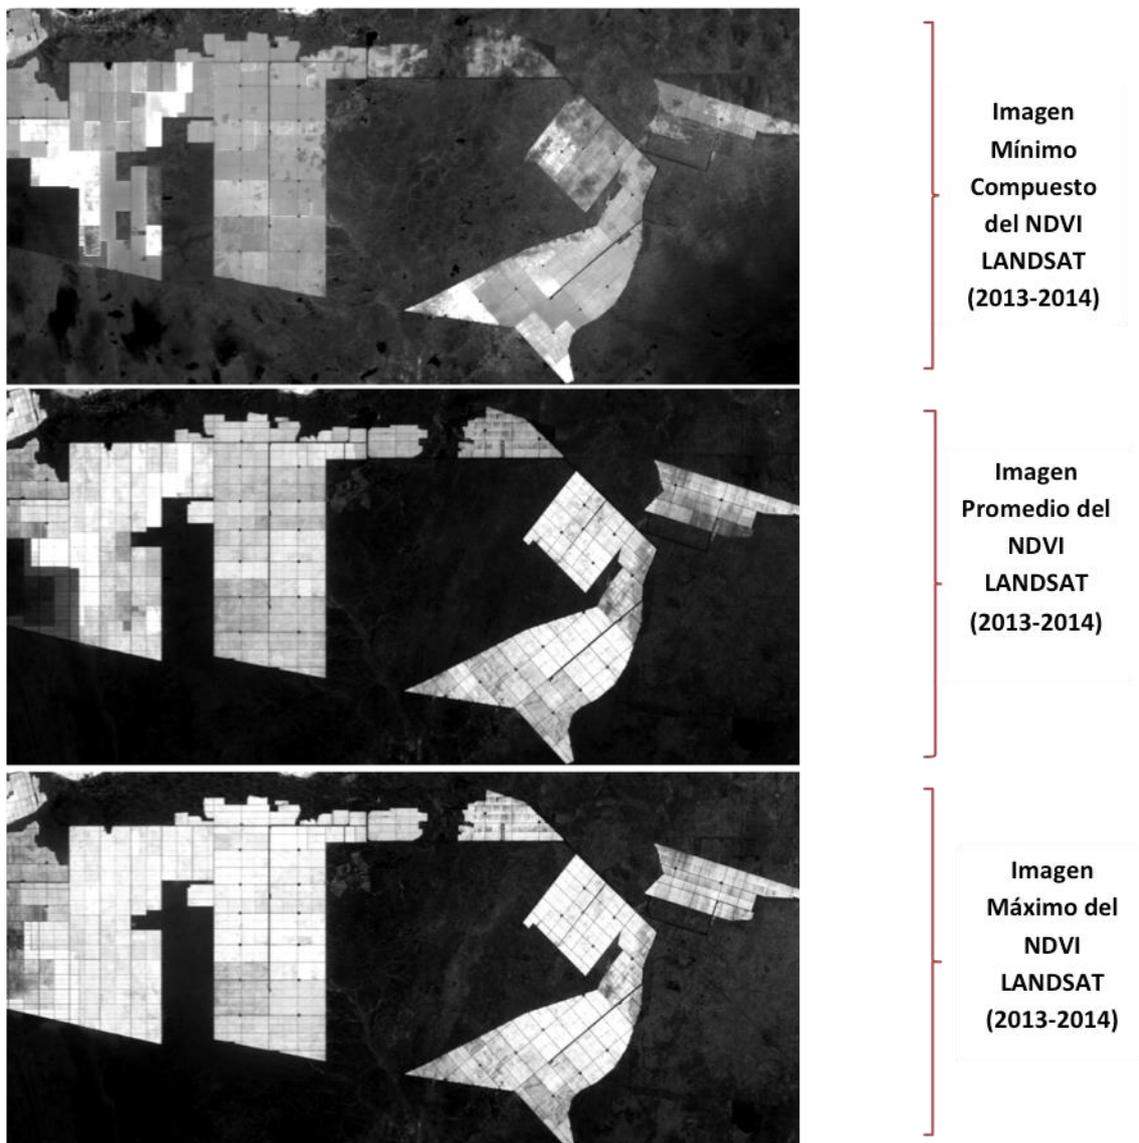


Figura 4.9: Las imágenes promedio, máximo y mínimo compuesto del NDVI se obtuvieron a partir de las imágenes presentadas en la Figura 4.8.

Obsérvese el notorio contraste entre las áreas agrícolas y las demás coberturas para el caso del $NDVI_{Max}$. Dicho contraste es el que ayuda a discriminar áreas degradadas respecto a las no degradadas, al pasar de las imágenes MODIS a las OLI del LANDSAT 8.

El escalamiento de los datos MODIS a OLI permite refinar los resultados de 6.25 ha/píxel a 0.09 ha/píxel, empleando los siguientes criterios:

1. Un píxel de NDVI MODIS contiene más de 64 píxeles del NDVI OLI, por lo que el hecho de que presente una tendencia negativa en su $NDVI_{Max}$ (MODIS), no necesariamente implica que todos los correspondientes píxeles LANDSAT tengan el mismo comportamiento.
2. Si la tendencia del $NDVI_{Max}$ es negativa durante el periodo 2000-2013, sin embargo, presenta valores altos para el 2013-2014, entonces no hay degradación.

4.2.1 Vector de áreas degradadas en imágenes OLI (LANDSAT 8)

Sobre la imagen del $NDVI_{Max}$ (obtenido a partir de las imágenes OLI mensuales), se superpusieron los vectores de superficies agrícolas (Figura 3.10). Se seleccionan los píxeles que se encontraban entre los rangos 0.3 a 0.45, a los que se les asigna el amarillo, tal como se aprecia en a Figura 3.10. Éstos corresponden a las superficies que presentan baja cobertura vegetal.

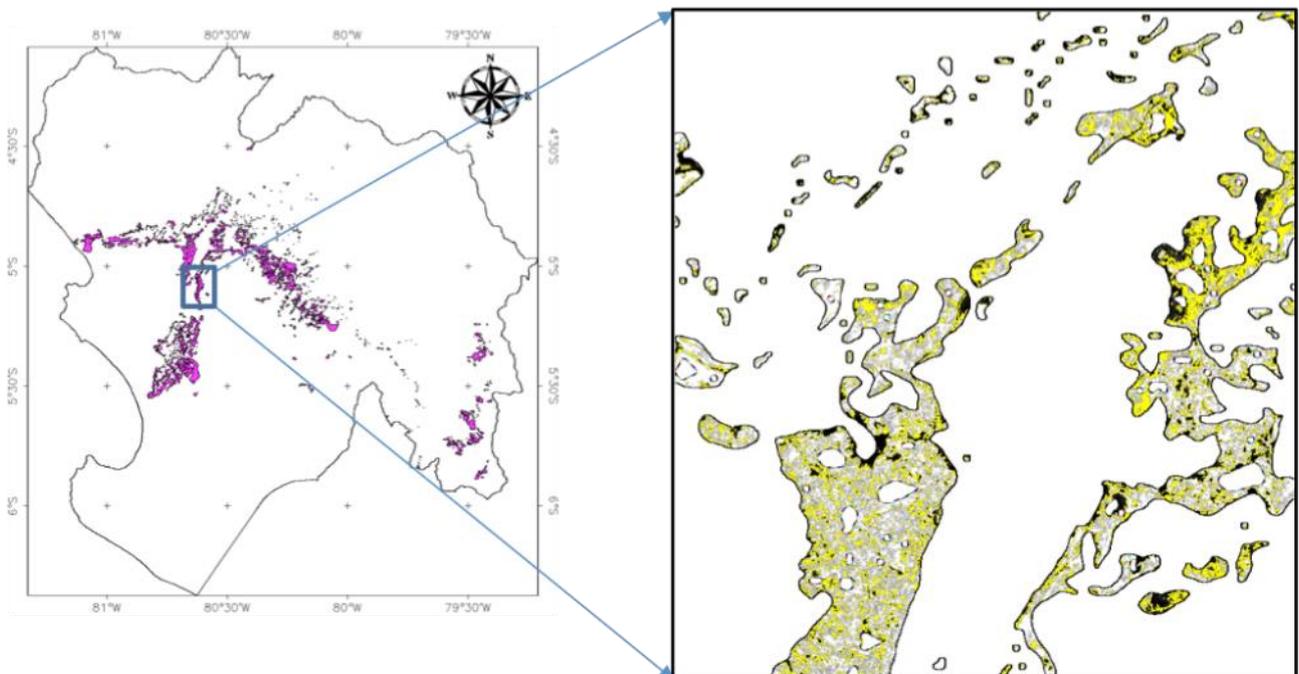


Figura 4.10: Superficies agrícolas sobre la imagen $NDVI_{Max}$ de LANDSAT.

4.3 GENERACIÓN DE VECTORES

De los pasos seguidos, podemos resaltar que los vectores generados en las imágenes MODIS corresponden a aquellas áreas que presentan:

- a) Evolución negativa del NDVI (disminución del valor con el tiempo).
- b) Disminución del valor del NDVI en un cierto año, mientras que en los siguientes aumenta, característica que podría estar asociada a la dinámica de la salinidad, por ejemplo.

Luego de aplicar los vectores obtenidos en las imágenes MODIS al $NDVI_{Max}$ del LANDSAT, se seleccionaron los píxeles que se encontraban con valores de NDVI entre 0.3 a 0.45. Dichos valores corresponden a superficies agrícolas con poca cobertura vegetal. Para el caso de áreas en buen estado, los píxeles de $NDVI_{Max}$ valores cercanos a 1 para el periodo 2013-2014. Por su parte, valores menores a 0.3 resultaban en poblados y cerros, por ejemplo.

Los píxeles identificados en el paso anterior fueron convertidos a vector, los que proveen información a mayor detalle (0.09 ha/píxel) acerca de las áreas con baja cobertura vegetal debido a procesos de salinización, erosión, alcalinización, etc. A su vez, a fin de lograr un mayor refinamiento, a la vez de eliminar falsos positivos, los vectores generados sobre las imágenes OLI fueron exportados a las imágenes RapidEye (5m de resolución espacial y de las fechas 2011-2012). Mediante una para una interpretación monoscópica, se mejoran los contornos.

V. ESTUDIOS DE SUELOS

Los estudios de campo permiten generar información cuantitativa acerca del estado de degradación de los suelos agrícolas en el ámbito geográfico de interés. Es decir, contribuyen con mayor precisión. Sin embargo, demoran y son costosos en vista de que requieren de desplazamiento de personal para la recopilación de muestras y análisis de laboratorios.

Con el propósito de optimizar recursos y tiempos, a la vez de generar información que haga más precisa la identificación de suelos degradados empleando imágenes de satélite, se desarrolló una metodología alternativa. Esta combina una alta participación de los agricultores y se basa en el análisis de la conductividad eléctrica y pH, usando el método de relación suelo-agua 1:5.

El proceso comprende las siguientes etapas:

1. Recopilación de muestras
2. Preparación y análisis de muestras
3. Sistematización y discusión de los resultados

5.1 Recopilación de muestras.

Se toman muestras a nivel de la capa arable (profundidad de hasta 40 cm), zona en la que se localiza la parte más activa del sistema radicular de los cultivos (algodón, maíz, frijoles, hortalizas, etc.). En vista de que la concentración de sales incide en la capacidad de absorción y retención de agua de las raíces, el nivel de la salinidad en dicha capa guarda una relación directa con la capacidad productiva del suelo y con los efectos de las sales en la producción de los cultivos.

La selección de los puntos de muestreo es aleatorio, no estratificado y geo-referenciado (sistema UTM WGS 84). A fin de lograr una maximización en el número de muestras, se hace partícipes a los agricultores locales en las tareas de recolección. Previamente, se organiza un taller para la capacitación en el proceso de recolección de muestras, siguiendo un protocolo sencillo:

1. Siendo conocedor del estado de sus terrenos, el agricultor hace una división (estratificación) del mismo de acuerdo a su productividad (menos productivo → más productivo) y tipo de cultivo.

2. Se ubica en el centro de cada división (estrato) y abre un hoyo rectangular de 30 cm por 30 cm, y 40 cm de profundidad (capa arable).
3. Procede al raspado de las paredes del hoyo, depositando el suelo en una bolsa, la cual se coloca cerrada al costado del hoyo, posteriormente el equipo de recolección de las muestras pasaba con el GPS tomando la ubicación geográfica e indicando al agricultor el traslado de la muestra en algunos casos fueron trasladados por el mismo equipo de investigación.

Como criterio adicional, se recomienda no realizar el muestreo en lugares erosionados, suelos modificados por hormigas u otros insectos, zonas utilizadas como depósitos de fertilizantes, estiércol, mejoradores químicos y/o de paso de maquinaria y animales.

Para cada uno de los predios muestreados, se realiza un registro fotográfico del área alrededor de la calicata y se coloca una ficha en las muestras conteniendo la siguiente información:

Estudio de Suelos - Comisión / Cuenca:	
Muestra N° :	
Fundo:	
Sector:	
Distrito:	
Región:	
Fecha:	
Propietario:	
Ubicación Geográfica (UTM WGS84):	

Finalmente, las muestras son llevadas por el agricultor al local de la comisión o recopiladas en vehículos.



Figura 5.1: (Izquierda) Capacitación a los agricultores de la Comisión de Yuscay y Tablazo Alto. (Derecha) Hoyo del que se recopilan las muestras a nivel de la capa arable.

Comentario: En el caso del estudio en Piura, el procedimiento empleado propició el desarrollo de un proceso altamente participativo, que no solo contribuyó a una optimización en las tareas de recopilación (134 muestras en dos días de trabajo efectivo), sino que, además, fortalecieron las capacidades para el monitoreo de la degradación de suelos. Asimismo, en vista de que los resultados de los análisis fueron entregados en una fecha posterior a los participantes, se ha generado un clima de confianza mutua y constituye una experiencia valiosa de interacción entre gobierno (MINAM, GOREP), la academia y usuarios. Ello facilitará el emprendimiento de iniciativas futuras dentro del marco de la lucha contra la desertificación, como por ejemplo, la implementación de la metodología LADA.

5.2 Preparación y análisis de muestras.

Para la preparación de las muestras, primero se procede con el secado completo. Para ello, las muestras son colocadas sobre una bandeja o manta de plástico, y se les dejó secar al aire durante un periodo de una semana, aproximadamente. Luego, se muelen y deben ser tamizados usando un tamiz N° 10 (2mm de diámetro), con el fin de obtener uniformidad en el tamaño de las partículas y poder separar los restos de raíces y piedras.

Para las mediciones de la conductividad eléctrica y de pH se emplea el método de extracto 1:5 (solución con una relación suelo-agua, de 1 en 5). Tradicionalmente, se usa el método de extracto de saturación (CE_e) o 1:1 (p.ej. ZEE, 2011); sin embargo, este resulta muy laborioso, costoso y

demanda de mucho tiempo para poder llevarlo a cabo. Como alternativa, el método 1:5 ($CE_{1:5}$) permite una identificación de suelos salinos versus no-salinos, así como una sub-clasificación de éstos, de una manera rápida y económica. La Tabla 5.1 nos muestra la equivalencia entre ambos métodos, así como la clasificación correspondiente. Las unidades están expresadas en deciSiemens por metro (dS/m).

Tabla 5.1: Equivalencia de los rangos de valores de CE de extracto y 1:5, y la correspondiente clasificación según grado de salinidad.

CE_e (dS/m)	$CE_{1:5}$ (dS/m)	CLASIFICACIÓN
< 2	< 0.35	No salino
2 – 4	0.35 – 0.65	Ligeramente salino
4 – 8	0.65 – 1.15	Salino
> 8	> 1.15	Muy salino

(Fuente: elaboración propia basado en Fuentes (1999)).



Figura 5.2: (Izquierda) Preparación de los extractos 1:5 y (derecha) medición de la CE y pH empleando un sensor digital. La preparación y medición de las muestras se llevó a cabo en el Laboratorio de Suelos de la Facultad de Agronomía de la Universidad Nacional Pedro Ruíz Gallo de Lambayeque.

Sistematización y discusión de resultados.

Los resultados de las mediciones son ordenados en tablas, consignando el código de la muestra, longitud y latitud en coordenadas UTM (WGS84), altitud, nombre del propietario, tipo de cultivo, valor de la $CE_{1:5}$, clase salina, pH y clasificación pH.

Punto N°	Propietario	Estado/Cultivo/ob	CE 1:5	CLASE SALINA	Ph 1:5	CLASIFICACIÓN Ph
Y02	Agricultor 1	ALGODÓN	0.39	Ligeramente Salino	8.47	Moderadamente Alcalino
Y03	Agricultor 2	ALGODÓN	0.89	Salino	7.70	Moderadamente Alcalino
Y04	Agricultor 3	ALGODÓN	2.71	Muy Salino	7.30	Neutro
Y05	Agricultor 4	ALGODÓN	0.47	Ligeramente Salino	8.80	Fuertemente Alcalino
Y06	Agricultor 5	ALGODÓN	0.18	No Salino	7.91	Moderadamente Alcalino
Y07	Agricultor 6	ALGODÓN	0.56	Ligeramente Salino	8.79	Fuertemente Alcalino
Y08	Agricultor 7	ALGODÓN	0.07	No Salino	8.24	Moderadamente Alcalino
Y09	Agricultor 8	ALGODÓN	1.14	Salino	8.40	Moderadamente Alcalino
Y10	Agricultor 9	RASTROJO	0.88	Salino	7.69	Moderadamente Alcalino
Y11	Agricultor 10	RASTROJO	1.25	Muy Salino	8.08	Moderadamente Alcalino
Y12	Agricultor 11	MAIZ	0.04	No Salino	8.29	Moderadamente Alcalino
Y13	Agricultor 12	RASTROJO	0.07	No Salino	7.63	Moderadamente Alcalino
Y14	Agricultor 13	RASTROJO	0.12	No Salino	7.84	Moderadamente Alcalino
Y15	Agricultor 14	PALLAR	0.18	No Salino	7.13	Neutro
Y16	Agricultor 15	ALGODÓN	0.35	No Salino	7.59	Moderadamente Alcalino

Tabla 4.2: Ejemplo de la sistematización de los resultados.

REFERENCIAS

1. Abbas, A., Khan, S., Hussain, N., Hanjra, M. A., & Akbar, S. (2013). Characterizing soil salinity in irrigated agriculture using a remote sensing approach. *Physics and Chemistry of the Earth, Parts A/B/C*, 55-57, 43-52.
2. Bai, Z.G., & Dent, D.L. (2007). Land degradation and improvement in Argentina 1: Identification by remote sensing. *Report 2007/05, ISRIC – World Soil Information, Wageningen*.
3. Buenemann, M., Martius, C., Jones, J. W., Herrmann, S. M., Klein, D., Mulligan, M., Reed, M. S., Winslow, M., Washington-Allen, R. A., Lal, R., & Ojima, D. (2011). Integrative geospatial approaches for the comprehensive monitoring and assessment of land management sustainability: rationale, potentials, and characteristics. *Land Degradation & Development* 22(2), 226-239, DOI: 10.1002/ldr.1074
4. Bui, E.N. (2013). Soil salinity: A neglected factor in plant ecology and biogeography. *Journal of Arid Environments*, 92, 14-25.
5. Fuentes, J. (1999). *El suelo y los fertilizantes*. Ed. Mundi Prensa, 5ta. Edición, Madrid.
6. Maxwell S. K., Sylevester, K.M. (2012). Identification of “ever-cropped” land (1984–2010) using Landsat annual maximum NDVI image composites: Southwestern Kansas case study. *Remote Sensing of Environment*, 121, 186-195
7. Millenium Ecosystem Assessment (2005). *Ecosystems and Human Well-Being: Desertification Synthesis*. Island Press, Washington DC.
8. Pervez, Md.S., Budde, M., & Rowland, J. (2014). Mapping irrigated areas in Afghanistan over the past decade using MODIS NDVI. *Remote Sensing of Environment*, 149, 155-165.
9. Rasmussen, M.S. (1998). Developing simple, operational, consistent NDVI-vegetation models by applying environmental and climatic information. Part 1. Assessment of net primary production. *International Journal of Remote Sensing*, 19, 97–117.
10. Vogt, J. V. , Safriel, U., Von Maltitz, G., Sokona, Y., Zougmore, R., Bastin, G., & Hill, J. (2011). Monitoring and assessment of land degradation and desertification: Towards new conceptual and integrated approaches. *Land Degradation & Development*, 22, 150-165.