

UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS

**FACULTAD DE INGENIERÍA GEOLÓGICA, MINERA,
METALÚRGICA Y GEOGRÁFICA**

E.A.P. DE INGENIERÍA GEOGRÁFICA

**Predicción de tierras degradadas a partir del análisis
de series temporales del índice mejorado de vegetación
y temperatura de superficie de suelo mediante
imágenes MODIS - caso estudio Piura**

TESIS

Para optar el Título Profesional de Ingeniero Geógrafo

AUTOR

Yonatan Tarazona Coronel

ASESOR

Luis Alberto Huamán Amasifuén

Bram Leo Willems

Vasco Manuel Jorge Soares Mantas

Lima - Perú

2015

**PREDICCIÓN DE TIERRAS DEGRADADAS A PARTIR DEL
ANÁLISIS DE SERIES TEMPORALES DEL ÍNDICE
MEJORADO DE VEGETACIÓN Y TEMPERATURA DE
SUPERFICIE DE SUELO MEDIANTE IMÁGENES MODIS -
CASO ESTUDIO PIURA**

Presentado por:

Bach. Yonatan Tarazona Coronel

Asesor: Ing. Luis Alberto Huamán Amasifuén

Co-asesor: Dr. Bram Leo Willems:

Co-asesor: Dr. Vasco Manuel Jorge Soares Mantas

DEDICATORIA

A Dios, mis padres: Priscilo y María.
Mis hermanos: Heisemberg y Franklin.

AGRADECIMIENTOS

Esta tesis no sería posible sin la ayuda de quienes contribuyeron directa o indirectamente a ella, apoyándome de una u otra manera. Quiero expresar mi agradecimiento a todos ellos por su relevante colaboración para que esta tesis saliera adelante.

Por encima de todo, a Dios, a quien me debo y sin la presencia espiritual de él no sería posible nada. En segundo lugar a mis padres por su apoyo incondicional día a día en la decisión tan difícil de realizar una tesis. Hay muchas razones por las que un día decidí escribir esta tesis, pero, como en todo lo que hago, saber que ellos se sentirán orgullosos de mí por hacerlo es, sin duda, la principal de todas ellas.

Dedico mi más sincero reconocimiento:

Al proyecto: PEER “Strengthening resilience of Andean river-basin headwaters facing global change” por el financiamiento a esta investigación.

A mi asesor externo principal, Dr. Bram Leo Willems, profesor/investigador del Laboratorio de Teledetección (LABTEL) de la Universidad Nacional Mayor de San Marcos (UNMSM), y director de proyectos del Centro de Competencias del Agua-CCA por brindarme asesoramiento en la elaboración de esta tesis. No olvidar que fue él de la idea de este tema de investigación, ya que personalmente tenía planeado realizar otra tesis, pero gracias a él pude entender y aprender en sobremana la problemática y los diferentes enfoques algorítmicos de pseudo-detección y cuantificación de la degradación de la tierra.

A mi co-asesor externo, Dr. Vasco Manuel Jorge Soares Mantas, catedrático del departamento de ciencias de la tierra de la Universidad de Coimbra (UC) -Portugal e investigador del Laboratorio de Teledetección y GIS de la UC, por brindarme su asesoramiento, sus enseñanzas y su apoyo personal para la finalización de esta tesis tan compleja. Darle mil gracias por dedicarme su tiempo valioso en compartir sus recomendaciones para la mejora de esta tesis.

Al Dr. Raúl Espinoza investigador de LABTEL-UNMSM por darme sus recomendaciones y observaciones en la mejora de esta investigación, si fuera posible un co-co-asesor externo, no hay duda que él, sería uno de ellos.

Agradecer también a mi asesor interno el ingeniero Luis Huamán, por brindarme apoyo en mi facultad durante la realización de esta investigación.

Y finalmente quiero terminar agradeciendo y relatando cómo fue que llegué a realizar esta tesis. Recuerdo que todo comenzó desde que realicé mis prácticas pre-profesionales en la Dirección General de Ordenamiento Territorial-MINAM allá por el mes de junio del 2013. Fue que conocí al ingeniero William Llactayo Leon (Jefe del área SIG de la DGOT) quien me brindó el apoyo incondicional a este humilde investigador en todas las formas posibles. Fue él quien me direccionó a estudios de cambio y uso de cobertura mediante técnicas como CLASlite y que finalmente me encaminó a seguir investigando no solo cambios por deforestación, sino también la degradación de la tierra.

LISTA DE FIGURAS

Figura 2-1. Situación actual y tendencias de la degradación de la tierra en todo el mundo (Adaptado de: FAO, 2011)	25
Figura 2-2. Relación entre la pobreza y la degradación de la tierra (Adaptado de: FAO, 2011).	26
Figura 2-3. Efectos de amplio alcance, y la espiral descendente de la DDTS.	27
Figura 2-4. La biodiversidad es la base de unas tierras de cultivo y unos pastizales sanos y productivos. Reducir a la mitad la pérdida y la degradación de ecosistemas, restaurar al menos el 15% de los ecosistemas degradados antes de 2020 – en línea con las Metas de Aichi para la Diversidad Biológica – y alcanzar la NDT son pasos esenciales en el camino hacia el desarrollo sostenible, ayudándonos en la producción de más alimento, mitigando y adaptándonos al cambio climático y reduciendo la vulnerabilidad antes los desastres.	28
Figura 2-5. Los circuitos de retroalimentación y los objetivos de las Convenciones de Río.	29
Figura 2-6. Taxonomía de técnicas para la detección de cambios en la cobertura terrestre.	34
Figura 2-7. En el gráfico superior notamos la Serie de Tiempo, en el siguiente la estacionalidad, en la subsiguiente la tendencia y por último lo aleatorio.	41
Figura 2-8. Tomados desde 1960-1997, muestra cómo se incrementa el Dióxido de Carbono en nuestra atmósfera en un claro ejemplo de una serie de tiempo.	42
Figura 2-9. El test de normalidad nos permite identificar valores anómalos dentro de una serie de tiempo.	43
Figura 2-10. En la figura (a) se muestra una serie de tiempo tal cual es, mientras que en la figura (b) superior derecha se muestra en línea oscura, la serie original y sobre ella la serie suavizada con $\alpha = 3$ en color rojo. Lo mismo para la figura (c) se muestra un suavizamiento con $\alpha = 5$ y en la figura (d) un suavizamiento con $\alpha = 25$	45
Figura 2-11. Regresión lineal simple en donde se observa desviaciones de valores observados y ajustados.	46
Figura 2-12. Representación de $Y = 1\cos(2\pi t50 + 0)$	49
Figura 2-13. Serie generada como $Y = 5\cos(2\pi t50 + 0)$ y su periodograma.	54
Figura 2-14. Cohete V-2.	55
Figura 2-15. TIROS-I (izquierda). Primera imagen de televisión desde el espacio (derecha).....	56
Figura 2-16. Elementos de un proceso de Teledetección desde satélites.	57
Figura 2-17. Las posiciones de las bandas espectrales para instrumentos comunes de teledetección se indican. Sensores Hyperespectrales (Cientos de bandas) abarcan casi todo el espectro de longitudes de onda. Adaptado de (NASA-USGS).	58
Figura 2-18. Las posiciones de las bandas espectrales para instrumentos comunes de teledetección se indican. Sensores Hyperespectrales (Cientos de bandas) abarcan casi todo el espectro de longitudes de onda.....	59
Figura 2-19. Formato de una imagen digital (7x9 píxeles). Cada píxel representa un área de la superficie terrestre. Los tonos de gris hacen referencia a los distintos niveles de energía detectada	63
Figura 2-20. Longitud de onda de las primeras 7 bandas del sensor MODIS (Mora, 2010)	67

Figura 2-21. Deformaciones relacionadas con el ángulo de barrido (Mora, 2010).....	67
Figura 2-22. Esquema metodológico de la composición MODIS-IV (Huete et al., 2002).....	71
Figura 2-23. Bandas del producto MOD13Q1 – MODIS. Adaptado de (Huete et al., 2002).	75
Figura 2-24. La cubierta forestal se utiliza aquí como ejemplo de indicador de la degradación (FAO, 2011).....	77
Figura 2-25. Ilustración de los factores que condicionan la temperatura superficial adaptado de (Inge Sandholt, Kjeld Rasmussen, 2002).....	82
Figura 2-26. Simplificado $T_s/NDVI$ adaptado de (Lambin & Ehrlich, 1996).	83
Figura 4-1. Tiles que serán usados para la investigación.	106
Figura 4-2. Con la banda de fiabilidad (B) se filtra los píxeles sucios como se muestra en la figura (B').....	109
Figura 4-3. Metodología de la interpolación de datos faltantes “NA” al utilizar la banda de confiabilidad.....	110
Figura 4-4. En la figura se muestra que los Máximos Compuestos Anuales (b), son datos donde se ha eliminado la componente estacional. Se aprecia con más precisión la pérdida o ganancia de la biomasa.	111
Figura 4-5. β_1 es la pendiente – indicador del proceso degradador.....	114
Figura 4-6. Figura que muestra para el píxel i, j la pendiente de la regresión lineal. Es una pendiente negativa lo que indica, un decrecimiento gradual de la variable biofísica (pérdida de biomasa).....	114
Figura 4-7. Figura que muestra para el píxel i, j la pendiente de la regresión lineal. Es una pendiente positiva lo que indica, crecimiento abrupto de la variable biofísica (incremento de la biomasa).	115
Figura 4-8. Bfast detectó una ruptura en la tendencia de la serie de tiempo. El periodo de cambio ocurrió en el 2010 en adelante.....	116
Figura 4-9. Bfast detectó cuatro periodos de cambio, esto da a entender que es una serie compleja en donde hubo subidas y bajadas de la variable biofísica.	117
Figura 5-1. Área donde hubo un cambio en el uso del suelo por agricultura en el 2010.	125
Figura 5-2. Satter plot del EVI para los periodos 2001 vs 2007 (a), 2007 vs 2014 (b) y 2001 vs 2014 (c).....	126
Figura 5-3. Diagrama de dispersión en función a los cuadrantes de estudio.....	127
Figura 5-4. Regresión lineal de los índices EVI para los periodo 2001, 2007 y 2014. 2001 vs 2007 (a), 2007 vs 2014 (b) y 2001 vs 2014 (c).	128
Figura 5-5. El análisis de tendencias de la cubierta vegetal utilizando MODIS EVI entre enero del 2001 y diciembre del 2014 señala una reducción de la cobertura (en color rojo - Figura B, C y D - para el punto 1) durante la mayor parte de la zona, aunque algunas partes de la sección muestran aumentos en el EVI (por ejemplo los puntos 2 y 3). La dinámica de la cobertura de la zona es, por tanto, bastante compleja y variable. Con todo, la evolución de la cubierta vegetal de la zona (Figura 5-5 A) para el período de 2001 al 2014, muestra importantes variaciones interanuales, en gran parte determinada por las sales dentro del valle y fuera del valle por las condiciones climáticas. (Área de análisis - valle agrícola de Piura).	129

Figura 5-6. Haciendo un mismo análisis de tendencias de la cubierta vegetal utilizando MODIS EVI entre enero del 2001 y diciembre del 2014 señala una reducción de la cobertura (en color rojo - B, C y D - para los puntos 1 y 2) durante la mayor parte de la zona, aunque algunas partes de la sección muestran aumentos en el EVI (por ejemplo los puntos 3 y 4). La dinámica de la vegetación de la zona es, por tanto, bastante compleja y variable. Con todo, la evolución de la cubierta vegetal de la zona (A) para el período de 2001 al 2014, muestra importantes variaciones interanuales, tanto positivas como negativas, esto está determinada por las sales dentro del valle y fuera del valle por las condiciones climáticas (Valle Agrícola).	130
Figura 5-7. Se muestra los años en que se expandió la agricultura mediante bfast- Imagen L8-2014.	134
Figura 5-8. Disminución del índice EVI y detectado con bfast para el punto a (Mapa 5-6).....	136
Figura 5-9. Disminución del índice EVI y detectado con bfast para el punto b (Mapa 5-6).....	137
Figura 5-10. Disminución del índice EVI y detectado con bfast para el punto c (Mapa 5-6).....	138
Figura 5-11. La relación entre el verdor de la vegetación y la temperatura superficial.	139
Figura 5-12. Simplificado $T_s/NDVI$ adaptado de (Lambin & Ehrlich, 1996).	140
Figura 5-13. La relación entre la tendencia de la degradación y la tendencia de la temperatura guarda relación con el tipo de uso del suelo y sobre todo con los bosques secos. La tendencia positiva (Panel B), muestra zonas con estrés hídrico. Por lo tanto, el aumento de la temperatura superficial aumenta, mientras que el verdor del índice EVI disminuye según (Lambin & Ehrlich, 1996).....	143
Figura 5-14. Comparación del bosque seco de un periodo a otro (Ministerio de Agricultura y Riego, 2013).....	144
Figura 5-15. Gráfico de dispersión entre la tendencia de la degradación, tendencia de la temperatura y el uso actual del suelo.....	146
Figura 5-16. Análisis histórico de la degradación de la media del índice EVI 2001-2014. (a) Bosque seco y (b) Valle agrícola.	147
Figura 5-17. Puntos de muestreo en campo.	150
Figura 6-1. Número de huecos a interpolar. Generalmente el número de huecos influye en la interpolación de los datos.	155
Figura 6-2. Los datos interpolados discreparon en un 2.15% de los datos reales, habiendo comisión y omisión; sobre todo comisión.....	156

LISTA DE MAPAS

Mapa 2-1.Elaboración propia en base a data del WAD Atlas Mundial de la Desertificación, Joint Research Centre UE y del Mapa de desertificación del Gobierno Regional de Piura.	32
Mapa 3-1.Mapa geológico de Piura.	91
Mapa 3-2.Mapa Fisiográfico de Piura.	93
Mapa 3-3.Mapa Geomorfológico de Piura.	95
Mapa 3-4.Mapa de Suelos de Piura.....	98
Mapa 3-5.Mapa de uso actual del suelo de Piura	100
Mapa 3-6.Mapa de Tierras Secas de la Región de Piura (Adaptado de: MINAM, 2012)	103
Mapa 4-1.En la imagen A se muestra los datos disponibles de salinización tomados con imágenes de alta resolución y datos de campo. Estos datos permitirá la comprobación del resultado final. ...	118
Mapa 5-1.Resultado de extraer las pendientes de las ecuaciones lineales píxel a píxel en los MCA.	123
Mapa 5-2.Resultado de extraer las pendientes de las ecuaciones lineales píxel a píxel en los MCA.	124
Mapa 5-3.Uso actual del suelo según la Zonificación Ecológica Económica de Piura.....	131
Mapa 5-4.Bosques secos según el tipo de cobertura de la Zonificación Ecológica y Económica-Piura 2012.....	132
Mapa 5-5.Significancia en el píxel de cambios interanuales del EVI sobre el periodo 2001 – 2014.	133
Mapa 5-6.Se muestra los píxeles aplicando el método bfast en a, b y c.	135
Mapa 5-7.Mapa de tendencias de la temperatura superficial obtenida de las pendientes de las regresiones lineales de los valores mínimos anuales del producto MOD11A2-Day a 1km de resolución espacial.	141
Mapa 5-8.Mapa de tendencias de la temperatura superficial obtenida de las pendientes de las regresiones lineales de los valores mínimos anuales del producto MOD11A2-Day a 1km de resolución espacial.	142
Mapa 5-9.Tierras degradadas al 95% de significancia.	149
Mapa 5-10.Sobre-posición entre el mapa de tendencias de degradación de la tierra con los datos disponibles de zonas degradadas por salinización.	152
Mapa 6-1.En el panel A se muestra la tendencia del índice y las regiones con mayor importancia en la interpretación de los resultados. En el panel B se muestra la tendencia de la temperatura superficial del suelo.	157

LISTA DE TABLAS

Tabla 1-1. Tierras en degradación (Adaptado de: Gobierno Regional de Piura, 2012).....	20
Tabla 2-1. Ejemplo de series de tiempo.....	39
Tabla 2-2. Bandas del sensor MODIS	66
Tabla 2-3. Especificaciones técnicas del sensor MODIS.....	68
Tabla 2-4. Especificaciones del producto MOD13Q.	73
Tabla 2-5. Bandas del producto MOD13Q1 – MODIS.	74
Tabla 3-1. Índice de aridez y extensión de tierras secas de la Región Piura, estimados a partir del mapa de tierras secas del MINAM (Willems, 2014).	101
Tabla 4-1. Píxel de fiabilidad MOD13Q1.....	107
Tabla 4-2. Descripción de los datos de Evaluación de la Calidad IV-QA (Adaptado de: Solano, 2010)	108
Tabla 4-3. Información general de las principales ventajas y desventajas de los principales suavizadores a los índices biofísicos.	112
Tabla 5-1. Nivel de significancia o de confiabilidad de las regresiones lineales.	133
Tabla 5-2. La relación entre el verdor de la vegetación y la temperatura superficial guarda una relación	145
Tabla 5-3. Agrupación del uso del suelo en función a la tendencia de la degradación	145
Tabla 5-4. Resumen del porcentaje de tierras degradadas en función el nivel de significancia..	148
Tabla 5-5. Ganancia y pérdida de suelo por salinización.....	148
Tabla 5-6. Acierto de los datos obtenidos en campo con los resultados del mapa de pendiente.	151
Tabla 6-1. Síndromes de la degradación en los usos actuales.....	159

SIGLAS Y ACRONIMOS

AVHRR:	Radiómetro Avanzado de Muy Alta Resolución
BRDF:	Función de distribución de la reflectancia bidireccional
DDTS:	Desertificación, degradación de la tierra y sequía
EVI:	Índice mejorado de vegetación
LANDSAT:	Satélite de la Tierra
MODIS:	Espectroradiómetro de imágenes de media resolución
MCA:	Máximos compuestos anuales
MINAM:	Ministerio del Ambiente - Perú
NDVI:	Índice de vegetación de diferencia normalizada

RESUMEN

El área de tierras degradadas viene aumentando a nivel global, lo que ha desencadenado una serie de esfuerzos crecientes de mitigación y reversión del complejo proceso de degradación de tierras. En el presente estudio se propone una metodología para la predicción (estimación) de áreas degradadas a partir del análisis de las tendencias lineales de las series de tiempo de los productos MOD13Q1-índice de Mejoramiento de Vegetación (EVI) y MOD11A2-Temperatura de la Superficie de Suelo (LST) del sensor MODIS. Descargados los datos, se filtraron los píxeles contaminados debido a los artefactos atmosféricos mediante la capa de fiabilidad y se completaron las series con interpolaciones en función al tiempo. Luego, se generaron los máximos compuestos anuales (MCA), cuyas tendencias se determinaron píxel por píxel con su respectivo test de significancia. Se obtuvieron mapas de tendencias de la degradación en base al EVI, mostrando un total de 26.97% de área degradada con significancia ($p < 0.05$) y 34.97% con significancia ($p < 0.1$). A su vez, este resultado se relacionó con el mapa de tendencias de la temperatura superficial (T_s), basado en el balance de energía entre el calor sensible y el calor latente de vaporización, mostrando un 26.59% de área de estrés hídrico con significancia ($p < 0.1$). El mapa de tendencias de la Temperatura superficial permitió observar un estrés hídrico en la cobertura del bosque seco y usos, debido a las actividades humanas, principalmente. Esto fue relacionado con el mapa de tendencias de degradación del EVI en el cual, los resultados de degradación en el valle para ambas variables fueron debido al problema de la salinización, y en el bosque seco por el estrés hídrico y la deforestación. La degradación obtenida guarda relación con los llamados síndromes de la degradación, mostrando tendencias negativas para el EVI y tendencias positivas para la temperatura de superficie de suelo de acuerdo al balance de energía.

INDICE

INTRODUCCIÓN	17
CAPITULO I	
1. PLANTEAMIENTO DEL PROBLEMA.....	20
1.1 Situación problemática	20
1.2 Formulación del problema	21
1.3 Justificación	21
1.4 Objetivos	21
1.4.1 Objetivo general.....	21
1.4.2 Objetivos específicos	21
1.5 Tipo de la Investigación	22
1.5.1 Hipótesis.....	22
CAPITULO II	
2. DESERTIFICACIÓN Y DEGRADACIÓN DE LA TIERRA	24
2.1 Tierra y el suelo.....	25
2.2 Pérdida de Biodiversidad.....	28
2.3 La tierra y el Cambio Climático.....	29
2.4 Degradación de suelos agrícolas por salinización	30
2.4.1 Procesos y causas de la salinización de suelos en tierras bajo riego.....	30
2.4.2 Características y condiciones para el desarrollo de suelos salinos	30
2.5 La desertificación en la Región de Piura	31
2.5.1 Evolución de la biomasa como aporte al análisis de la desertificación en Piura.	31
2.6 DETECCIÓN DE CAMBIOS EN LA COBERTURA TERRESTRE	33
2.6.1 Bitemporal	33
2.6.2 Multitemporal/ Series de Tiempo.....	34
2.7 TAXONOMÍA DE TÉCNICAS DE DETECCIÓN DE CAMBIO DE COBERTURA DE LA TIERRA.	34
2.8 Técnicas Bitemporales.....	35

2.8.1	Técnicas basadas en el Píxel.....	35
2.8.2	Clasificación basada en objetos.....	35
2.8.3	Transformación Lineal.....	36
2.8.4	Clasificación.....	36
2.9	Técnicas Multitemporal	36
2.9.1	Las técnicas basadas en píxeles multitemporales	36
2.9.2	Clasificación basada en objeto.....	37
2.9.3	Espacio de Características	37
2.9.4	Series de Tiempo	37
2.10	SERIES DE TIEMPO	38
2.10.1	Observación, medición y generalización.....	38
2.10.2	Formalización.....	38
2.10.3	Definición de Series temporales.....	39
2.10.4	Ejemplos de Series de Tiempo	39
2.10.5	Objetivos de análisis de series de tiempo	39
2.10.6	Componentes de una Serie Temporal.....	40
2.11	ANÁLISIS PRELIMINAR DE SERIES DE TIEMPO	42
2.11.1	Test de Normalidad de los residuos.....	42
2.11.2	Filtros de Series	43
2.12	Análisis de series temporales desde la matemática.....	45
2.12.1	Regresión Lineal	46
2.12.2	Regresión Múltiple.....	48
2.12.3	Funciones periódicas	48
2.12.4	Series de Fourier.....	51
2.12.5	Periodograma.....	53
2.12.6	Residuales de una serie de tiempo	54
2.13	Nociones de teledetección.....	55
2.13.1	Historia de la Teledetección.....	55
2.13.2	Elementos de la Teledetección.....	56
2.13.3	El espectro electromagnético	57
2.13.4	Reflectancia de la superficie terrestre	58

2.13.5	Efectos atmosféricos sobre la radiación	59
2.13.6	Dispersión	60
2.13.7	Características orbitales de los satélites de teledetección	61
2.13.8	Resolución de los sensores de satélite	62
2.13.9	Tipos de imágenes de teledetección.....	64
2.14	Sensor MODIS	65
2.14.1	Especificaciones técnicas del sensor MODIS	65
2.14.2	Deformaciones relacionadas con el barrido (ángulo de vista)	67
2.14.3	Niveles de procesamiento.....	69
2.14.4	Problemas en la calibración del sensor MODIS-AQUA y TERRA	70
2.14.5	Variables biofísicas relacionadas con la vegetación.....	70
2.14.6	NDVI vs EVI.....	75
2.15	Estimación de tierras degradadas mediante la teledetección	76
2.15.1	Degradación forestal	76
2.15.2	Degradación por salinización	78
2.15.3	Degradación por erosión del suelo	79
2.16	Temperatura superficial y el índice de vegetación	80
2.16.1	Cubierta vegetal	80
2.16.2	La evapotranspiración.....	81
2.16.3	Las propiedades térmicas de la superficie.....	81
2.16.4	La radiación neta	81
2.17	Rupturas en tendencia y estacionalidad aditivas (bfast)	84
2.17.1	Modelo de descomposición	85
2.17.2	Detección de cambio iterativo dentro de las series temporales.....	86

CAPITULO III

3.	ÁREA DE ESTUDIO	89
3.1	Ubicación y extensión	89
3.2	Características físicas del área de estudio.....	89
3.2.1	Geología.....	89
3.2.2	Fisiografía.....	92
3.2.3	Geomorfología	94

3.2.4	Suelos	96
3.2.5	Uso actual de la tierra.....	99
3.2.6	Características climáticas de las tierras secas de Piura	101

CAPITULO IV

4.	DATOS Y METODOLOGÍA.....	105
4.1	Índice Mejorado de Vegetación (EVI)	106
4.2	Datos de calidad MOD13Q1	107
4.3	Interpolación de Datos Faltantes (“NA”).....	110
4.4	Máximos Compuestos Anuales de EVI	111
4.5	Pendiente de la regresión lineal de los Máximos Compuestos Anuales	113
4.6	Procesamiento de las imágenes MOD11A2.....	115
4.7	Identificación del Inicio del proceso degradador.....	116
4.8	Validación de los resultados.....	118
4.9	Datos obtenidos con imágenes Landsat, Rapideye y Campo.....	119
4.10	Códigos en R empleados en la metodología	119

CAPITULO V

5.	RESULTADOS Y VALIDACIÓN.....	123
5.1	Análisis empírico mediante el índice EVI – Máximos Compuestos Anuales (MCA)	123
5.2	Test de Confianza	133
5.3	Detección del periodo de cambio mediante bfast.....	134
5.4	Análisis mediante la temperatura superficial (Ts).....	139
5.5	Validación de los resultados (Porcentaje de acierto)	150

CAPITULO VI

6.	DISCUSIÓN DE RESULTADOS	154
6.1	El ruido en los datos MODIS	154
6.2	Interpolaciones de datos faltantes	154
6.3	Tendencia de la degradación.....	156
6.4	Síndromes de la degradación en los usos del suelo.....	158
6.5	Detección del periodo de cambio	159
6.6	Validación de los resultados.....	159

CAPITULO VII

7. CONCLUSIONES	161
8. RECOMENDACIONES.....	163
9. GLOSARIO.....	164
10. BIBLIOGRAFÍA.....	167
11. ANEXOS.....	174

INTRODUCCIÓN

Los esfuerzos mundiales por detener y revertir la desertificación o degradación de la tierra y por lograr una degradación neta cero, son requisitos que se necesitan previamente para liberar a millones de personas de la pobreza, permitir la seguridad alimentaria, salvaguardar las reservas de agua y alcanzar los Objetivos de Desarrollo del Milenio y los Objetivos de Desarrollo Sostenible. La desertificación entonces puede ser definida como pérdida persistente de servicios de los ecosistemas (Safriel et al., 2005). La Convención de las Naciones Unidas de Lucha contra la Desertificación entiende desertificación como la degradación de las tierras de zonas áridas, semiáridas subhúmedas secas resultantes de diversos factores, tales como las variaciones climáticas y actividades humanas. Por tanto, la degradación de la tierra es un término complejo y ambiguo con múltiples definiciones relacionado con cambios en la vegetación y el suelo (Washington et al., 2006). Actualmente algunas técnicas de detección de degradación se centran principalmente en la evaluación de la reducción de la productividad en relación con el potencial del sitio, otros programas ven la degradación de la tierra como una disminución en la capacidad del medio ambiente en satisfacer las demandas de los usuarios (Kasperson et al., 1995), permitiendo que la extensión y severidad de la degradación varía en función de los diferentes objetivos de gestión (Reed, 2011). Estos diferentes enfoques dificulta la evaluación de la degradación de la tierra. Los componentes sociales, económicos y la recolección de datos de campo resulta ser muy costoso. El costo oneroso de recolección de datos de campo y la necesidad de plantear una metodología consistente para cuantificar el grado y la magnitud de las reducciones en la capacidad productiva, sugiere utilizar la teledetección como una solución razonable (Reeves, 2014).

Los índices de vegetación obtenida en base a reflectancia del espectro visible e infrarrojo cercano, el índice de vegetación de diferencia normalizada (NDVI), o el índice mejorado de vegetación (EVI) han demostrado que se correlaciona con la biomasa vegetal, área foliar y la productividad primaria (Myneni, 1995). Muchos estudios han utilizado índices de vegetación obtenidos por medio de sensores remotos (LANDSAT, MODIS, AVHRR) para monitorear las tendencias de la productividad primaria para la evaluación en los efectos de la degradación de la tierra (Bastin, 1995; Diouf & Lambin, 2001). La teledetección se ha utilizado para cuantificar la degradación de la tierra, pero su aplicación se ha limitado por tres factores principales; disponibilidad de datos fiables del terreno (Tongway et al., 2004), la alta variabilidad de las precipitaciones que pueden enmascarar degradación de la tierra (Wessels, 2007), y la falta de condiciones de referencia apropiados que representen las tierras no degradadas para la comparación. A pesar de ello, se produjo una evaluación mundial de la degradación utilizando el NDVI como una medida combinada con la precipitación anual para analizar las zonas con significancia reducida en la eficiencia del uso de las precipitaciones (Bai, 2008). Sin embargo, para un análisis global, este método de identificación de tierras degradadas puede ser adecuado, pero los patrones de degradación tienen generalmente una resolución más fina (Matthew, 2014) imposibilitando el estudios de degradación, por ejemplo, en valles agrícolas donde uno de los problemas principales es la salinización. Se ha intentado también plantear algoritmos muy robustos basados en series de fourier y análisis de gráficos de control como BFAST (rupturas en tendencia y estacionalidad aditivas) (Verbesselt et al., 2010) que permite detectar perturbaciones o *breakpoints* en series de tiempo de variables biofísicas (NDVI, EVI), sin embargo la estacionalidad de las series de tiempo, los valores anómalos y la dificultad de

automatizar para áreas extensas, debido a que una serie de tiempo existirá más de un *breakpoint*, origina confusión al momento de programar. No cabe duda que monitorear pequeñas áreas o determinados pixeles, es posible mediante BFAST, pero la excesiva detección de *breakpoints* dificulta analizar degradación de la tierra.

Teniendo en cuenta las cuestiones señaladas, este trabajo desarrolla un proceso de predicción de tierras degradadas en base a un análisis empírico de imágenes MODIS (MOD13q1 y MOD11a2) de 250m y 1000m de resolución espacial respectivamente, utilizando la estadística significativa, los usos de suelo, las coberturas y las tendencias negativas en los Máximos Compuestos Anuales (Holben, 1986), ***centrándonos únicamente en los componentes ecológicos de la degradación y no en los atributos sociales y/o económicos.***

CAPITULO I

PLANTEAMIENTO DEL PROBLEMA

1. PLANTEAMIENTO DEL PROBLEMA

1.1 Situación problemática

Según el Gobierno Regional de Piura (2012) las principales causas de degradación de tierras en Piura, y en la Costa Norte en general, han sido identificadas debido a la erosión hídrica, eólica; debido a la tala, quema de la vegetación y el sobrepastoreo.

Los algarrobales y bosques secos han desaparecido o han sido reducidos por la acción humana en extensas zonas, la salinización de suelos agrícolas por excesivo riego y mal drenaje (sobre todo en cultivos de arroz). Amplias zonas irrigadas son afectadas por este problema en Tumbes, Piura, Lambayeque y La Libertad, y por último la desertificación por la tala de los bosques en las zonas semidesérticas (algarrobales), propiciando en algunos casos el avance de dunas en áreas agrícolas (Morales, 2013).

El porcentaje de tierras en degradación según el Gobierno Regional de Piura (2012) se muestra en la Tabla 1-1.

En el Perú, las metodologías de degradación de la tierra utilizan imágenes bitemporales y con un aprendizaje supervisado o no supervisado basados en “machine learning” “identifican” y “cuantifican” tierras degradadas. Actualmente, la tendencia de los investigadores en el uso de las imágenes de satélite, es usar series de imágenes para analizar los procesos dinámicos como la degradación de la tierra. Ello se ve plasmado en la cantidad de artículos de investigación citando algunos de ellos: “A remote sensing protocol for identifying rangelands with degraded productive capacity”, “Limits to detectability of land degradation by trend analysis of vegetation index data”, “Monitoring forest degradation in tropical regions by remote sensing: some methodological issues” y otros. Es necesario entonces, plantear un objetivo plasmada en una metodología distinta para la predicción de tierras degradadas en base a una serie histórica de imágenes MODIS que permita no solo detectar el cambio, sino también, cuándo ocurrió dicho cambio en lo posible, algo que no se puede realizar usando técnicas de clasificación que usan imágenes bitemporales.

Tierras afectadas	Superficie (ha)	Superficie (%)
Degradación por erosión hídrica	58,095.20	8.11
Degradación por mal drenaje	1,755.30	0.24
Degradación por alta concentración de sales y sodio	112,862.12	15.75
Zonas deforestadas en costa, sierra y ceja de selva	543,872.37	75.9
Total de tierras en degradación-Piura	716,584.99	100

Tabla 1-1. Tierras en degradación (Adaptado de: Gobierno Regional de Piura, 2012).

1.2 Formulación del problema

Es necesario contestar dos preguntas, primero: es posible detectar degradación de la tierra mediante el análisis empírico de imágenes MODIS?, y segundo: cuál es el nivel de precisión y/o acierto al analizar la tendencia de los Máximos Compuestos Anuales y la pendiente de una regresión lineal para predecir la degradación en las series históricas del índice EVI.

1.3 Justificación

Educacional-Científico.- Es necesario responder ¿por qué? y ¿para qué? sirve la investigación. Referente a las interrogantes planteadas, tal como se menciona en la situación problemática, las escasas metodologías de detección de un proceso complejo y dinámico como la degradación de la tierra, amerita una dirección distinta en la identificación de la degradación. Este estudio, y siguiendo la tendencia actual de la investigación, se plantea una metodología que permita monitorear la degradación de la tierra en base a un análisis histórico de variables biofísicas (EVI) y físicas (LST). Por tanto, esta tesis es un aporte a la comunidad científica en los esfuerzos por monitorear las perturbaciones de los ecosistemas, de manera que se pueda evaluar y hacer frente a los procesos de degradación de la tierra.

1.4 Objetivos

1.4.1 Objetivo general

Analizar y validar la tendencia de la variable biofísica (EVI) en complemento con la temperatura de superficie de suelo de imágenes MODIS para la predicción de tierras en degradación 2001-2014.

1.4.2 Objetivos específicos

- a) Implementar algoritmos para el pre-procesamiento y procesamiento de datos de imágenes MODIS.
- b) Establecer la metodología adecuada para la interpretación y análisis estadístico de los datos.
- c) Generar mapas con zonas potenciales en degradación estadísticamente significativas $p < 0.05$.
- d) Validar y contrastar el mapa generado con información de campo e información disponible de zonas degradadas por salinización.
- e) * Identificar cambios abruptos relacionados a la expansión agrícola mediante el método BFAST.

1.5 Tipo de la Investigación

De acuerdo a la problemática planteada y a los objetivos del estudio, el tipo de investigación es aplicada.

1.5.1 Hipótesis

Las rupturas decrecientes en la tendencia de las series temporales del índice EVI y el incremento tendencial de la temperatura de superficie de suelo, permiten predecir las tierras degradadas.

CAPTULO II

MARCO TEÓRICO

2. DESERTIFICACIÓN Y DEGRADACIÓN DE LA TIERRA

Por “desertificación” se entiende la degradación de las tierras de zonas áridas, semiáridas y subhúmeda secas resultante de diversos factores, tales como las variaciones climáticas y las actividades humanas (CLD, 2013).

Por otro lado, la “degradación de la tierra” se entiende la reducción o la pérdida de la productividad biológica o económica y la complejidad de las tierras agrícolas de secano, las tierras de cultivo de regadío o las dehesas, los pastizales, los bosques y las tierras arboladas, ocasionada, en zonas áridas, semiáridas y subhúmedas secas, por los sistemas de utilización de las tierras o por un proceso o una combinación de procesos, incluidos los resultantes de actividades humanas y pautas de poblamiento, tales como: i) la erosión del suelo causada por el viento o el agua; ii) el deterioro de las propiedades físicas, químicas y biológicas o de las propiedades económicas del suelo; y iii) la pérdida duradera de vegetación natural (CLD, 2013). Las relaciones entre la desertificación y la gestión sostenible de las tierras, así como entre los suelos y el cambio climático, son muy importantes. Tienen efectos transfronterizos y de alcance mundial, y deberían ser más tenidas en cuenta por los responsables de la adopción de decisiones y de la formulación de políticas.

Las tierras secas suponen el 43.3% de la superficie del suelo de la Tierra y son el hogar de más de 2.100 millones de personas, se estima que a escala global, el 24% del suelo se está degradando, que cerca del 20% de los suelos degradados son tierras de cultivo, y entre un 20% y un 25%, pastizales. Alrededor de 1 500 millones de personas en todo el mundo dependen directamente de esas áreas degradadas, y que cerca de los 1000 millones de personas más pobres y marginadas, que viven en las áreas más vulnerables, pueden ser las afectadas más severamente por la desertificación (CLD, 2013).

2.1 Tierra y el suelo

La tierra y el suelo productivos son bienes de capital naturales decisivos para la productividad agraria, ya que conservan la biodiversidad y la disponibilidad de servicios ecosistémicos, como los de secuestro de carbono, purificación y almacenamiento de agua, biocombustibles, protección y regulación del clima y patrimonio natural. En las comunidades que dependen en extremo de la tierra como principal proveedora de medios de subsistencia, particularmente en las poblaciones rurales pobres, la salud humana y el bienestar de las personas dependen enteramente y están estrechamente vinculados a la salud y productividad de la tierra. Así, las funciones vitales de la tierra y del suelo están en la base del vínculo entre alimentos, energía renovable y seguridad hídrica.

La degradación de la tierra es la disminución o pérdida de la capacidad productiva biológica o económica de la tierra (UNCCD, 2013) causada por actividades humanas, exacerbada por procesos naturales, y frecuentemente magnificada por los impactos del cambio climático y la pérdida de biodiversidad. Se define la desertificación como el proceso de degradación de las tierras áridas, semiáridas y subhúmedas secas, que refleja una reducción persistente o pérdida de productividad biológica y económica (Zakri, 2005). Tanto la degradación de la tierra como la desertificación son reducciones de carácter persistente; la diferencia estriba en que la desertificación se limita a las tierras secas y está considerada como un caso extremo de degradación. Las sequías se caracterizan por una deficiencia de precipitación que redundará en una escasez de agua y al igual que la degradación de la tierra, son un fenómeno mundial presente también en regiones húmedas.

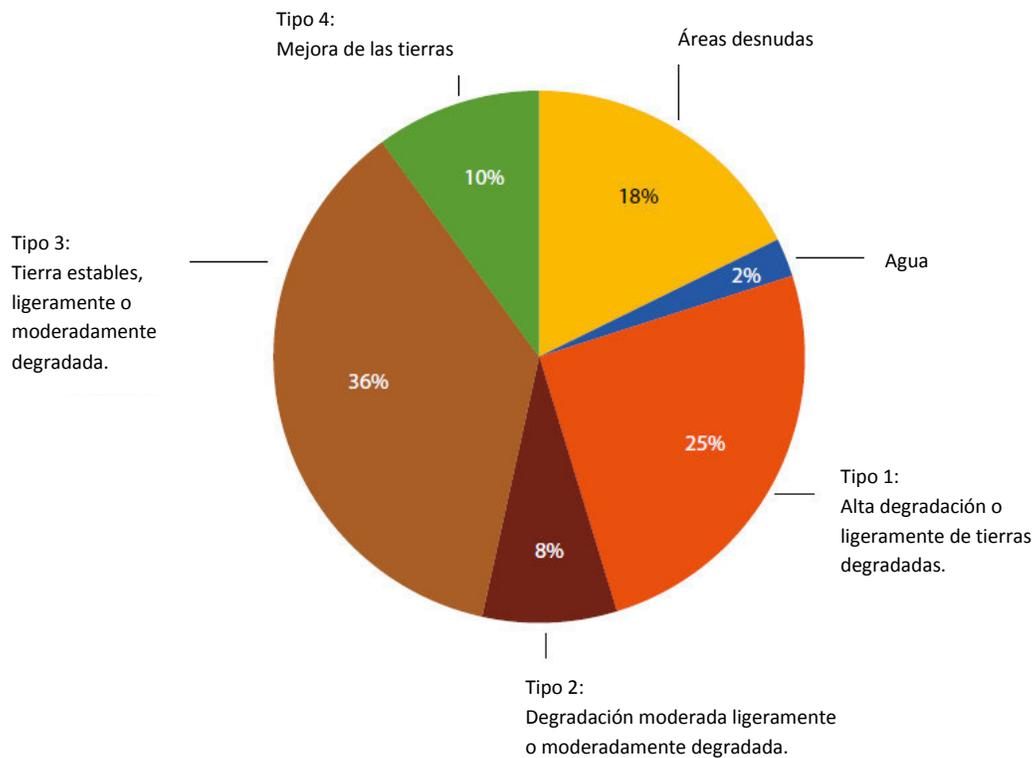


Figura 2-1. Situación actual y tendencias de la degradación de la tierra en todo el mundo (Adaptado de: FAO, 2011)

Diversos estudios indican que ha aumentado porcentualmente la superficie total de tierra degradada o en proceso de degradación, pasando de un 15% en 1991 a un 25% en 2011. En 2008, más de un 20% de toda la superficie cultivada, un 30% de los bosques naturales y un 25% de los pastizales experimentaban algún tipo de degradación. Diversas estimaciones indican que hasta un 25% de todas las tierras están actualmente muy degradadas, y un 36% ligera o moderadamente degradadas aunque en condiciones estables, mientras que sólo un 10% está mejorado (FAO, 2011), ver Figura 2-1. Varios estudios indican que la degradación de la tierra afecta directamente a 1.500 millones de personas en todo el mundo, recayendo sus efectos de manera desproporcionada sobre las poblaciones pobres, las mujeres y los niños, habiendo reducido ya la productividad de la superficie mundial en aproximadamente un 25% entre 1981 y 2003. Tales evaluaciones evidencian que, en un periodo relativamente reciente, la productividad biológica ha disminuido apreciablemente, sumándose así a la extensión de tierra ya degradada. Aunque la degradación de la tierra entraña un riesgo generalizado, aproximadamente un 40% de ellas son extensiones en que la incidencia de la pobreza es máxima (Nachtergaele, 2010), ver Figura 2-2.

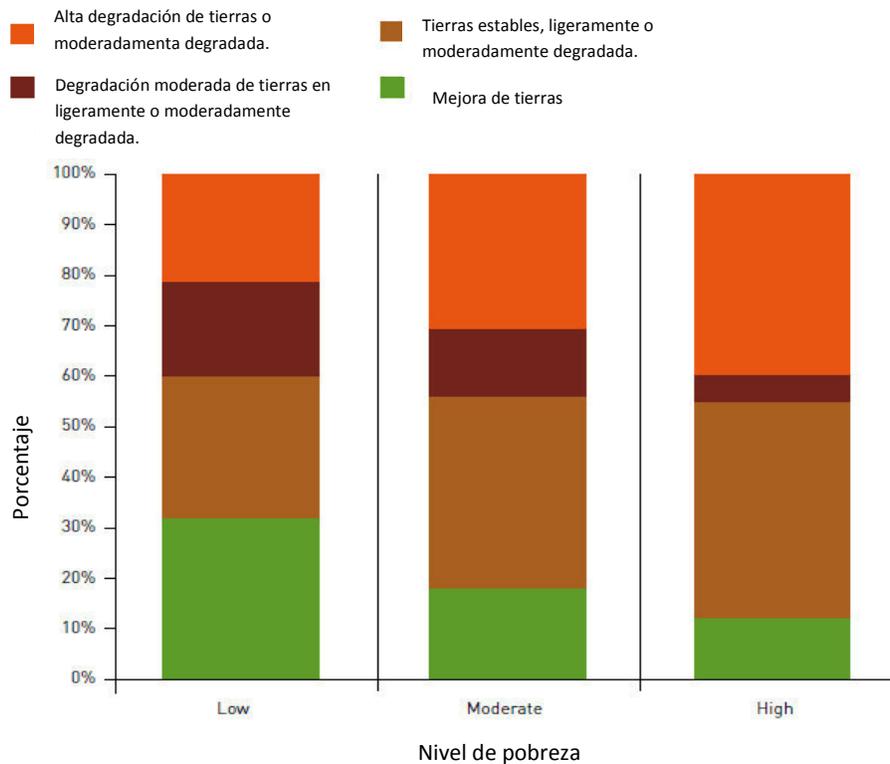


Figura 2-2. Relación entre la pobreza y la degradación de la tierra (Adaptado de: FAO, 2011).

Los ciclos de realimentación mutua entre la degradación de la tierra y el cambio mundial del medio ambiente, y específicamente los impactos del cambio climático y la pérdida de biodiversidad, intensifican aún más los problemas de la DDTs. Un análisis reciente parece indicar que el aumento del calentamiento mundial podría inducir una mayor frecuencia e intensidad de los fenómenos

meteorológicos extremos en términos sincronizados y a escala mundial. Sumada a los procesos de DDTs actualmente en curso, esa evolución podría reducir notablemente la resiliencia a la sequía y ocasionar alteraciones mundiales de los sistemas de producción de alimentos (Figura 2-3).

La degradación de la tierra afecta también al valor de la tierra, frecuentemente determinado por su capacidad para proporcionar bienes tales como alimentos, combustibles y fibra. Según estimaciones, el promedio mundial de las pérdidas económicas de productividad debidas a la degradación de la tierra a nivel local representa entre un 3% - 5% del producto interno bruto agrario, es decir, aproximadamente 490,000 millones de dólares anuales (Berry, 2003).



Figura 2-3. Efectos de amplio alcance, y la espiral descendente de la DDTs.

Según ciertos autores, la posibilidad de una crisis de abastecimiento de agua y de alimentos representa el segundo y tercer riesgos mundiales más importantes atendiendo a sus posibles efectos económicos. Ambos riesgos están relacionados en numerosos casos a los procesos de degradación de la tierra, aunque ésta no está considerada todavía como un riesgo importante para la sostenibilidad de las empresas ni para la economía mundial.

Nuestra sociedad mundial esta, literalmente “perdiendo terreno”. La extensión actual de las tierras degradadas y en trance de degradación afecta a numerosas personas, y acarrea un costo económico y social considerable. Para invertir con éxito la tendencia de degradación de las tierras es necesario abordar urgentemente y de manera integrada sus causas subyacentes, y crear instrumentos y mecanismos que fomenten la adopción y difusión de prácticas de gestión sostenible de la tierra, tanto en términos de extensión como de eficacia.

2.2 Pérdida de Biodiversidad

Dependemos de la biodiversidad y de los servicios del ecosistema para satisfacer nuestras necesidades diarias así como nuestro desarrollo económico y cultural (Figura 2-4). Esto no solo abarca la producción alimentaria y la recolección, sino también otras actividades como la industria, el turismo y la artesanía. La degradación de la tierra y el cambio climático están teniendo significantes e irreversibles impactos en la biodiversidad en todo el mundo (UNCCD, 2013).

La degradación del suelo está reduciendo todo tipo de recursos disponibles, haciéndonos menos resistentes y más vulnerables a los impactos del cambio climático. Las especies locales, las plantas silvestres afines y sus reservas genéticas pueden suponer una guía hacia la mejora de los cultivos, la diversidad y la resiliencia del ganado de cara a los cambios medioambientales. La pérdida de biodiversidad y del hábitat contribuye a la inseguridad y al empobrecimiento de algunas de las comunidades y naciones más frágiles (UNCCD, 2013).



Figura 2-4. La biodiversidad es la base de unas tierras de cultivo y unos pastizales sanos y productivos. Reducir a la mitad la pérdida y la degradación de ecosistemas, restaurar al menos el 15% de los ecosistemas degradados antes de 2020 – en línea con las Metas de Aichi para la Diversidad Biológica – y alcanzar la NDT son pasos esenciales en el camino hacia el desarrollo sostenible, ayudándonos en la producción de más alimento, mitigando y adaptándonos al cambio climático y reduciendo la vulnerabilidad antes los desastres.

2.3 La tierra y el Cambio Climático

La degradación de la tierra es a la vez una causa y una consecuencia del cambio climático. Y lo que es más preocupante, la degradación de la tierra y el cambio climático pueden formar un “bucle de retroalimentación” en donde la producción de alimentos hace aumentar las emisiones, mientras que la pérdida de suelo y de vegetación reduce de manera significativa los posibles sumideros de carbono (Figura 2-5). El resultado es un incremento de los gases de efecto invernadero en la atmósfera, alimentando un ciclo energético de degradación de la tierra, pérdida de biodiversidad y cambio climático.

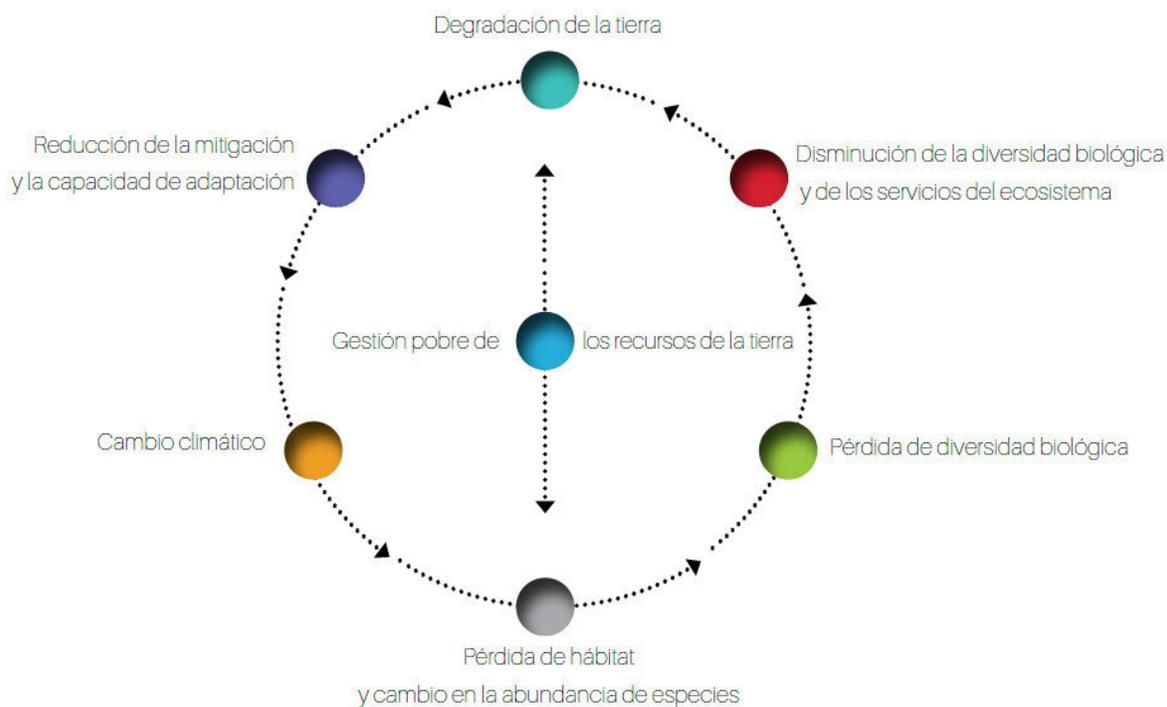


Figura 2-5. Los circuitos de retroalimentación y los objetivos de las Convenciones de Río.

2.4 Degradación de suelos agrícolas por salinización

El riego de tierras agrícolas ha sido considerado ya desde hace varios milenios la manera más efectiva de incrementar y regular la producción agrícola, especialmente en climas áridos y semiáridos. Los beneficios derivados de la agricultura de riego frecuentemente no han sido sostenibles por la salinización o desarrollo de suelos afectados por sales. Esta salinización puede conducir a una pérdida parcial o total de la capacidad productiva del suelo, al provocar una degradación interna, prácticamente irreversible, de sus propiedades químicas y físicas (Lleida, 1997).

2.4.1 Procesos y causas de la salinización de suelos en tierras bajo riego

Los problemas de salinización de suelos son generalmente la consecuencia de la acumulación de sales en zonas y profundidades donde el régimen de humedad del suelo se caracteriza por fuertes pérdidas de agua por evaporación y transpiración (Lleida, 1997), y por un reducido lavado de las sales que estaban disueltas en ella. A pesar de que estos procesos de salinización se pueden desarrollar en forma progresiva bajo condiciones naturales, donde existan combinaciones de aridez y drenaje restringido, generalmente solo se aceleran cuando el régimen de humedad del suelo cambia drásticamente con intervención del hombre, especialmente con la introducción del riego sin una adecuada combinación de su manejo y de las condiciones de drenaje.

Las aguas de riego contienen siempre sales en solución, en variables cantidades y composiciones. Sus aportes de sales pueden alcanzar hasta 10 toneladas (Mg) por hectárea en un año. La mayoría de esas sales permanecen en el suelo cuando el agua de riego se pierde fundamentalmente por evapotranspiración. Cuando dichas sales no son lavadas al subsuelo y eliminadas con el agua drenaje interno, pueden acumularse en el suelo superficial hasta niveles que afecten el crecimiento de las plantas o las propiedades del suelo (Lleida, 1997). Cuando el lavado requerido no es provisto por un exceso de agua de lluvia, lo cual es más común en climas áridos y semiáridos, se requerirá aplicar un exceso de agua de riego con dicho fin. Si dichos excesos de agua no son evacuados a través de sistemas naturales o artificiales de drenaje, las sales lavadas pueden volver a resalinizar el suelo superficial en el mismo sitio o en áreas adyacentes.

De los argumentos precedentes pueden sacar la solución de que la introducción de riego en zonas áridas, semiáridas e incluso subhúmedas, pueden conducir a la salinización del suelo cuando no existen o no se proveen las condiciones adecuadas de drenaje.

2.4.2 Características y condiciones para el desarrollo de suelos salinos

Todos los suelos con problemas derivados directa o indirectamente de la cantidad o tipo de sales presentes en la solución del suelo, se llaman genéricamente "*suelos afectados por sales*". Los problemas resultantes pueden ser muy diferentes dependiendo de los procesos geoquímicos que intervengan en el proceso de salinización, ya sea de origen primario (procesos naturales) o secundario (con intervención del hombre). En ambos casos los factores responsables son la concentración y la composición relativa de las sales en las aguas superficiales y subterráneas, y los

cambios que pueden sufrir en la solución del suelo como consecuencia de la influencia del clima, del riego y del drenaje sobre el régimen hídrico del suelo. Los principales factores climáticos a considerar son la lluvia y la evapotranspiración. El drenaje es resultado de las propiedades hidráulicas del perfil del suelo, de la profundidad del nivel freático y de la posición en el paisaje. En cuanto al riego interesan las cantidades de agua aplicar, el método y la frecuencia (Leida, 1997).

2.5 La desertificación en la Región de Piura

La degradación de tierras es un problema grave para la región de Piura, por sus efectos en las actividades productivas, sociales y en el medio ambiente en general. Si bien existe consenso entre los expertos que se trata de un problema de vital importancia para la región, no se ha alcanzado un acuerdo en cuanto a la delimitación y profundidad de este flagelo. Las cifras estimadas por los estudiosos de este fenómeno, no obstante, se aproximan. Respecto de las causas, también hay consenso: la actividad agrícola, y dentro de ella la producción de arroz y la deforestación, serían los principales agentes causantes de la desertificación, junto al sobrepastoreo (César et al., 2013).

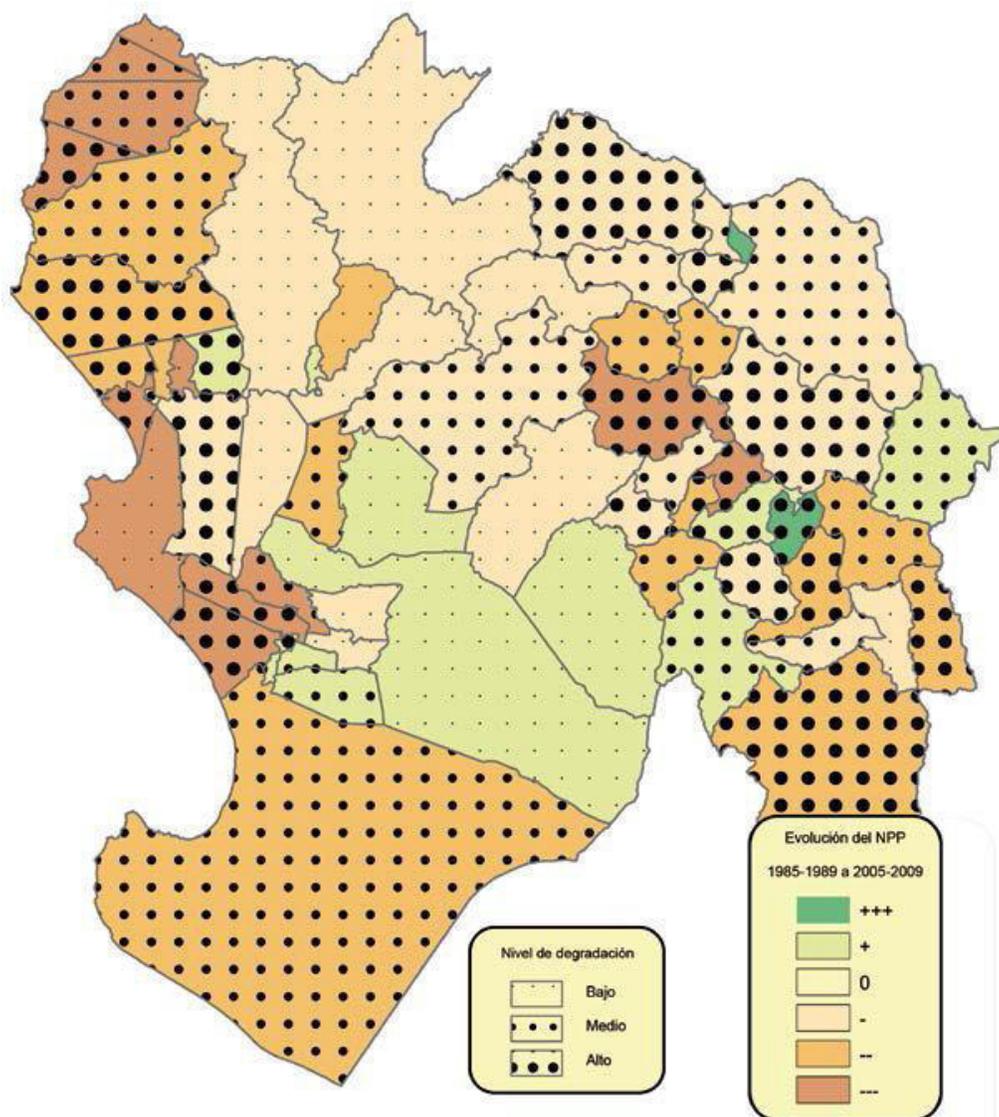
De la Tabla 1-1 y siendo la superficie total de Piura 3 589 250 ha, el área afectada por desertificación y deforestación alcanza los 19.97%. En cuanto al nivel nacional, la Cuarta Comunicación Nacional del Perú a la Convención de las Naciones Unidas de Lucha contra la Desertificación, publicada en 2011, señala que “cerca de la tercera parte de la superficie del Perú se halla en algún estado de desertificación, ya sea como zona desertificada o en proceso de desertificación” (César et al., 2013).

2.5.1 Evolución de la biomasa como aporte al análisis de la desertificación en Piura.

En el marco de la elaboración del Atlas Mundial de la Desertificación (WAD por sus siglas en inglés), el Joint Research Centre de la UE elaboró mediante imágenes satelitales puntos ubicados a aproximadamente 5km de distancia entre sí, cada uno de ellos conteniendo información respecto del promedio anual de la producción primaria neta (NPP) para el periodo 1982-2009. El mapa modificado para la Región de Piura se muestra en el Mapa 2-1.

Dada la influencia del fenómeno ENOS en el clima de Perú en general y en la producción de la biomasa en particular, se ha preferido evitar años clave, como 1982-1983, en el análisis comparativo. Por ello, con el fin de reconocer tendencias en su evolución, se ha preferido comparar el promedio de producción de biomasa por distrito de 1985-1989 con el de 2005-2009. Una vez conocida la tendencia, *Morales et al., 2013* procedió a organizar los distritos según hayan tenido una evolución negativa, es decir, la producción primaria neta se redujo entre el periodo 2005-2009 en relación con el periodo 1985-1989 o positiva, es decir, dicha producción se incrementó en ambos periodos.

Predicción de Tierras Degradadas a Partir del Análisis de Series Temporales del Índice Mejorado de Vegetación y Temperatura de superficie de Suelo mediante Imágenes MODIS - Caso Estudio Piura



Mapa 2-1. Elaboración propia en base a data del WAD Atlas Mundial de la Desertificación, Joint Research Centre UE y del Mapa de desertificación del Gobierno Regional de Piura.

2.6 DETECCIÓN DE CAMBIOS EN LA COBERTURA TERRESTRE

En términos generales, la detección de cambios en la cobertura de la tierra está relacionada cuando la cobertura de un lugar determinado ha experimentado un cambio de un tipo a otro, estos cambios **contribuyen al cambio climático** y el desequilibrio ecológico y hacen que la capacidad de la Tierra como apoyo a las necesidades humanas sean cada vez menos. Por lo tanto la ubicación de los cambios en la superficie de la tierra y la cuantificación de su tiempo y magnitud, así como la evaluación de sus efectos sobre los ecosistemas son difíciles (Lambin, 2006). Los cambios pueden consistir en las transformaciones de la superficie de la tierra o de las conversiones y pueden estar relacionados con las dinámicas naturales o por las actividades humanas. Además puede presentarse cambios abruptos o graduales (Coppin, 2004).

Los sensores remotos pueden ser útiles en la evaluación de los impactos de las actividades humanas sobre la superficie terrestre. Los sensores de mediana resolución proporcionan series de tiempo de imágenes de información de la superficie. Aunque la limitada resolución espacial de estas series de tiempo restringen la gama de cambios que se puede detectar (Coppin, 2004), sin embargo su alta resolución temporal ofrece la oportunidad de describir la evolución de la superficie de la tierra. Para análisis de series de tiempo hay muchas técnicas como la diferenciación de imagen (Ingram, 2005), cambios vectoriales multitemporales (Bayarjrgal et al., 2006), los modelos de regresión (Frase et al., 2005), el análisis de componentes principales (Singh et al., 1985), redes neuronales, wavelets (Woodcock et al., 2001) y transformadas de Fourier (Azzali et al., 2000) todas estas técnicas actualmente son muy usados para detectar cambios en las series de tiempo o los llamados breakpoint.

Introduzcamos la siguiente notación para describir los tipos de datos para la detección de cobertura del suelo. Sea C el conjunto de datos con ubicaciones terrestres T . En término generales, hay dos tipos de datos que se utilizan para la detección de cambios en la cobertura de la tierra: bitemporales (instantáneas de dos fechas) y multitemporal (datos desde múltiples fechas) que son las **series de tiempo**. Dado que la naturaleza de estos dos tipos de datos es muy diferente, utilizaremos la siguiente notación distinta para cada uno.

2.6.1 Bitemporal

Estos datos típicamente se representan como las imágenes de dos fechas diferentes.

T1 Fecha de la primera imagen.

T2 Fecha de la segunda imagen.

M1 una matriz $m \times n$ que representa la imagen en el tiempo T1. Cada entrada (intensidad de los píxeles) en la matriz corresponde a una ubicación individual de la tierra, es decir, $m \times n = N$.

M2 una matriz $m \times n$ que representa la imagen en el tiempo T2.

Tenga en cuenta que T1 y T2 puede ser multiespectral, en cuyo caso son matrices tridimensionales. Con el fin de mantener la simplicidad de notación, no vamos a especificar explícitamente la tercera dimensión (correspondiente a los espectros), pero se entiende que el comparar las ij píxeles a partir de dos imágenes, cada espectro se compara individualmente.

2.6.2 Multitemporal/ Series de Tiempo

Cada lugar de la tierra tiene una serie de tiempo de longitud T. La serie temporal de un lugar corresponde a T quincenales/ observaciones mensuales en esa ubicación. Por ejemplo cada 16 días tendremos un dato a lo largo del tiempo.

2.7 TAXONOMÍA DE TÉCNICAS DE DETECCIÓN DE CAMBIO DE COBERTURA DE LA TIERRA.

Shyam Boriah propone una taxonomía de los principales enfoques de detección de cambio (Figura 2-6), que describiremos de manera general cada uno de ellos, enumerando los puntos fuertes y débiles, pero sin entrar en los detalles de las técnicas específicas, ya que hay una serie de estudios excelentes que tratan sobre una gran variedad de técnicas con gran detalle.

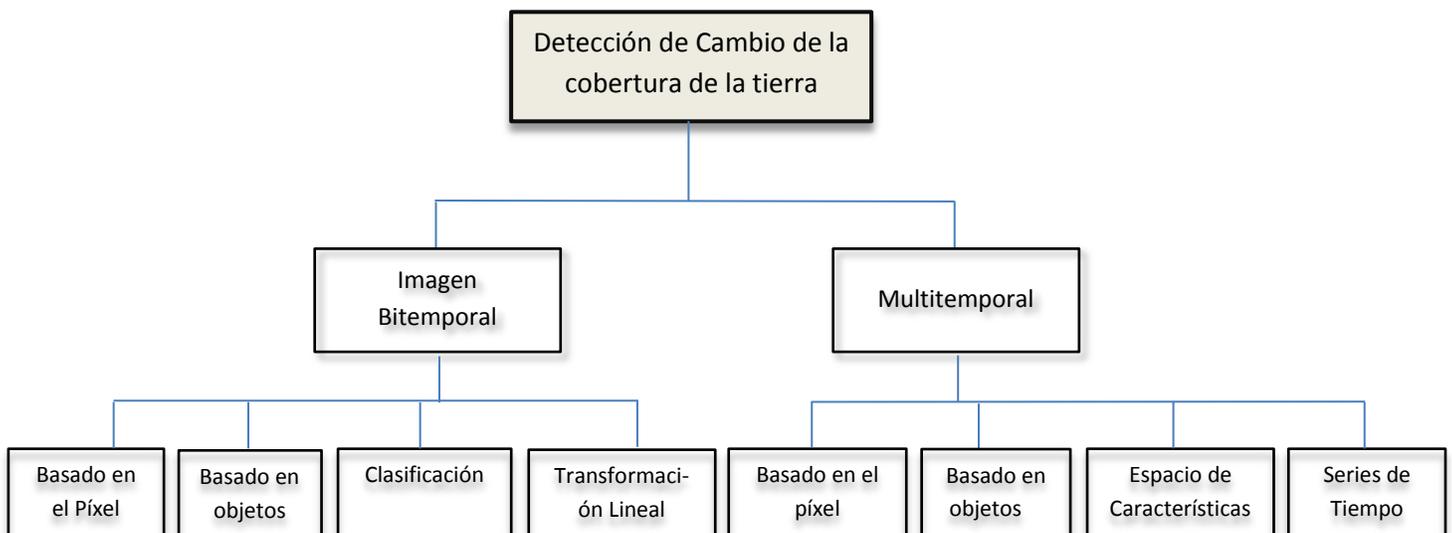


Figura 2-6. Taxonomía de técnicas para la detección de cambios en la cobertura terrestre.

2.8 Técnicas Bitemporales

Los métodos de detección que se basan en imágenes bitemporales comparan dos imágenes instantáneas T1 y T2 de diferentes fechas. La salida por lo general es de la forma de un cambio de máscara M, que es una matriz mxn con $M_{ij}=1$ si ij ha cambiado y $M_{ij}=0$ en caso contrario.

2.8.1 Técnicas basadas en el Píxel

Técnicas basadas en píxeles simples son los que comparan píxel ij para el tiempo T1 con el mismo píxel para el tiempo T2. Estas técnicas abarcan una gran variedad de métodos que van desde la simple diferenciación de una imagen con la otra, hasta los enfoques más sofisticados de regresión. En el caso de una diferenciación simple M_{ij} , se calcula como sigue:

$$M_{ij} = \begin{cases} 1 & \text{si } (T_2 - T_1)_{ij} > \tau \\ 0 & \text{de lo contrario} \end{cases} \quad (2.1)$$

Aquí τ es un umbral especificado por el usuario que denota cuando un píxel dado se considera que ha cambiado. **CLASlite** es un enfoque similar basado en píxeles donde en lugar de la diferencia, la relación se compara con un umbral. Un enfoque más sofisticado construye un modelo de regresión que calcula una relación funcional entre las imágenes bitemporales y luego compara el valor del píxel predicho con el valor del píxel de la primera imagen. Técnicas basadas en píxeles simples puede ser eficaz para estudios localizados, pero su principal inconveniente es que son extremadamente sensibles al ruido. En este momento las técnicas de este tipo, que recorren por ejemplo en *Change Vector Analysis*, usan los umbrales con base en el tipo de cobertura, reduciendo asimismo el ruido. Para grandes áreas, principalmente en el contexto de aplicaciones operacionales, no es muy fácil la utilización de series temporales. Todos los grandes programas de cartografía de cobertura de la tierra a nivel mundial usan esencialmente técnicas basadas en métodos bitemporales.

2.8.2 Clasificación basada en objetos

El problema de la utilización de umbrales es que son dependientes de los datos. Por ejemplo, el porcentaje de píxeles de la vegetación varían significativamente entre los datos que se capturan en verano o en invierno (Volker, 2004). Otros factores que influyen son la luz, las condiciones climáticas y el tipo de suelo (Volker, 2004). Por lo tanto, no podemos utilizar los mismos umbrales para diferentes conjuntos de datos. Con el fin de evitar el problema de definir umbrales dependientes de los datos, se introduce un enfoque de clasificación basada en objetos. La clasificación basada en objetos funciona de la misma manera que una clasificación basada en píxeles con la diferencia de que se clasifica cada píxel, pero combinados todos los píxeles de cada objeto.

2.8.3 Transformación Lineal

Técnicas de transformación lineal se basan esencialmente en la codificación de imágenes como una matriz y el examen de las propiedades estructurales de la matriz utilizando técnicas de álgebra lineal. El enfoque básico comienza mediante la representación de las imágenes como columnas de una matriz M , es decir, que 1 y 2 se convierten en vectores columna $T1$ y $T2$. El siguiente paso es aplicar una transformación lineal tal como Análisis de Componentes Principales (ACP).

El ACP descompone la matriz en vectores propios y valores propios (clasificados). Los valores propios mayores y vectores propios correspondientes, generalmente representan la mayor parte de la variación en la matriz. El supuesto es que los grandes valores propios representarán la parte sin cambio, mientras que los valores propios más pequeños representarán las partes codificadas. Una variación del enfoque clásico es aplicar ACP a la imagen diferenciada. En este caso, los grandes valores propios corresponden a las partes modificadas de la imagen (Boriah, 2010).

2.8.4 Clasificación.

Los métodos de detección de cambio basados en la clasificación consisten en entrenar un clasificador para diferentes tipos de cobertura. El enfoque básico es clasificar $T1$ y $T2$ por separado y luego comparar las etiquetas de clase clasificado píxel por píxel. Si la clasificación o clase pronosticada es diferente entre $T1$ y $T2$ para el píxel ij , entonces ij se considera que ha cambiado.

Métodos basados en clasificación pueden ser muy poderosos, sobre todo cuando los clasificadores pueden ser entrenados con alta fiabilidad (esto se ha hecho con los árboles de decisión, y redes neuronales). Sin embargo, en general obtener etiquetas para grandes regiones manualmente es muy engorroso, lento y un proceso costoso.

2.9 Técnicas Multitemporal

Las técnicas multitemporales pueden tener dos puntos de vista desde los datos disponibles: 1) una secuencia de imágenes de la misma ubicación de diferentes fechas o 2) como un conjunto de series de tiempo correspondiente a cada píxel.

2.9.1 Las técnicas basadas en píxeles multitemporales

Esta técnica es una extensión de la diferenciación sencilla del espacio multitemporal al espacio multidimensional (correspondiente a múltiples espectros) donde se consideran varios canales espectrales en lugar de uno solo. El enfoque clásico consiste en construir vectores entre los pasos de tiempo sucesivos en el espacio multidimensional. La longitud de un vector dado corresponde a la magnitud del cambio entre las etapas de tiempo respectivos, mientras que la dirección corresponde a la naturaleza del cambio. Esta técnica sufre las mismas limitaciones que la diferenciación simple, ya que requiere la determinación de un umbral y es sensible al ruido (Boriah, 2010).

2.9.2 Clasificación basada en objeto

La clasificación multitemporal basada en objeto utiliza una secuencia de imágenes de la misma ubicación de diferentes fechas para obtener atributos y características de la superficie terrestre.

2.9.3 Espacio de Características

Esta clase de técnica de detección de cambio consiste en construir un espacio de alta dimensión característica, que se deriva de una serie de tiempo. Se usa un clasificador para entrenar modelos en el espacio de alta dimensión característica y toma un enfoque similar a la clasificación bitemporal para detectar cambios. Las técnicas que utilizan este enfoque han mostrado promesas recientes, pero el entrenamiento de un clasificador puede ser engorroso. Estas técnicas son sensibles a la calidad del espacio de característica y existe un potencial para la pérdida de información en la transformación (Boriah, 2010).

2.9.4 Series de Tiempo

La interpretación de perfiles en el tiempo permite caracterizar la dinámica de la vegetación en diferentes escalas temporales y, por lo tanto, para diferenciar entre las modificaciones repentinas en la dinámica estacional. Tal caracterización ha demostrado ser más eficaz cuando los procedimientos analíticos se implementan para tener en cuenta las dependencias temporales existentes entre las observaciones sucesivas de las series de tiempo (Beurs, 2005). Sin embargo, aunque se ha propuesto una amplia gama de algoritmos de detección de cambio para analizar series de tiempo, la mayoría de ellos no se ocupan de la cuestión de las dependencias temporales entre las observaciones. Una primera categoría de técnicas se basan en procesos de clasificación con una sola fecha de clasificación o conjuntos plurianuales de datos también se clasifican para aislar los cambios en las clases dinámicas como la regeneración de bosque o deforestación (Cardille, 2003). Aunque actualmente hay técnicas de detección que analizan el componente estacional propias de las series de tiempo como BFAST (Verbesselt et al., 2012).

Aunque los enfoques de series de tiempo¹ utilizan la mayoría de la información y es potencialmente la técnica más poderosa para la detección de cambios, su aplicabilidad es restringida debido a algunos detalles. En concreto, los instrumentos satelitales que recogen datos con una frecuencia temporal alta tienen una resolución espacial muy gruesa. Por lo tanto, estas técnicas no se pueden usar para cambios muy pequeños a escala mayor. Además, los enfoques de series de tiempo tienen un valor limitado cuando la serie de tiempo es de corta duración (por ejemplo cuando un satélite acaba de ser lanzado) (Boriah, 2010).

¹ El enfoque de las series de tiempo y la matemática que hay detrás se estudiará con más detalle en los capítulos siguientes.

2.10 SERIES DE TIEMPO

La historia de las series de tiempo se puede dividir en dos épocas (Observación, Medición y Generalización por una parte y por la otra la Formalización) teniendo en cuenta los métodos para abordar los diferentes fenómenos que motivaron el estudio del comportamiento de ciertos elementos respecto al tiempo.

2.10.1 Observación, medición y generalización

El antecedente más antiguo se remonta a 1846 cuando el astrónomo Heinrich Schwabe, observó la actividad periódica de las manchas solares (*sunspots*). Seguido de décadas de investigación, no solo en física solar sino en el magnetismo terrestre, meteorología e incluso economía, donde se examinaban las series para comprobar si su periodicidad coincidían con los diferentes fenómenos anteriormente mencionados, por ejemplo, Simon Laplace y Jacques Quetelet, habían analizado datos meteorológicos y William Herschel había escrito un libro al respecto. Todos estos estudios basados en la observación empírica.

Las técnicas en uso variaban desde las más simples, como la tabla de Buys Ballot, la cual permitía conocer los centros de alta y baja presión respecto de la dirección en que sopla el viento, a formas más sofisticadas como el análisis armónico, es el caso del físico Arthur Schuster quien introdujo en 1889 el periodograma, el cual permite calcular la densidad espectral de una señal.

Sin embargo, por ese entonces, una forma rival del análisis de series temporales, basada en la correlación y promovida por Pearson, Yule y Hooker y otros, fue tomando forma.

2.10.2 Formalización

El análisis estadístico de series de tiempo tiene sus inicios formales con el texto escrito por George Udny Yule en 1927 llamado "*On a Method of Investigating Periodicities in Disturbed Series, with Special Reference to Wolfer's Sunspot Numbers*", donde, basado en el concepto de correlación intenta explicar las manchas solares con otros fenómenos astronómicos.

A pesar de los avances propuestos por varios estadísticos influyentes de la primera década del siglo XX, no fue sino hasta 1970, con la publicación de "*Time Series Analysis: Forecasting and Control*" por Box y Jenkins en 1970, que se constituyó una herramienta bibliográfica, que permitía aplicar los métodos de series de tiempo de manera sistemática, y además logró unificar el objetivo de investigación.

Es importante mencionar que el desarrollo teórico y práctico del análisis de series de tiempo está estrechamente relacionado con el desarrollo informático, ya que este, provee las herramientas necesarias para los extensos cálculos que demandan los métodos inherentes al análisis de series de tiempo. Uno de los más importantes consiste en la parametrización de los modelos de estado y espacio y el **filtro Kalman** desarrollados en su mayoría al final de la década de 1970.

2.10.3 Definición de Series temporales

Una serie temporal es una sucesión de observaciones de una variable tomadas en el transcurso del tiempo, de manera que los valores que toma la variable aparecen ordenados cronológicamente a intervalos iguales.

De acuerdo a Bowerman y O'Connel (1993), una serie de tiempo es una secuencia cronológica de observaciones de una variable particular.

2.10.4 Ejemplos de Series de Tiempo

Algunos ejemplos de series de tiempo en diversas disciplinas se muestran a continuación.

Tabla 2-1. Ejemplo de series de tiempo.

Series de Tiempo	Ejemplos
1. Series Económicas	-Precios de un artículo -Tasas de desempleo -Tasa de inflación -Índice de precios, etc
2. Series físicas	-Meteorología -Cantidad de agua caída -Temperatura máxima diaria -Velocidad del viento -Energía solar, etc
3. Geofísicas	-Series sismológicas
4. Series demográficas	-Tasa de crecimiento de la población -Tasa de natalidad, mortalidad -Resultados de censos posicionales
5. Series de marketing	-Series de demanda, oferta, etc.
6. Series de telecomunicaciones	-Análisis de señales
7. Series de transporte	-Series de tráfico
8. Series de índices de vegetación	-NDVI -EVI -AVI, etc.

2.10.5 Objetivos de análisis de series de tiempo

Según Chatfield (1978), son varios los objetivos por los cuales se puede querer analizar una serie de tiempo.

- **Descripción:** Cuando tenemos una serie de tiempo, el primer paso en el análisis es graficar

los datos y obtener medidas descriptivas simples de las propiedades principales de la serie.

- **Explicación:** Cuando las observaciones son tomadas sobre dos o más variables, es posible usar la variación en una serie para explicar la variación en otras series.
- **Predicción:** Dada una serie de tiempo se puede querer predecir los valores futuros de la serie. Este es el objetivo más frecuente en el análisis de series de tiempo.
- **Control:** Cuando una serie de tiempo se genera por mediciones de calidad de un proceso, el objetivo del análisis puede ser el control del proceso.

2.10.6 Componentes de una Serie Temporal

El análisis clásico de series temporales considera que una serie temporal queda formada por cuatro componentes:

2.10.6.1 *Tendencia*

Patrón de evolución sostenido a mediano y largo plazo de la serie. Crecer, decrecer o estable. "Se determinar usando regresiones lineal".

2.10.6.2 *Ciclo*

Movimiento oscilatorio por encima y por debajo de la tendencia de una serie temporal.

2.10.6.3 *Estacionalidad*

Oscilaciones de una serie temporal que se completa dentro de un periodo largo (un año) y se repiten más o menos de forma invariable en los periodos (años) sucesivos.

2.10.6.4 *Aleatorio*

Oscilaciones de una serie temporal que se atribuyen a factores fortuitos, aleatorios y esporádicos.

Estos cuatro componentes conforman la serie de tiempo. Estos componentes se pueden apreciar en la herramienta computacional R. Solo es cuestión de graficar mediante la función "stl" y tendremos como respuesta la Figura 2-7.

Predicción de Tierras Degradadas a Partir del Análisis de Series Temporales del Índice Mejorado de Vegetación y Temperatura de superficie de Suelo mediante Imágenes MODIS - Caso Estudio Piura

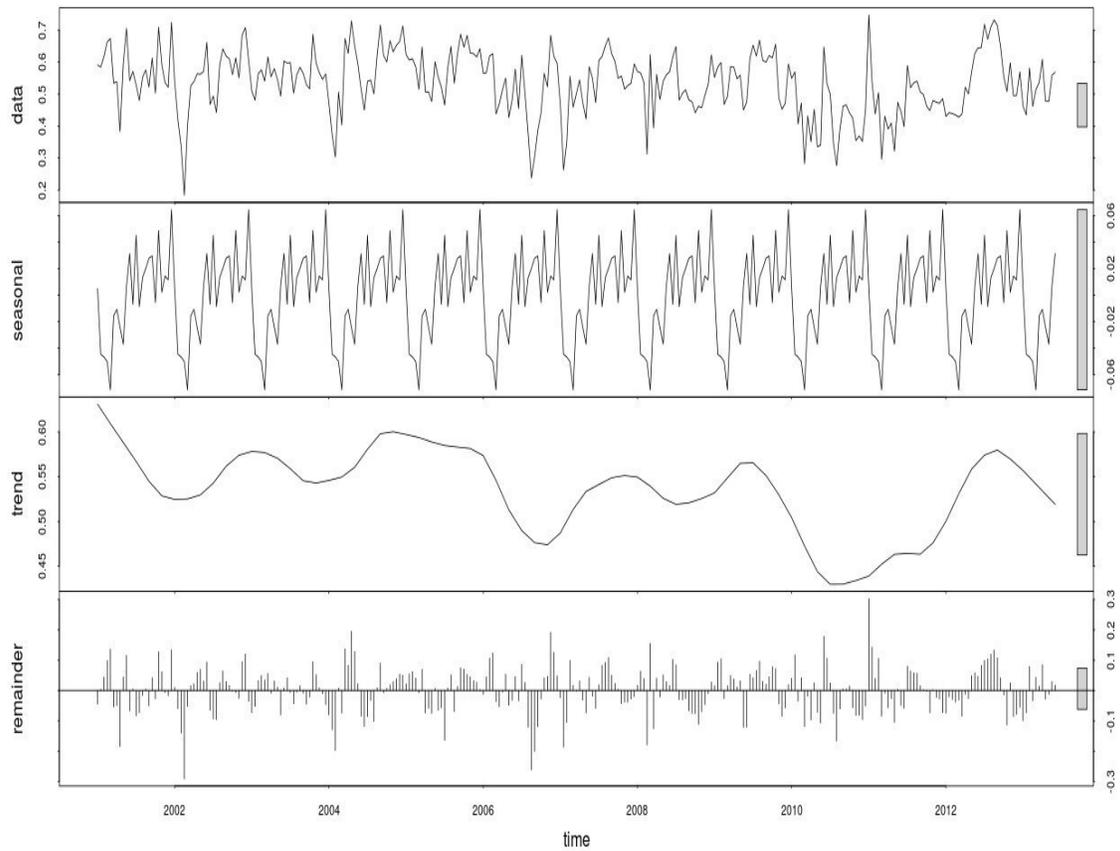


Figura 2-7. En el gráfico superior notamos la Serie de Tiempo, en el siguiente la estacionalidad, en la subsiguiente la tendencia y por último lo aleatorio.

2.11 ANÁLISIS PRELIMINAR DE SERIES DE TIEMPO

Son los primeros estudios y análisis que se hace a las series de tiempo. La forma más sencilla de iniciar el análisis de una serie temporal es mediante su representación gráfica. Para ello, en un sistema cartesiano, los valores de la serie Y_t se representan en el eje de ordenadas y los periodos de tiempo en el eje de abscisas. Mediante este tipo de representación se pueden detectar las características más sobresalientes de la serie, tales como el movimiento a largo plazo, la amplitud de las oscilaciones, la posible existencia de ciclos, los puntos de ruptura, la presencia de valores atípicos o anómalos, etc. Posteriormente, es conveniente recurrir a otras técnicas que superen el simple análisis gráfico.

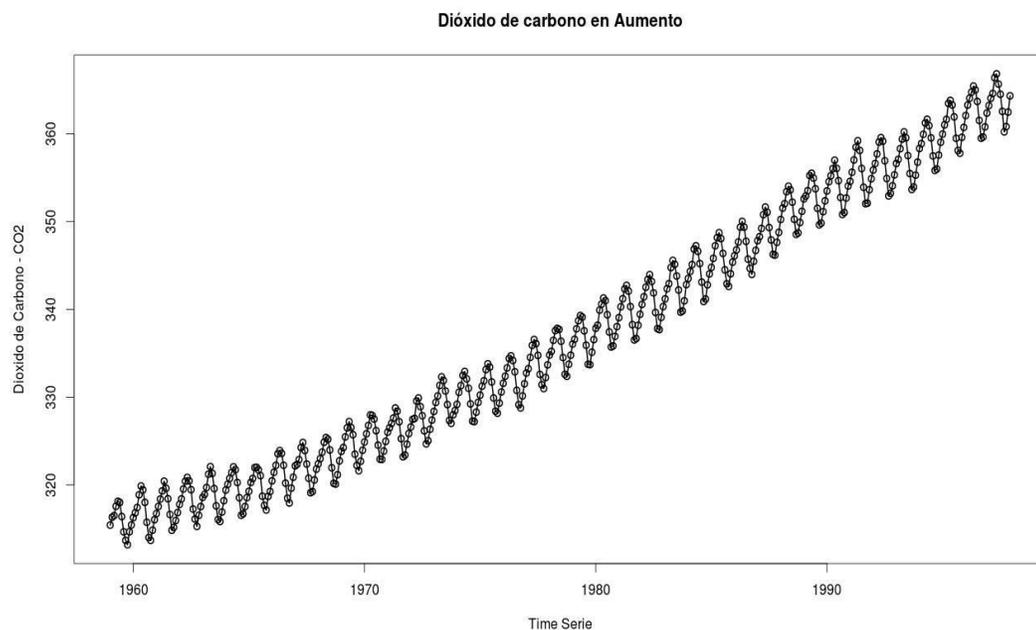


Figura 2-8. Tomados desde 1960-1997, muestra cómo se incrementa el Dióxido de Carbono en nuestra atmósfera en un claro ejemplo de una serie de tiempo.

2.11.1 Test de Normalidad de los residuos

Verificar que la Serie de Tiempo (ST) siga la curva normal, es importante porque la mayoría de modelos de ST como de Box-Jenkins parten del hecho que los datos siguen la curva normal, es decir, la ST sigue la curva normal.

El test de normalidad se realiza sobre la primera diferencia de las Series de Tiempo. Mostraremos un ejemplo mediante el lenguaje de programación R.

```
> vector < -1:10
```

```
> vector  
[1] 1 2 3 4 5 6 7 8 9 10  
> diff(vector)  
[1] 1 1 1 1 1 1 1
```

Veamos más detenidamente término a término.

$2 - 1 = 1, 3 - 2 = 1, 4 - 3 = 1, 5 - 4 = 1, 6 - 5 = 1, 7 - 6 = 1, 8 - 7 = 1, 9 - 8 = 1, 10 - 9 = 1$

“La función **diff** lo que nos resalta es la diferencia de un dato a otro, entonces lo que se busca es ver que los datos saltos o caídas de un dato a otro debe seguir la curva normal (Figura 2-9), se hace esto para evitar que no haya tipicidades o saltos grotescos en una ST”.

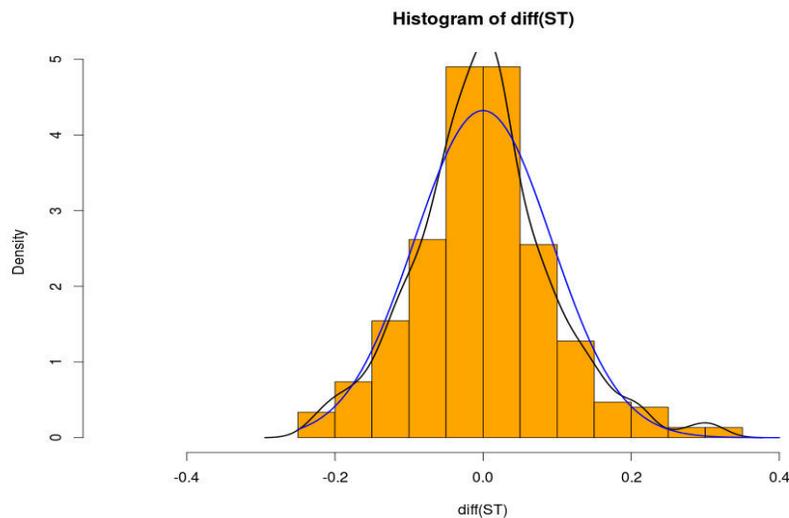


Figura 2-9. El test de normalidad nos permite identificar valores anómalos dentro de una serie de tiempo.

2.11.2 Filtros de Series

Un filtro no es más que un tratamiento aplicado a un “input”, $\mu(t)$, de manera que se obtiene un “output”, $Y(t)$.

En el caso de filtros lineales no recursivos la relación general entre el *input* y *output* responde a la expresión siguiente.

$$Y(t) = \sum_{k=-\infty}^{k=\infty} c_k \mu_{t-k} \quad (2.2)$$

Como se puede apreciar, el output no es más que una combinación lineal de los valores del input

pasados, presente y futuros. Los coeficientes C_k pueden tomar cualquier valor, (incluso ser nulos para algún valor de k), en el caso de que los coeficientes sean constantes a lo largo del tiempo hablaremos de filtros invariantes con el tiempo que será el caso habitual y el que usaremos en este estudio.

Un ejemplo de filtro **no-recursive** nos lo proporciona una media móvil centrada de orden 3.

$$Y(t) = \sum_{k=-1}^{k=1} \frac{1}{3} \mu_{t-k} = \frac{1}{3} \mu_{t-1} + \frac{1}{3} \mu_t + \frac{1}{3} \mu_{t+1} = \frac{1}{3} (\mu_{t-1} + \mu_t + \mu_{t+1}) \quad (2.3)$$

2.11.2.1 Promedios Móviles

Es el método de suavización bastante simple, en el que se relaciona un número N , y se obtiene la media o promedio de la variable para los N datos, permitiendo que el promedio se mueva conforme se observan los nuevos datos de la variable en cuestión.

“Esto suaviza posibles oscilaciones fuertes o datos atípicos, es decir, elimina atipicidades”

$$Y(t) = \sum_{i=-\infty}^{\infty} \lambda_i X_{t+i}; \quad Y(t) = \frac{1}{2a+1} \sum_{i=-a}^a X_{t+i};$$

$$a = 2: \lambda_i = \left\{ \frac{1}{5}, \frac{1}{5}, \frac{1}{5}, \frac{1}{5}, \frac{1}{5} \right\};$$

$$a = 12: \lambda_i = \left\{ \frac{1}{25}, \frac{1}{25} \right\};$$

$$a = 40: \lambda_i = \left\{ \frac{1}{81}, \dots, 40 \text{ veces}, \dots, \frac{1}{81}, \dots, 40 \text{ veces}, \dots, \frac{1}{81} \right\} \quad (2.4)$$

Veamos mediante gráficos los resultados de aplicar filtros no recursivos (Figura 2-10).

Predicción de Tierras Degradadas a Partir del Análisis de Series Temporales del Índice Mejorado de Vegetación y Temperatura de superficie de Suelo mediante Imágenes MODIS - Caso Estudio Piura

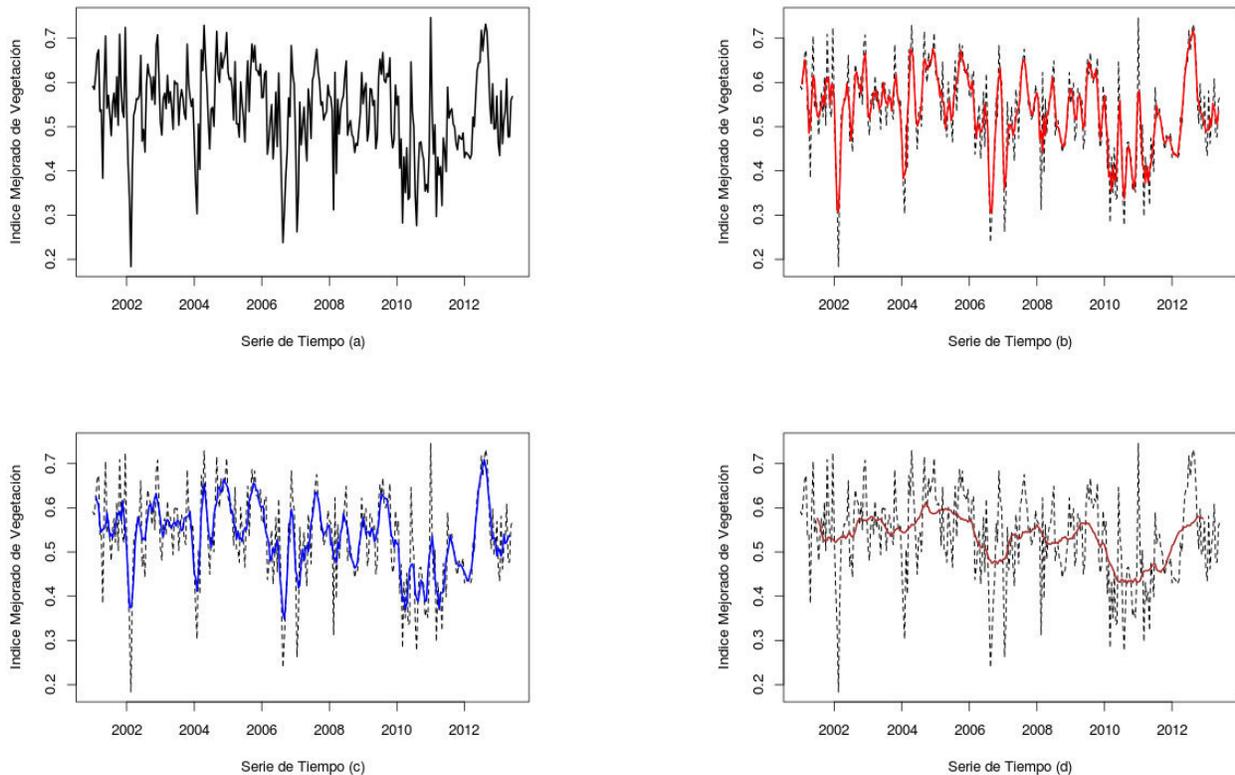


Figura 2-10. En la figura (a) se muestra una serie de tiempo tal cual es, mientras que en la figura (b) superior derecha se muestra en línea oscura, la serie original y sobre ella la serie suavizada con $\alpha = 3$ en color rojo. Lo mismo para la figura (c) se muestra un suavizamiento con $\alpha = 5$ y en la figura (d) un suavizamiento con $\alpha = 25$.

A veces aplicar un suavizamiento con “a” bastante grande ocasiona que estemos eliminando ciertos valores o saltos atípicos en una serie que en la vida real ocurre y que es un falso valor anómalo o outlier. Por ello se recomienda aplicar un suavizamiento con $a = 2, 3, 4$ de tal manera que no eliminemos estacionalidades.

2.12 Análisis de series temporales desde la matemática

Una serie de tiempo no es más que el resultado de la Tendencia, estacionalidad y lo aleatorio. Todos estos componentes son estudiados mediante regresiones y funciones periódicas que permitirán alcanzar algún objetivo del estudio de ST.

2.12.1 Regresión Lineal

La regresión en las series de tiempo busca modelar la tendencia, el decrecimiento, el crecimiento o la combinación de ambas. Por ello en este subcapítulo daremos un breve repaso a las regresiones desde la matemática.

El objetivo de las regresiones es estudiar la asociación entre dos variables conocida también como asociación simple. La primera forma de del estudio de la asociación entre las variables X e Y es denominada regresión, que consiste en determinar la relación funcional lineal o no lineal entre ellas, con el fin de predecir el valor de una variable en base a otra. La variable que se va a predecir se denomina **variable dependiente** y la variable que es la base de la predicción se denomina **variable predictora o predictor**.

La segunda forma del estudio de la asociación entre las variables X e Y, es denominada **correlación**, que consiste en determinar la variación conjunta de las dos variables, su grado o nivel de relación, y su sentido (positivo o negativo).

2.12.1.1 Los datos de una regresión lineal simple

Los n datos en parejas $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ son valores de la variable bidimensional (X, Y), donde los x_i son los valores de la variable independiente X y los y_i son los valores de la variable dependiente Y.

$$Y = \beta_0 + \beta_1 X; \quad (2.5)$$

donde:

β_0 = Intercepto

β_1 = Influencia de la variable X

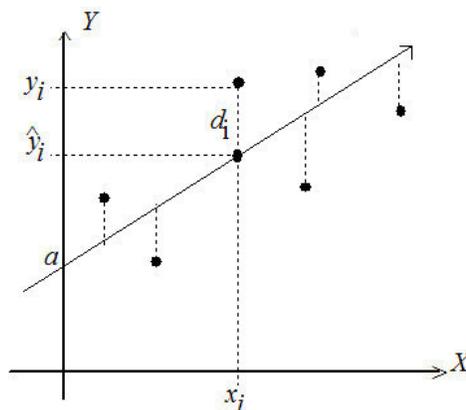


Figura 2-11. Regresión lineal simple en donde se observa desviaciones de valores observados y ajustados.

La covarianza de los datos observados en una muestra es la estadística que mide el nivel de variabilidad (dispersión o concentración) conjunta de los datos de las variables en pareja (X, Y) con respecto a sus medias respectivas (\bar{x} , \bar{y}).

Entonces, la covarianza de n valores $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ de una variable bidimensional (X, Y) es el número real que denotaremos por Cov_{XY} y que se define como la media aritmética de los productos de las desviaciones conjuntas de los datos con respecto a sus correspondientes medias. Esto es:

$$Cov_{XY} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n} \quad (2.6)$$

“La covarianza a diferencia de la varianza, **puede ser negativa**”

2.12.1.2 El índice de correlación

El coeficiente o índice de correlación lineal de Pearson de los n pares de valores $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ de una variable bidimensional (X, Y) es el mínimo abstracto o relativo r que se calcula por:

$$r = \frac{Cov_{XY}}{S_X S_Y} \quad (2.7)$$

Donde, S_X es la desviación estándar de X
 S_Y es la desviación estándar de Y

Teniendo la covarianza definida podemos determinar r.

$$r = \frac{Cov_{XY}}{S_X S_Y} = \frac{\frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n}}{\frac{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}}{n} \frac{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}{n}} = \frac{\sum xy - n\bar{x}\bar{y}}{\sqrt{\sum x^2 - n\bar{x}^2} \sqrt{\sum y^2 - n\bar{y}^2}} \quad (2.8)$$

El coeficiente de correlación de correlación está comprendido entre -1 y 1

Interpretación del índice de correlación

Si $r=1$, se dice que hay una correlación lineal perfecta positiva.

Si $r=-1$, se dice que hay una correlación lineal perfecta negativa.

Si $r=0$, se dice que no hay correlación entre las dos variables.

Dentro de R cogemos la base de datos "cars" que viene por defecto y analizamos primeramente la correlación que existe. Si la correlación es muy buena, entonces podemos realizar una regresión.

2.12.2 Regresión Múltiple

El modelo de regresión múltiple, típicamente estimado por Mínimos Cuadrados Ordinarios (OLS por sus siglas en inglés) es aplicado en la econometría. El modelo es de la forma.

$$y_i = x_i^T \beta + \varepsilon_i, \quad i = 1, 2, \dots, n \quad (2.9)$$

O en forma matricial:

$$y = X\beta + \varepsilon, \quad (2.10)$$

Donde y es un vector de $n \times 1$ y contiene la variable dependiente, x_i contiene la variable independiente. $X = (x_1, \dots, x_n)^T$ y β es un vector de $k \times 1$ dimensión que contiene los coeficientes de regresión. Finalmente ε es un vector de $n \times 1$ dimensión que contiene los errores.

La solución a la ecuación (2.10) está en la utilización de matrices y determinantes, donde, $\hat{\beta} = (X^T X)^{-1} X^T y$, siendo esta solución muy familiar de los **Mínimos Cuadrados Ordinarios** o también llamado **OLS** por sus siglas en inglés, que no es más que la solución a una regresión múltiple, en donde el objetivo es encontrar los coeficientes β .

La correspondencia de los valores estimados una vez calculada los coeficientes, son $\hat{y} = X\hat{\beta}$, los residuales son $\hat{\varepsilon} = y - \hat{y}$, y la suma de los cuadrados de los residuales (RSS) es $\hat{\varepsilon}^T \hat{\varepsilon}$ (Zeileis, 2011).

2.12.3 Funciones periódicas

Diremos que Y_t es una serie periódica de periodo T ; ($T > 0$) si los valores de dicha serie se repiten transcurrido T , es decir si se cumple:

$$Y(t + T) = Y(t) \quad (2.11)$$

Las funciones típicas que satisfacen dicha propiedad son las trigonométricas (seno, coseno,..), estas, son las formas más simples a partir de las cuales podemos construir cualquier función periódica, o dicho de manera alternativa, cualquier función periódica no es más que una combinación de funciones seno y coseno (Carcedo, 2000).

La forma funcional más simple de una función periódica tiene por expresión una derivación de una función trigonométrica coseno:

$$Y_t = A \cos\left(\frac{2\pi t}{T} + \theta\right) \quad (2.12)$$

Donde T es el periodo o intervalo de tiempo que transcurre entre repetición de los valores, A es la amplitud y θ es la fase (desfase) o desplazamiento en el origen respecto al valor 1, en el caso de una función coseno (definido en radianes).

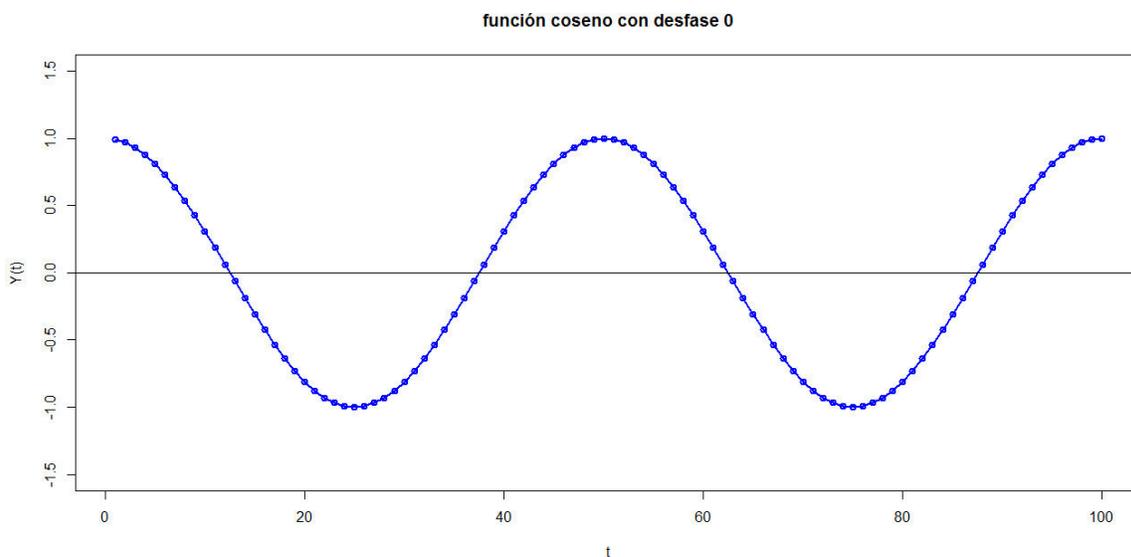


Figura 2-12. Representación de $Y = 1 \cos\left(\frac{2\pi t}{50} + 0\right)$

$$T = 50, A = 1$$

Un muchas ocasiones va a ser necesario, dada una serie temporal, aproximarla mediante la agregación de componentes periódicos (seno-coseno) de distintas frecuencias, cada uno de los cuales tendrá amplitudes y fases diferentes y por lo tanto distinta contribución en la descomposición de la serie. Determinar las contribuciones de las distintas frecuencias en la descomposición de una serie es el objetivo de este subcapítulo, cuya base se halla en la transformación de Fourier de una serie temporal.

Teniendo en cuenta las identidades trigonométricas:

$$\cos(p + t) = \cos p \cos t - \sin p \sin t;$$

Podemos expresar:

$$Y_t = A \cos(\omega t + \theta) = A \cos \omega t \cos \theta - A \sin \omega t \sin \theta;$$

O bien:

$$Y_t = a \cos(\omega t) + b \sin(\omega t) \quad (2.13)$$

Expresión en la que se han sustituido la amplitud y fase por unas constantes a y b, a través de:
 $a = A \cos(\theta)$ y $b = -A \sin(\theta)$

dado la amplitud A es una cantidad no negativa y teniendo en cuenta: $\sin^2 a^2 + \cos^2 b^2 = 1$, tenemos lo siguiente:

$$a^2 + b^2 = A^2 (\cos \theta)^2 + A^2 (\sin \theta)^2 = A^2 ((\cos \theta)^2 + (\sin \theta)^2) = A^2;$$

Y por lo tanto, podemos determinar la amplitud de la función periódica a través de:

$$A = \sqrt{(a^2 + b^2)} \quad (2.14)$$

La fase se determinará según la expresión:

$$\theta = \begin{cases} \tan^{-1}(-b/a), a > 0 \\ \tan^{-1}(-b/a) - \pi, \text{ si } a < 0 \text{ y } b > 0 \\ \tan^{-1}(-b/a) \text{ si } a < 0 \text{ y } b \leq 0 \\ -\pi/2, \text{ si } a = 0 \text{ y } b > 0 \\ \pi/2, \text{ si } a = 0 \text{ y } b < 0 \\ \text{arbitrario, si } a = 0 \text{ y } b = 0 \end{cases}$$

En resumen tenemos las siguientes expresiones equivalentes:

$$Y_t = A \cos\left(\frac{2\pi t}{T} + \theta\right)$$

$$Y_t = A \cos(\omega t + \theta)$$

$$Y_t = a \cos(\omega t) + b \sin(\omega t)$$

2.12.4 Series de Fourier

Como se ha mencionado en el ítem 2.13, una combinación de funciones trigonométricas simples de seno y coseno, da lugar a otra función periódica. Si consideramos una combinación infinita de funciones seno-coseno tendríamos lo que se conoce como una **Serie de Fourier o transformada de Fourier**.

$$Y_t = \frac{1}{2}a_0 + \sum_{n=1}^{\infty}(a_n \cos \omega_0 nt + b_n \sin \omega_0 nt) \quad (2.15)$$

Los coeficientes a y b se denominan **coeficientes de Fourier**, se demuestran y se determinan de la siguiente forma.

Proposición 2.11.4 Sean m y n enteros positivos, entonces.

$$\int_0^{2\pi} \sin mx \cos nx \, dx = \int_0^{2\pi} \cos mx \cos mx \, dx = \begin{cases} 0, & \text{si } m \neq n; \\ 2\pi, & \text{si } m = n; \end{cases}$$

$$\int_0^{2\pi} \sin mx \cos nx \, dx = 0;$$

Demostraremos que:

$$\int_0^{2\pi} \sin mx \sin nx \, dx = \begin{cases} 0, & \text{si } m \neq n; \\ \pi, & \text{si } m = n; \end{cases}$$

Supongamos $m \neq n$, ayudándonos de las funciones trigonométricas.

$$\sin mx \sin nx = \frac{1}{2}(\cos((m-n)x) - \cos((m+n)x));$$

Por lo tanto

$$\begin{aligned} \int_0^{2\pi} \sin mx \sin nx \, dx &= \frac{1}{2} \int_0^{2\pi} \cos((m-n)x) \, dx - \frac{1}{2} \int_0^{2\pi} \cos((m+n)x) \, dx \\ &= \frac{1}{2} \left[\frac{\sin((m-n)x)}{m-n} \right]_0^{2\pi} - \frac{1}{2} \left[\frac{\sin((m+n)x)}{m+n} \right]_0^{2\pi} = 0 - 0 = 0 \end{aligned}$$

Supongamos ahora que $m = n$, ayudándonos nuevamente de la igualdad trigonométrica

$$\sin^2(mx) = \frac{1 - \cos(2mx)}{2} \quad (2.16)$$

Por lo tanto,

$$\begin{aligned} \int_0^{2\pi} \sin^2(2mx) dx &= \frac{1}{2} \int_0^{2\pi} (1 - \cos(2mx)) dx \\ &= \frac{1}{2} \left[x - \frac{\sin 2mx}{2m} \right]_0^{2\pi} = \pi \end{aligned}$$

De la ecuación 2.15 y mediante la proposición 2.11.4

Sea P un polinomio trigonométrico de la forma, entonces.

$$\alpha_0 = \frac{1}{\pi} \int_0^{2\pi} P(t) dt;$$

$$a_0 = \frac{1}{\pi} \int_0^{2\pi} P(t) \cos(\omega_0 n t) dt, \quad \text{para } \omega_0 n = 1, \dots, n$$

$$b_k = \frac{1}{\pi} \int_0^{2\pi} P(t) \sin(\omega_0 n t) dt, \quad \text{para } \omega_0 n = 1, \dots, n$$

A estos coeficientes se les denomina coeficientes de Fourier. También se puede expresar de la forma siguiente.

$$Y_t = \frac{1}{2} a_0 + a_1 \cos \omega_0 t + a_2 \cos(2 \omega_0 t) + b_1 \sin \omega_0 t + b_2 \sin(2 \omega_0 t) + \dots \quad (2.17)$$

donde $\omega_0 = 2\pi/T$

Esta ecuación es la base de la detección de periodicidades “ocultas” en los datos. Así, bastaría realizar la transformada de Fourier sobre la serie y observar qué coeficientes son distintos de cero, éstos serán los correspondientes a la frecuencia que posee la serie analizada. Este método nos permite la estimación del **periodograma**.

2.12.5 Periodograma

La periodicidad en una serie de tiempo no tiene por qué ser manifiesta, es decir, lo habitual es que de la observación de un gráfico no se desprenda la existencia de ciclos, dado que la combinación de ciclos de diferentes amplitudes, frecuencias y fases, pueden dar lugar a series con una evolución temporal compleja.

Para ayudarnos a visualizar la existencia de periodicidades podemos utilizar el “periodograma”. De forma intuitiva, el periodograma es similar a un sintonizador de un receptor de radio, así, la serie económica que observamos sería la señal emitida por una radio (en realidad un radio que emite diferentes frecuencias) y el periodograma no sería más que el dial que busca en qué frecuencia se oye la señal emitida (Carcedo, 2000).

El periodograma está íntimamente ligado a la estimación de la amplitud de una serie periódica de periodo conocido.

Schuster (1998) propone un procedimiento de búsqueda de “periodicidades ocultas” consistente en calcular los parámetros a y b para las distintas frecuencias de Fourier. Para determinar si un componente cíclico está presente en la serie, propone calcular su amplitud a través de $A = \sqrt{(a^2 + b^2)}$ y comprobar si es o no nulo. Si realmente la serie presenta un componente de un periodo determinado, la amplitud correspondiente a esa frecuencia será distinta de cero.

No obstante, es preferible la utilización de la siguiente expresión que normaliza las amplitudes (realmente magnifica la diferencia entre amplitudes pequeñas y grandes):

$$I(\omega_p) \frac{(a_p^2 + b_p^2)}{2\omega_0} \dots \dots \quad (2.18)$$

A esta expresión se la denomina **periodograma**, o espectro de amplitud, y habitualmente se la representa gráficamente respecto a la frecuencia (ω). Cuando la serie temporal presenta un componente periódico de frecuencia (ω_i), el periodograma presenta un “pico” equivalente a la amplitud “normalizada” de dicho componente.

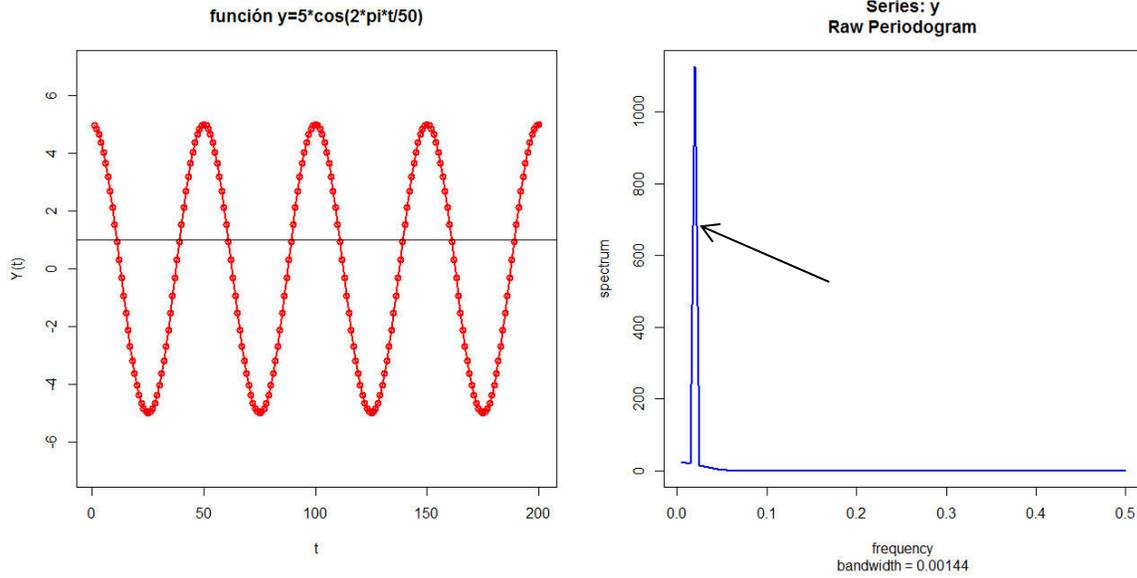


Figura 2-13. Serie generada como $Y = 5 \cos\left(\frac{2\pi t}{50} + 0\right)$ y su periodograma.

2.12.6 Residuales de una serie de tiempo

Un residual en el pronóstico es la diferencia entre un valor observado y su pronóstico sobre la base de otras observaciones $e_i = y_i - \hat{y}_i$. Para la predicción de series de tiempo, un residual se basa en las previsiones de un solo paso; \hat{y}_t es el pronóstico de y_t basado en observaciones y_1, \dots, y_{t-1} .

2.13 Nociones de teledetección

2.13.1 Historia de la Teledetección

La teledetección, tal y como se entiende en la actualidad, comenzó en el periodo de 1946 a 1950, cuando se lanzaron desde Nuevo México (EE. UU) los primeros cohetes rusos V-2 con pequeñas cámaras fotográficas instaladas en ellos como sensores remotos (Figura 2-14). A partir de ese instante se sucedieron diferentes proyectos y misiones a bordo de otros cohetes, misiles balísticos y satélites, que realizaron la toma de fotografías de la Tierra. Aunque la calidad de las primeras fotografías desde el espacio no era muy buena, permitió revelar el verdadero potencial que le esperaba a esta técnica.

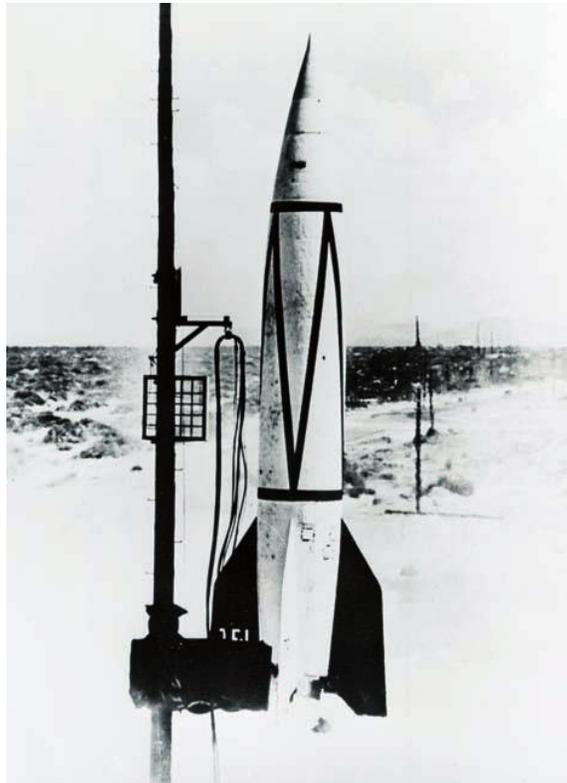


Figura 2-14. Cohete V-2.

La observación sistemática de la Tierra comenzó en el año 1960 con el lanzamiento del TIROS-I (Television Infrared Observation Satellite - I) (Figura 2-15), primer satélite meteorológico con una cámara de televisión de baja resolución espacial, que permitía a los meteorólogos discriminar entre nubes, agua, hielo y nieve. La serie de satélites TIROS, conocidos desde 1970 como NOAA (National Oceanic and Atmospheric Administration), continúa vigente en nuestros días, siendo el satélite NOAA-19 el último en haber sido puesto en órbita.

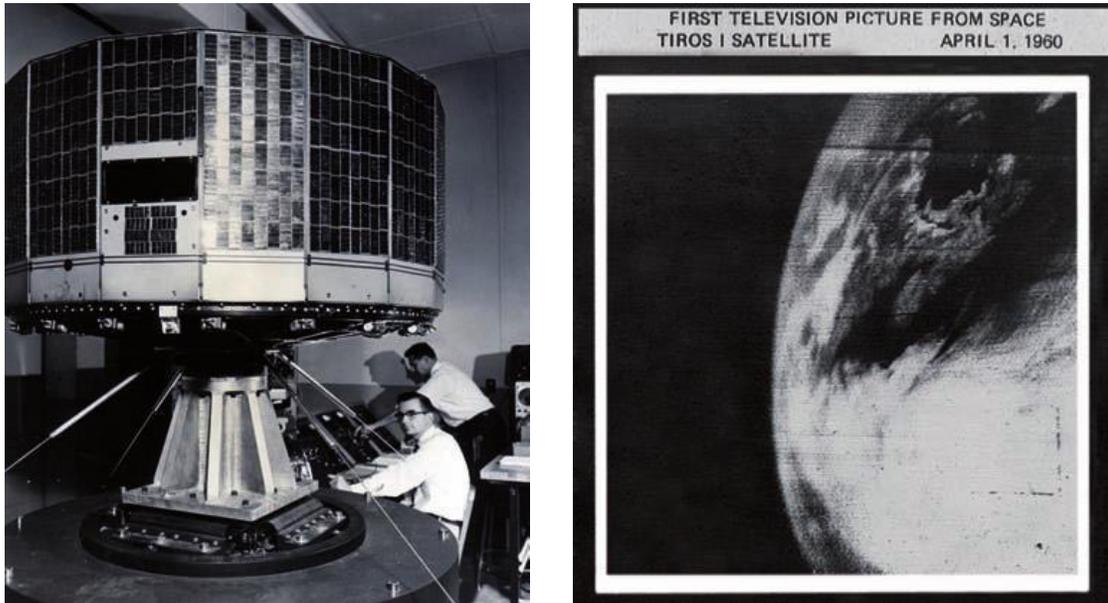


Figura 2-15. TIROS-I (izquierda). Primera imagen de televisión desde el espacio (derecha).

2.13.2 Elementos de la Teledetección

Los elementos involucrados en proceso de la teledetección desde satélites, se muestra en la Figura 5. **El primer requerimiento supone disponer de una fuente de energía que ilumine o provea energía al objeto de interés** (cultivo, bosque, mar, ciudad, etc.). El caso más habitual consiste en que esa fuente sea el Sol (A). La radiación solar, en su "viaje" hacia la Tierra, atraviesa e interacciona con la atmosfera (B). Una vez alcanza la superficie terrestre interactúa con los objetos que en ella se encuentran. La radiación reflejada dependerá de las características de esos objetos, permitiendo distinguir a unos de otros (C). Un sensor a bordo de un satélite recoge y graba esa radiación reflejada por la superficie terrestre y la propia atmosfera (D).

La energía captada por el sensor se transmite a una estación de recepción y procesamiento donde los datos se convierten en imágenes digitales (E). La imagen procesada se intercepta, visualmente y/o digitalmente, para extraer información acerca de los objetos que fueron iluminados (F). El paso final del proceso de teledetección consiste en aplicar la información extraída de la imagen para conseguir un mejor conocimiento de la zona de estudio, revelando nuevas informaciones o ayudándonos a resolver un problema particular (G).

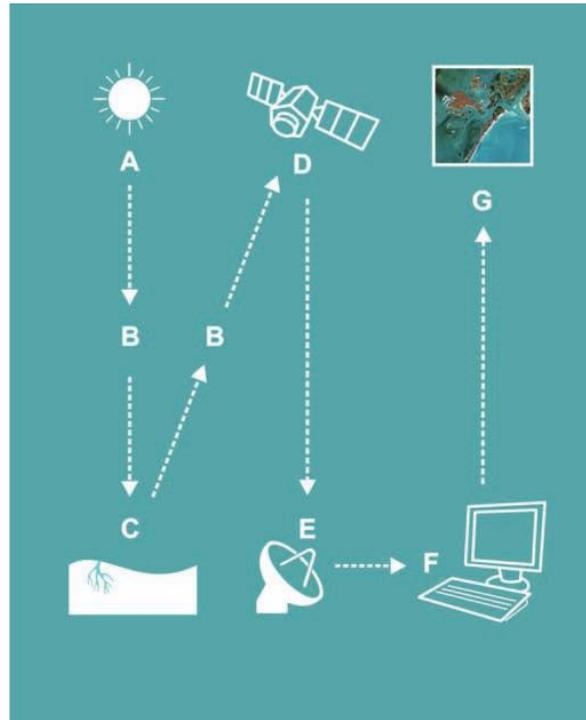


Figura 2-16. Elementos de un proceso de Teledetección desde satélites.

2.13.3 El espectro electromagnético

Los ojos de los seres humanos se pueden considerar como sensores remotos ya que detectan la luz reflejada por los objetos de nuestro entorno. Sin embargo, la visión humana solo es capaz de percibir una pequeña parte del espectro electromagnético, el visible.

La luz visible es solo una de las muchas formas de radiación electromagnética que existen. Así, las ondas de radio, el calor, los rayos ultravioleta o los rayos X son otras formas comunes. En teledetección, lo normal es caracterizar a las ondas electromagnéticas por su longitud de onda en micrómetros (μm , $10^{-6}m$) o nanómetro (μm , $10^{-9}m$), es decir, por la posición que ocupan dentro del espectro electromagnético. De esta forma quedan definidas varias regiones del espectro. Aunque por conveniencia se le asignan diferentes nombres a estas regiones (ultravioleta, visible, infrarrojo, microondas, etc.), no existe divisiones exactas entre unas y otras (Figura 2-17).

Los sensores montados a bordo de los satélites de teledetección son capaces de detectar y grabar radiaciones de las regiones no visibles del espectro electromagnético, desde el ultravioleta hasta las microondas.

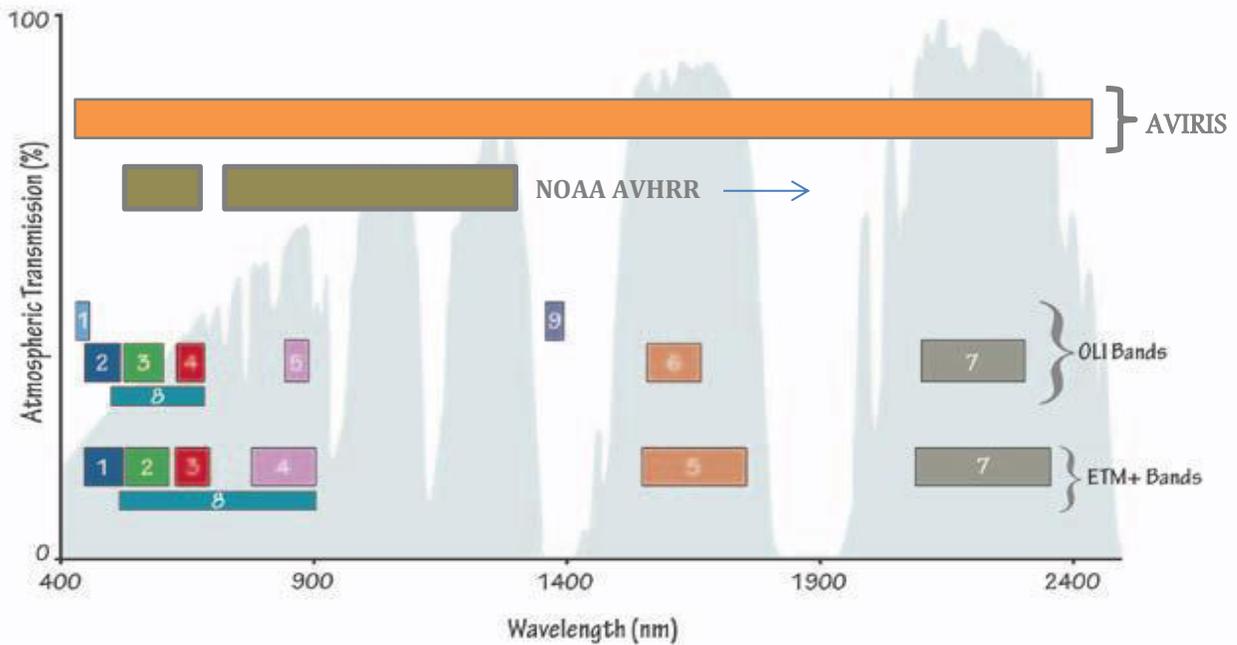


Figura 2-17. Las posiciones de las bandas espectrales para instrumentos comunes de teledetección se indican. Sensores Hiperespectrales (Cientos de bandas) abarcan casi todo el espectro de longitudes de onda. Adaptado de (NASA-USGS).

2.13.4 Reflectancia de la superficie terrestre

La reflectancia espectral es una característica de las superficies terrestres, algo fundamental en teledetección. Se define como la proporción de energía incidente que es reflejada por una superficie. Por lo tanto, es una magnitud adimensional que puede tomar valores entre 0 y 1 o porcentajes entre 0 y 100%. Para una determinada superficie este parámetro varía en función de la longitud de onda. Al gráfico de la reflectancia espectral frente a la longitud de onda se le denomina curva de reflectancia espectral o firma espectral (Figura 2-18). La configuración de estas curvas permite extraer las características espectrales de una superficie y tiene una gran influencia sobre la elección de la región espectral en la cual los datos de teledetección se deben adquirir para una aplicación particular.

Así por ejemplo, las curvas de reflectancia espectral para la vegetación casi siempre manifiestan los picos y valles que se muestran en la (Figura 2-18). Los valles en la región del visible vienen dados por los pigmentos en las hojas de las plantas. La clorofila absorbe energía fuertemente en las bandas centradas entre 0.45 y $0.67\mu m$. Es por ello que nuestros ojos perciben la vegetación sana de color verde, debido a la gran absorción en azul y rojo por las hojas y la reflexión en el verde. Cuando la vegetación no está sana, disminuye la clorofila, y el resultado es un incremento de la

reflectancia espectral en el rojo, por lo que las hojas se ven con un tono amarillento (mezcla de verde y rojo). Al llegar al IR próximo la reflectancia de la vegetación sana aumenta drásticamente. La región $0.7-1.3\mu m$ refleja entre el 40% y el 50% de la energía incidente. El resto de la energía es transmitida casi en su totalidad, ya que en esta región la absorción es menor al 5%. La reflectancia de 0.7 a $1.3\mu m$ es función de la estructura interna de las hojas. Como estas son distintas, nos permite diferenciar distintos tipos de vegetación, aunque en el visible sean muy similares. Más allá de $1.3\mu m$ la reflectancia de las hojas es inversamente proporcional a su contenido de agua total, por lo que esta región del espectro es útil para detectar estrés hídrico en la vegetación.

Los suelos casi no presentan variación en la reflectancia a lo largo de todo el espectro electromagnético (Figura 2-18). Los principales factores que la afectan son: humedad, textura, rugosidad, presencia de óxidos de hierro y materia orgánica. La presencia de humedad hace decrecer la reflectancia, al igual que la rugosidad, la materia orgánica y la presencia de óxidos de hierro, estos últimos principalmente en el visible.

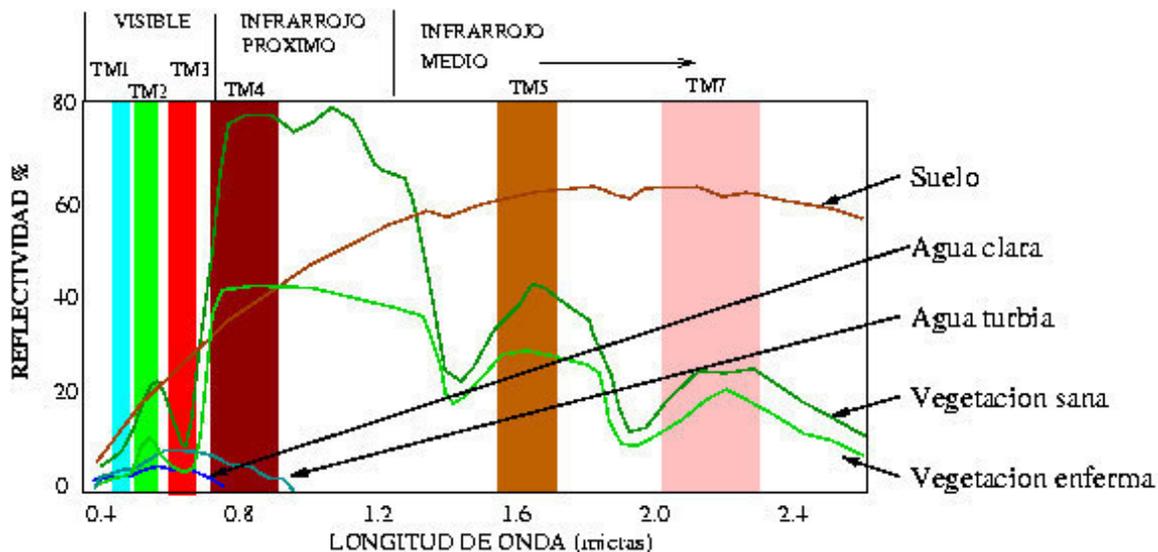


Figura 2-18. Las posiciones de las bandas espectrales para instrumentos comunes de teledetección se indican. Sensores Hyperespectrales (Cientos de bandas) abarcan casi todo el espectro de longitudes de onda.

2.13.5 Efectos atmosféricos sobre la radiación

Antes de que la radiación usada en teledetección alcance la superficie de la Tierra, tiene que viajar a través de la atmósfera terrestre a lo largo de una determinada trayectoria y volver a atravesarla en sentido ascendente para que pueda ser detectada por los sensores espaciales. Este es el caso en el que se usan dispositivos que miden en las longitudes de onda del visible, infrarrojo próximo o medio.

En el caso de que dispongamos de sensores térmicos la radiación normalmente sólo puede realizar un viaje ascendente a través de la atmósfera, siguiendo una trayectoria más corta que en el caso anterior.

El efecto neto que produce la atmósfera en ambas radiaciones varía de acuerdo con las siguientes condiciones:

- Longitud de la trayectoria.
- Magnitud de la señal de energía detectada.
- Condiciones atmosféricas presentes.
- Longitudes de onda involucradas.

Los mecanismos atmosféricos que provocan ese efecto tan profundo en la radiación usada en teledetección con la dispersión (scattering) y la absorción.

2.13.6 Dispersión

Cuando la radiación electromagnética incide sobre una partícula o molécula de gas presente en la atmósfera, ésta puede extraer una porción de energía de esta onda incidente, mientras que el resto permanece inalterada. La porción de energía tomada puede ser reemitida en cualquier dirección. A este fenómeno se le conoce como *dispersión, difusión o scattering*.

Normalmente en estos problemas se define el parámetro de tamaño X como:

$$X = 2\pi r/\lambda \quad (2.19)$$

Donde r es el radio de la partícula.

En función de este parámetro de tamaño aparecen varios tipos de scattering:

- **Scattering Rayleigh:** en este caso el tamaño de las partículas es mucho menor que la longitud de onda incidente. Estas partículas son, generalmente moléculas de oxígeno o nitrógeno que se encuentran en la atmósfera. El efecto de la dispersión de Rayleigh es inversamente proporcional a la cuarta potencia de la longitud de onda:

$$I_R \text{ inv. prop } \frac{I_0}{\lambda^4} \quad (2.20)$$

Donde I_0 , es la radiación incidente e I_R , la debida a Rayleigh.

Luego las longitudes de onda cortas son mucho más dispersadas que las largas. Este tipo de scattering es el dominante en las partes altas de la atmósfera. El hecho de que el cielo aparezca azul durante el día se debe precisamente a este fenómeno. La luz solar interactúa con las moléculas de la atmósfera dispersándose de forma más efectiva las longitudes de onda corta (azul) que el resto de las longitudes de onda del visible. Sin embargo, al atardecer o al amanecer, la luz solar atraviesa un camino atmosférico mucho más largo, y aunque también tiene lugar este tipo de dispersión, se produce una mayor absorción de dichas longitudes de onda corta, por lo que finalmente los que prevalecen a esas horas son los rojos y naranjas. *Este tipo de scattering es uno de las causas más importantes de la falta de contraste en las imágenes* (John et al., 2006).

- **Scattering Mie:** Cuando las partículas son del mismo tamaño o algo más grandes ($X < 50$) que las longitudes de onda incidentes, tiene lugar este tipo de scattering. Aquí la resolución de las ecuaciones de Maxwell para el cálculo de la radiación dispersada se complica enormemente. Como ejemplo de partículas que producen este tipo de dispersión tenemos: partículas de polvo del desierto, polen, humo, etc. Normalmente el fenómeno de dispersión Mie se produce en las capas bajas de la atmósfera ya que, dada la naturaleza de las partículas que lo producen, éstas difícilmente se encuentran por encima de los seis kilómetros en cantidades apreciables.

2.13.7 Características orbitales de los satélites de teledetección

Se denomina órbita a la trayectoria seguida por un satélite alrededor de la Tierra. Esta depende de las características y objetivos de los sensores que van a bordo del satélite. En general, las órbitas quedan definidas por la altitud, orientación y rotación con respecto a la Tierra.

Las órbitas geoestacionarias son aquellas que describen los satélites que están situados a grandes alturas y siempre ven la misma porción de superficie terrestre. Su altura suele ser de 36.000 km y se mueven a una velocidad angular igual a la de la rotación de la Tierra, por lo que siempre permanecen en la misma posición relativa respecto a la superficie terrestre. Satélites meteorológicos como el METEOSAT tienen este tipo de órbitas.

Sin embargo, la mayor parte de los satélites de teledetección se diseñan para seguir una órbita de norte a sur, la cual, en conjunción con la rotación de la Tierra (de oeste a este), les permite cubrir la mayor parte de la superficie terrestre durante un cierto periodo de tiempo. A estas órbitas se les ha dado el nombre de cuasi polares, por la inclinación relativa con respecto a una línea trazada entre los polos norte y sur. Además, muchos de los satélites de órbita cuasi polar también son heliosíncronos, ya que cubren la misma área del mundo a una hora local fija de día, llamada hora

solar local. Esto significa que, a una latitud dada, la posición del Sol en el cielo, al igual que la posición del satélite que pasa por encima, será aproximadamente la misma dentro de la misma estación del año. Este hecho asegura condiciones de iluminación similares cuando se adquieren imágenes en una estación específica durante diferentes años, o en un área particular sobre una serie de días. Esta cuestión resulta fundamental para monitorizar cambios entre imágenes o para hacer mosaicos juntando imágenes adyacentes, al no tener que ser corregidas por diferentes condiciones de iluminación.

En el movimiento alrededor de la Tierra, el satélite sólo registra información de una porción de la misma. El ancho de la franja en la superficie terrestre que es capaz de registrar se denomina ancho de barrido. Este puede variar desde decenas a cientos de kilómetros, dependiendo del tipo de sensor y de la altura del satélite. Esta característica determinará en muchos satélites la capacidad para captar, en una sola pasada, un área determinada. Si el ancho del área a registrar es superior al ancho de barrido, la imagen no podrá ser captada en una sola toma y habrá que esperar a un segundo pase. Varios satélites modernos tienen la capacidad de reorientar en cualquier dirección (off-nadir) el sensor durante la adquisición de imágenes y tomar franjas adyacentes en una única pasada. Este hecho se traduce en un aumento del ancho de barrido práctico del satélite, lo cual supone un incremento importante en la capacidad de adquisición de imágenes de los satélites que poseen esta tecnología.

También hay que tener en cuenta que los satélites con órbita cuasi polar pueden tomar muchas más imágenes de altas latitudes que de las zonas ecuatoriales debido al incremento del solape en anchos de barridos adyacentes, ya que las trayectorias de la órbita pasan todas muy juntas cerca de los polos.

2.13.8 Resolución de los sensores de satélite

Los sensores instalados en los satélites de teledetección poseen una serie de particularidades que determinan las características de las imágenes que van a proporcionar. Estas características vienen definidas básicamente por diferentes tipos de resolución:

- Resolución espacial

Este concepto designa al objeto más pequeño que puede ser distinguido sobre una imagen. En un sistema fotográfico, suele medirse como la misma separación a la cual los objetos aparecen distintos y separados en la fotografía (Chuvienco, 1990). Se mide en unidades de longitud (mm sobre la foto, o m sobre el terreno), y depende de la longitud focal de la cámara y de su altura sobre la superficie.

Por su parte, en los sensores ópticos-electrónicos, se prefiere utilizar el concepto de campo de visión instantáneo (*instantaneous field of view, IFOV*). El IFOV se define como la sección angular, medida en radianes, observada en un momento determinado. No obstante, se suele utilizar normalmente la distancia sobre el terreno que corresponde a ese ángulo, teniendo en cuenta la altura de vuelo y la velocidad de exploración del sensor. En otras palabras, esa distancia se corresponde al tamaño de la mínima unidad de información incluida en la imagen, que se denomina pixel. Esta es la medida

más generalizada de resolución espacial, aunque también se emplean otros términos más complejos, como ERE (effective resolution element) o EIFOV (effective instantaneous field of view), que consideran la señal detectada como una función modulada compuesta (Townshend, 1981).

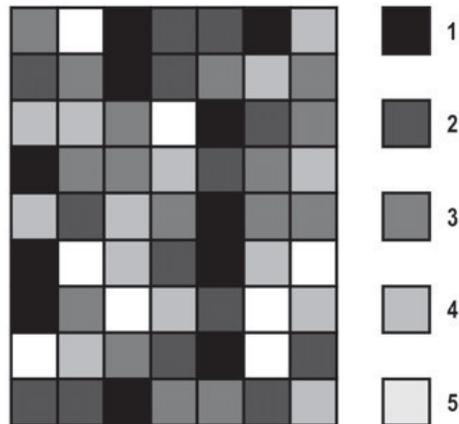


Figura 2-19. Formato de una imagen digital (7x9 píxeles). Cada píxel representa un área de la superficie terrestre. Los tonos de gris hacen referencia a los distintos niveles de energía detectada

- Resolución espectral

Indica el número y anchura de las bandas espectrales que puede discriminar el sensor. En este sentido, un sensor será tanto más idóneo cuanto mayor número de bandas proporcione, ya que facilita la caracterización espectral de las distintas cubiertas. A la vez, conviene que esas bandas sean suficientemente estrechas, con objeto de recoger la señal sobre regiones coherentes del espectro. Bandas muy amplias suponen registrar un valor promedio, que puede encubrir la diferenciación espectral entre cubiertas de interés.

- Resolución radiométrica

Hace mención a la sensibilidad del sensor, esto es, a su capacidad para detectar variaciones en la radiancia espectral que recibe. En el caso de los sistemas fotográficos, la resolución radiométrica del sensor se indica por el número de niveles de gris recogido en el **film**. Para los óptico-electrónicos, la misma habitualmente se presenta en formato digital, gracias a una conversión analógico-digital realizada a bordo del satélite. El número de valores que incluye ese rango-, suele identificarse con la resolución radiométrica del sensor. Este rango de codificación varía con los distintos sensores. Landsat 5 ofrecía un rango de 256 niveles (8 bits) de codificación por píxel, actualmente los sensores han mejorado mucho la resolución radiométrica por encima de los 256.

- Resolución temporal

Este concepto alude a la frecuencia de cobertura que proporciona el sensor. En otras palabras, refiere a la periodicidad con la que este adquiere imágenes de la misma porción de la superficie

terrestre. El ciclo de cobertura está en función de las características orbitales de la plataforma (altura, velocidad, inclinación), así como del diseño del sensor, principalmente del ángulo de observación y de abertura.

2.13.9 Tipos de imágenes de teledetección

El tipo de producto más común que suministran los satélites de teledetección es una imagen digital de tipo raster, donde cada pixel tiene asignado uno o varios valores numéricos (niveles digitales) que hacen referencia a la energía media recibida dentro de una determinada banda espectral. Teniendo esto en cuenta, se pueden adquirir los siguientes tipos de imágenes:

Imagen Multiespectral (MS). Imagen que lleva asociados varios valores numéricos a cada pixel, tanto como bandas espectrales sea capaz de detectar el sensor. A priori, es el tipo de producto más útil ya que nos proporciona, en cierto modo, la firma espectral de los distintos elementos presentes en la imagen.

Imágenes Hiperespectrales. A parte de las multiespectrales también existen las denominadas imágenes hiperespectrales, menos habituales. Vienen caracterizadas por poseer información en un gran número de bandas (cientos). Se requieren para estudios de identificación y clasificación muy precisos, principalmente en mineralogía.

Imagen pancromática (PAN). Dispone de una sola banda espectral que abarca comúnmente gran parte del visible y comienzo del infrarrojo, obteniendo como resultado una imagen que habitualmente se representa en una escala de grises (imagen en blanco y negro). Como contrapartida tienen la ventaja de poseer mayor resolución espacial que las multiespectrales que proporciona el mismo satélite. Es por ello que son muy interesantes para la detección de pequeños elementos de la superficie terrestre que no son distinguibles en la imagen multiespectral.

Imagen fusionada (PS). Este tipo de imagen se obtiene mediante la fusión de una imagen multiespectral con una pancromática. Las siglas PS provienen de *pan-sharpened*, su denominación en inglés. Básicamente, consiste en asignar a cada pixel de la imagen pancromática los valores procedentes de un algoritmo que combina la imagen pancromática con la multiespectral. El resultado final es una imagen multiespectral con la resolución espacial de la pancromática.

Imagen estéreo. En realidad se refiere a dos imágenes de una misma zona tomadas con ángulo de visión distinto. Muchos satélites tienen la capacidad de reorientar el sensor, lo que les permite tomar, en una o en sucesivas pasadas, este tipo de imágenes se suelen emplear para generar modelos de elevación del terreno.

2.14 Sensor MODIS

Desde finales de la década de los 1980, se llevaron a cabo proyectos creados para el monitoreo de coberturas globales, como el internacional Geosphere Biosphere Programme (IGBP), que permitió el mapeo de la cobertura terrestre usando los datos del sensor Advanced Very High Resolution Radiometer (AVHRR). Este sensor, a bordo de los satélites de la serie NOAA (National Oceanic and Atmospheric Administration), fue originalmente creado para el monitoreo climatológico con una resolución de 1.1km.

Sin embargo los datos AVHRR no son los más idóneos para estudios de las coberturas terrestres, porque tienen una baja resolución espacial, el ángulo de barrido es muy amplio (55.4 grados a ambos lados) lo cual implica notables problemas geométricos y radiométricos en las imágenes resultantes, además de los problemas de contaminación atmosférica de los pixeles extremos (Mas, 2011).

No obstante, los datos AVHRR tuvieron resultados suficientemente alentadores para motivar la creación de sensores diseñados específicamente para el monitoreo de las coberturas terrestres, la alta resolución temporal permite abarcar en una sola toma extensas regiones. Dentro de estos proyectos de percepción remota, el más ambicioso es el Earth Observing System (EOS) de la NASA, cuyo principal objetivo es la observación continua de los cambios globales, lo cual incluye el estudio integrado de la atmósfera, de los océanos y de la superficie terrestre (Mas, 2011).

Dentro del proyecto EOS sobresale el sensor llamado Espectroradiométrico para imágenes de Resolución Moderada (MODIS) a bordo de dos plataformas, que por sus características espaciales y espectrales es uno de los más importantes para el monitoreo de los procesos de cambio en la tierra. MODIS fue diseñado por un equipo interdisciplinario de científicos con una vasta experiencia en sensores remotos. Este equipo trabajó por cerca de 10 años para finalmente definir los requisitos para la toma, calibración y procesamiento de los datos (Xiong, 2008).

2.14.1 Especificaciones técnicas del sensor MODIS

El sensor MODIS se encuentra a bordo de los satélites Terra o EOS-AM (lanzado en diciembre de 1999) y Aqua o EOS-PM (lanzado en mayor de 2002). La órbita de ambas plataformas es helio-sincrónica con una inclinación de 98.2° y 98° y una altitud media de 708 y 705 km respectivamente. Terra está programada para pasar de norte a sur cruzando el ecuador a las 10:30 am en su órbita descendente, mientras que Aqua pasa de sur a norte sobre el ecuador a la 1:30 pm.

El instrumento MODIS cuenta con una alta sensibilidad radiométrica (12 bits) en 36 bandas espectrales, en un rango de longitud de onda que va de los $0.4 \mu\text{m}$ (Tabla 2-2). Las primeras 19 bandas están posicionadas en la región del espectro electromagnético situado entre $0.405 \mu\text{m}$ y $2.155 \mu\text{m}$. Las bandas de la 1 a la 7 son útiles para las aplicaciones terrestres (Figura 2-20); las bandas 8 a la 16 para las observaciones oceánicas y las bandas 17 a la 19 para las mediciones atmosféricas. Las bandas 20 a la 36, cubren la porción del infrarrojo térmico del espectro de ($3.660 - 14.385 \mu\text{m}$).

Tabla 2-2. Bandas del sensor MODIS

Uso principal	Banda	Ancho de banda (nm)
Límites de Tierra/Nubes/Aerosoles	1	620-670
	2	841-876
Propiedades de Tierra/Nubes/Aerosoles	3	459-479
	4	545-565
	5	1230-1250
	6	1628-1652
	7	2105-2155
	8	405-420
Color del océano/fitoplancton/bioquímica	9	438-448
	10	483-493
	11	526-536
	12	546-556
	13	662-672
	14	673-683
	15	743-753
	16	862-877
Atmosférica Vapor de agua	17	890-920
	18	931-941
	19	915-965
Temperatura de la Superficie/nubes	20	3.660-3840
Temperatura Atmosférica	21	3.929-3.89
	22	3.929-3.989
	23	4.020-4.080
	24	4.433-4.498
Nubes Cirrus Vapor de agua	25	4.482-4.549
	26	1.360-1.390
Propiedades de las nubes	27	6.535-6.895
	28	7.175-7.475
	29	8.400-8.700
Ozono	30	9.580-9.880
Temperatura de la superficie/nubes	31	10.780-11.280
	32	11.770-12.270
Altitud de las nubes	33	13.185-13.485
	34	13.485-13.785
	35	13.785-14.085
	36	14.085-14.385

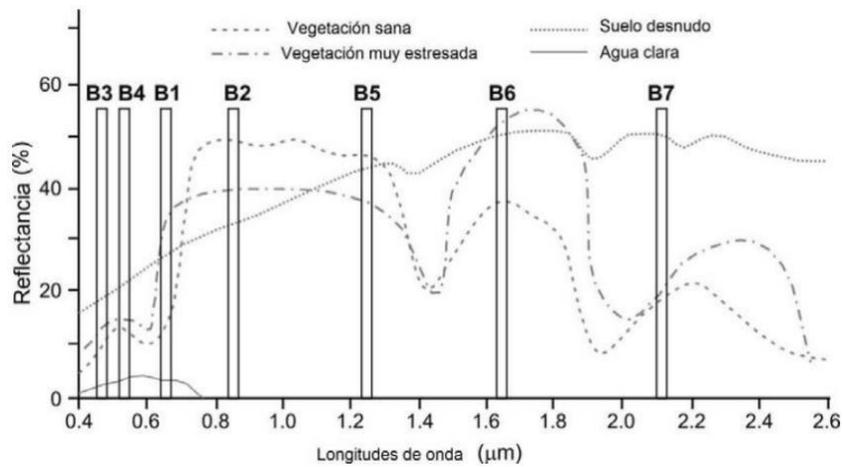


Figura 2-20. Longitud de onda de las primeras 7 bandas del sensor MODIS (Mora, 2010)

2.14.2 Deformaciones relacionadas con el barrido (ángulo de vista)

Debido al procedimiento de barrido mediante el cual el sensor MODIS captura los datos de la superficie terrestre, se produce una deformación de la imagen resultante (Figura 2-21). Mientras que los píxeles que se encuentran en la vertical del sensor (al nadir en un ángulo cenital) presenta deformaciones mínimas, el campo instantáneo de vista del sensor aumenta en los extremos de la imagen llegando a tener una deformación de 5 veces el tamaño del píxel en el eje Y y dos en el eje X. Estas deformaciones se conocen con el efecto Bowtie, que consiste en la presencia de líneas repetidas cerca de los bordes de las imágenes MODIS. No obstante, existen programas para corregir este defecto, pero los píxeles localizados en los bordes de la imagen deben ser empleados con cautela.



Figura 2-21. Deformaciones relacionadas con el ángulo de barrido (Mora, 2010).

El resumen de las características técnicas del sensor MODIS se muestra a continuación

Tabla 2-3. Especificaciones técnicas del sensor MODIS

Orbita	Altitud: 708 km (Terra) y 705 km (Aqua), pasando en el ecuador a 10: 30 am, nodo descendente (Terra) y a la 1:30 pm, nodo ascendente (Aqua), heliosíncrona, casi polar, circular.
Tasa de escaneo	20.3 rpm, ortogonal a la órbita
Dimensiones de la franja escaneada	2.330 km (ortogonal) por 10 km (a lo largo de la órbita, al nadir)
Telescopio	17.78 cm de diámetro con planos de desvió.
Tamaño	1.0 x 1.6 x 1.0 m
Peso	228.7 kg
Poder	162. 5 W (promedio orbital)
Tasa de transferencia de datos	10.6 Mbps (pico); 6.1 Mbps (promedio orbital)
Resolución radiométrica	12 bits
Resolución espacial	250m (bandas 1-2) 500m (bandas 3-7) 1000m (bandas 8-36)
Diseño de vida útil	6 años

El producto MOD13Q1 tiene una resolución espacial de 250m. De acuerdo a esta resolución, se estable que la escala de trabajo será de 1:500, 000. Ya que la resolución espacial está relacionado con la escala de trabajo.

2.14.3 Niveles de procesamiento

Los productos MODIS son divididos en cinco niveles (0-4) en función del grado de procesamiento realizado.

- **Nivel 0.** Son los datos brutos sin ningún tratamiento, solo los artefactos de comunicación han sido eliminados, como por ejemplo los paquetes de sincronización y los encabezados de comunicación entre el satélite y la estación de recepción (Mas, 2011).
- **Nivel L1.** Son los datos de geolocalización (identificados como MOD03) que contienen coordenadas geodésicas, información sobre la elevación del terreno, máscara de tierra/agua, ángulo de elevación, cenit, azimut del satélite y del sol (Mas, 2011).
- **Nivel 1A.** Son los productos utilizados para la geolocalización, la calibración y el procesamiento. Contienen los niveles de radiancia (MOD01) de las 36 bandas, junto con datos auxiliares del sensor y del satélite como coeficientes de calibración radiométrica y corrección geométrica, parámetros de georreferenciación (efemérides de la plataforma) (Mas, 2011).
- **Nivel 1B.** son los productos que contienen las radiancias calibradas y con geolocalización (MOD02) para las 36 bandas generadas por el nivel 1A. Es por lo tanto una imagen radiométricamente corregida y calibrada a unidades físicas (Mas, 2011).
- **Nivel L2G.** Son los productos que contienen variables geofísicas proyectadas en una malla conforme. Los datos adquiridos durante un periodo fijo de tiempo (12 o 24 horas) son agrupados en una cuadrícula de 1,200 x1,200 km, llamado *tile en una proyección sinusoidal de igual área* (Mas, 2011).
- **Nivel L2.** Son los productos que contienen variables geofísicas. Estos productos se generan a partir del producto nivel L1B aplicando correcciones atmosféricas y algoritmos bio-ópticos (Mas, 2011).
- **Nivel 3.** Son productos de valor agregado derivados de variables geofísicas mapeadas. En algunos casos, se realiza un remuestreo a una menor resolución espacial que las bandas originales y se elaboran compuestos de intervalos de tiempo establecido (1, 8, 16 y 30 días). Algunos productos de nivel 3 son reflectancia (MOD09), índices de vegetación (MOD13), temperatura y emisividad de la superficie terrestre (MOD11) y puntos de calor e incendios (MOD14) (Mas, 2011).
- **Nivel 4.** Son los productos generados por la incorporación de los datos MODIS en modelos para así estimar variables geofísicas. Estos productos se generan usando productos nivel L2 y datos auxiliares. Algunos ejemplos de estos productos que se presentan en el capítulo siguiente son el índice de área foliar / fracción de radiación activa fotosintética (MOD15), las coberturas del suelo (MOD12) y la producción primaria (MOD17) (Mas, 2011).

2.14.4 Problemas en la calibración del sensor MODIS-AQUA y TERRA

2.14.4.1 Problemas en MODIS-AQUA

Los parámetros de configuración del sensor, los sesgos que detecta y la tabla de conversión son cantidades que dependen del tiempo y que se han cambiado para optimizar el rendimiento del sensor (NASA). Las áreas donde se debe tener cuidado al usar el producto nivel 1B son:

- Detectores no funcionales o ruidoso del sensor AQUA
- Calibración incompleta para la banda 21
- Fugas térmicas (Band 5, 6, 7 y 26)
- La saturación del detector en las banda 33, 35 y 36

2.14.4.2 Problemas en MODIS-TERRA

Los factores de rendimiento que complicaron el logro de un rendimiento óptimo del instrumento MODIS-TERRA se deben principalmente a:

- Detectores no funcionales o ruidosos
- Fuga térmica (bandas 5, 6, 7 y 26)
- Cuenta digital uniforme (ND)
- Aumento anómalo en el ancho de banda de la banda 27
- Degradación en RSB (bandas 1-19, además de la 26)
- Calibración incompleta para la banda 21
- Saturación de alta temperatura de brillo en la temperatura superficial del mar (SST) bandas (11, 12, 31 y 32)

Estas son algunos de los principales problemas en la calibración del sensor TERRA que tiene que tenerse en cuenta en cualquier procesamiento y utilización del sensor.

2.14.5 Variables biofísicas relacionadas con la vegetación

2.14.5.1 Índices de vegetación MOD13Q1

El producto MOD13 (Sensor MODIS) presenta dos índices de vegetación (IV): El índice de vegetación de diferencia normalizada (NDVI), el índice de vegetación mejorado (EVI) y el análisis de calidad (QA) con datos estadísticos que indican la calidad en la reflectancia de entrada del producto IV. Se producen actualmente en intervalos de 16 días a 500m y 1km de resolución, con una producción limitada a 250m de resolución.

Los IVs se emiten en unidades de azulejos que son aproximadamente 1200 por 1200 km en la proyección sinusoidal. El producto IV se basa en los productos diarios de reflectancia de la superficie de nivel 2 (MOD09) que se corrigen para la dispersión molecular, la absorción de la capa de ozono y los aerosoles (Vermote et al., 2002). El algoritmo para generar el producto IV opera sobre múltiples observaciones durante un periodo de 16 días. Debido a la órbita del sensor y observaciones diarias, puede ser recogida un máximo de 64 observaciones durante un ciclo de 16 días; sin embargo debido a la presencia de nubes y cobertura espacial del sensor, este número puede oscilar entre 0 -64 observaciones, siendo menos cerca a las latitudes ecuatoriales.

Una vez que los 16 días de observaciones se recogen, se aplica un filtro a los datos basados en la calidad de la información, la nube y la geometría de visión (Figura 2-22). Solo la calidad más alta, libre de nubes se conserva. MODIS es un sensor que hace que aumente el tamaño del pixel al aumentar el ángulo de visión. Los pixeles que están en la visión nadir poseen distorsiones mínimas. El número de pixeles aceptables durante un periodo de composición de 16 días se reduce aún más y típicamente es menor a 10 y a menudo menos a 5 (Huete et al., 2002).

BRDF: Función compuesta de distribución de la reflectancia bidireccional

CV-MCV: Visión limitada, ángulo de valores compuestos máximos

MCV: Valores compuestos máximos

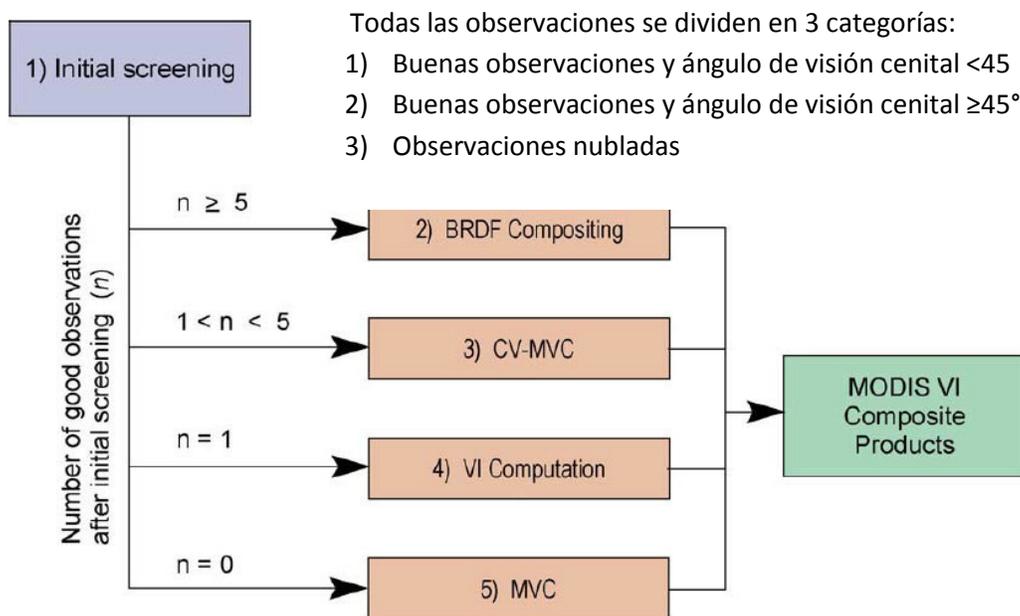


Figura 2-22. Esquema metodológico de la composición MODIS-IV (Huete et al., 2002).

El NDVI se produce mediante el cálculo del cociente normalizado de la banda del infrarrojo cercano y la banda del rojo (Mas, 2011).

$$NDVI = \frac{R_{IRC} - R_R}{R_{IRC} + R_R} \quad (2.21)$$

Donde, R_{IRC} y R_R son respectivamente los valores de reflectancia bidireccional de la superficie para las bandas del infrarrojo cercano y rojo. Este índice da continuidad al NDVI obtenido con base en el sensor AVHRR para extender el registro de datos a mayor plazo en los estudios de monitoreo (Mas, 2011).

El índice mejorado de vegetación (EVI), se optimizó a partir del NDVI aumentando la sensibilidad en la regiones de alta biomasa y mejoró el monitoreo de la vegetación mediante la disociación de la señal del fondo del dosel y una reducción de la influencia atmosférica. La ecuación utilizada para su obtención se indica a continuación.

$$EVI = G \frac{R_{IRC} - R_R}{R_{IRC} + C_1 R_R - C_2 R_A + L} \quad (2.22)$$

Donde:

R_{IRC} , R_R y R_A son respectivamente los valores de reflectancia bidireccional de la superficie para las bandas del infrarrojo cercano, del rojo y del azul con una corrección de los efectos de la atmósfera (Absorción de ozono y Rayleigh²).

L es un ajuste del fondo del dosel que toma en cuenta la transferencia radiante diferencial del infrarrojo cercano y el rojo a través del dosel, G es un factor de ganancia y C_1 y C_2 son los coeficientes de resistencia de aerosoles, que usan la banda azul para corregir la influencia del aerosol en la banda roja. Los coeficientes adoptados en el algoritmo EVI son $L = 1$, $C_1 = 6$, $C_2 = 7.5$ y $G = 2.5$.

² Existen dos mecanismos de dispersión ampliamente identificados. La primera es la dispersión por las propias moléculas de aire. Esto se denomina **dispersión de Rayleigh** y es inversamente proporcional a la cuarta potencia de la longitud de onda. El otro se llama aerosol o **dispersión de Mie** y es un resultado de la dispersión de la radiación de partículas más grandes, tales como los asociados con el humo, neblina y humus (John A. Richards, 2006).

Tabla 2-4. Especificaciones del producto MOD13Q.

Data	MOD13Q1
Plataforma	Terra – Aqua
Resolución temporal	16 días
Resolución espacial	250m
Extensión espacial	Tile
Nivel	L3
Fase de validación	2
Versión	5
Tamaño de archivo	5-270 MB
Número de capas	12

Tabla 2-5. Bandas del producto MOD13Q1 – MODIS.

MOD13Q1	UNITS	BIT TYPE	FILL	Valid Range	Multiply by Scale Factor
250m 16 days NDVI	NDVI	16-bit signed integer	-3000	-2000, 10000	0.0001
250m 16 days EVI	EVI	16-bit signed integer	-3000	-2000, 10000	0.0001
250m 16 days VI Quality detailed QA	Bits	16-bit unsigned integer	65535	0.65534	NA
250m 16 days Red Reflectance (band 1)	Reflectance	16-bit signed integer	-1000	0.1	0.0001
250m 16 days NIR Reflectance (band 2)	Reflectance	16-bit signed integer	-1000	0.1	0.0001
250m 16 days Blue Reflectance (band 1)	Reflectance	16-bit signed integer	-1000	0.1	0.0001
250m 16 days MIR Reflectance (band 1)	Reflectance	16-bit signed integer	-1000	0.1	0.0001
250m 16 days View zenith angle	Degree	16-bit signed integer	-10000	-9000,9000	0.01
250m 16 days sun zenith angle	Degree	16-bit signed integer	-10000	-9000,9000	0.01
250m 16 relative azimuth angle	Degree	16-bit signed integer	-4000	-3600,3600	0.1
250m 16 days composite day of the year	Julian day of year	16-bit signed integer	-1	1.366	NA
250m 16 days pixel reliability summary QA	Rank	8-bit signed integer	-1	0.3	NA

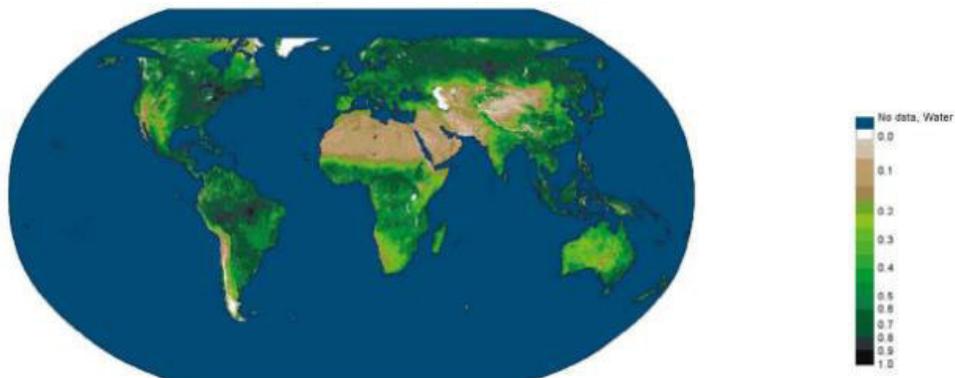
2.14.6 NDVI vs EVI

Se considera que el NDVI es más sensible a la clorofila y el EVI más sensible a las variaciones estructurales del dosel, incluyendo el índice de área foliar (LAI), el tipo y la arquitectura del dosel y la fisonomía de las plantas (Mas, 2011). Diferentes estudios de la vegetación mostraron que ambos índices se complementan entre sí mejorando la detección de cambios así como la extracción de parámetros biofísicos del dosel (Huete et al., 2002).

El Índice Mejorado de Vegetación (EVI), se optimizó a partir del NDVI, aumentando la sensibilidad en las regiones de alta biomasa (Figura 2-23) y mejoró el monitoreo de la vegetación mediante la disociación de la señal del fondo del dosel y una reducción de la influencia atmosférica (Mas, 2011).

De lo anterior, se puede decir que el uso del EVI al ser más sensible a altos contenidos de biomasa puede arrojar resultados un tanto más confiables. Esto no significa descartar el uso del NDVI, al contrario, si se usan ambos índices se puede obtener los mismos resultados confiables, pero en esta investigación se usará el Índice EVI como variable biofísica para la detección de degradación.

Composición del NDVI, 25 de junio -10 de julio del 2000



Composición del EVI, 15 de octubre -30 de octubre del 2000

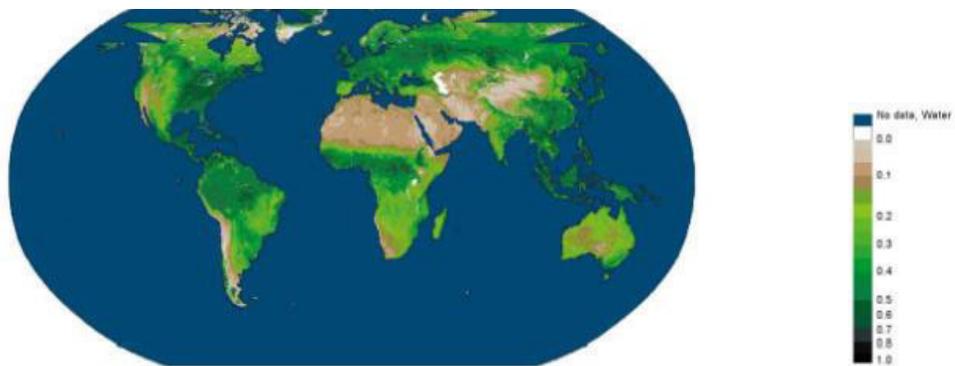


Figura 2-23. Bandas del producto MOD13Q1 – MODIS. Adaptado de (Huete et al., 2002).

2.15 Estimación de tierras degradadas mediante la teledetección

El suelo es un componente central de los recursos tierras y la base del desarrollo agrícola. El suelo es la base para obtener alimentos, combustible, producción de fibras y muchos servicios ecológicos vitales. El área de tierra productiva es limitada y se encuentra bajo una creciente presión por la intensificación y los usos que compiten por los cultivos agrícolas, bosques, pastos/pastizales y para satisfacer las demandas de una creciente población de alimentos y producción de energía, extracción de materias primas, y demás. Por lo tanto, hablar de degradación de la tierra involucra no solo hablar de degradación del suelo por salinización, por erosión, etc., sino también involucra la degradación de los bosques.

2.15.1 Degradación forestal

La degradación forestal es un proceso que lleva a un deterioro temporal o permanente en la densidad o la estructura de la cubierta vegetal o en su composición de especies (Grainger, A., 1993). Se trata de un cambio en los atributos forestales que conduce a una menor capacidad productiva. Es causada por las perturbaciones antrópicas o naturales. La degradación natural y la degradación causada por el hombre suelen ser fenómenos interdependientes. Las actividades humanas pueden hacer que el bosque sea vulnerable a la degradación por causas naturales, mientras que los daños de origen natural pueden conducir al agravamiento de las perturbaciones inducidas por el hombre (FAO, 2011).

La estimación por teledetección de atributos biofísicos que son indicativos de la degradación de los bosques se ha llevado a cabo utilizando un enfoque empírico o un enfoque de base física. En el enfoque empírico muchos autores han caracterizado la superficie utilizando índices de vegetación que son combinaciones aritméticas de bandas espectrales. La mayor parte de estos índices son variantes del índice de vegetación de diferencia normalizado (NDVI), como el cociente entre la diferencia y la suma de las radiancias medidas en el infrarrojo y rojo del espectro electromagnético.

Los estudios empíricos y simulaciones con modelos de *transferencia radiativa* apoyan la interpretación de los índices de vegetación en términos de la fracción de la radiación fotosintética activa, absorbida por el dosel de la vegetación y el estado de la vegetación (es decir, el vigor o el estrés) (Myneni et al., 1995).

La temperatura de la superficie de la Tierra (T_s), derivados de los canales térmicas de sensores de satélite, también se han utilizado como indicador de la superficie biofísica en los estudios empíricos. La T_s está relacionada, a través de la ecuación de balance de energía superficial, con la disponibilidad de humedad y evapotranspiración, en función del flujo de calor latente (Carlson et al.,

1990). Algunos autores han combinado el NDVI con los datos de T_s para describir exhaustivamente los cambios en la cobertura terrestre (Lambin & Ehrlich, 1996). La pendiente de la relación T_s -NDVI se interpreta en términos de resistencia superficial a la evapotranspiración (Nemani & Running, 1989).

Para evaluar la degradación de los bosques es necesario establecer un estado de referencia, una línea de base o *estado ideal* (Figura 2-24), con la cual se ha de comparar una situación que ha sido objeto de cambio. En la práctica, no resulta sencillo establecer un estado de referencia. Teóricamente, los bosques primarios podrían servir de línea de base, pero este método suele ser problemático a causa de las modificaciones que el ecosistema ha podido experimentar en el pasado. Los bosques que han sido ordenados con arreglo a criterios sostenibles con fines de producción podrían también servir de estado de referencia, aunque estos bosques puedan carecer de algunas de las especies, procesos, funciones y estructuras de los primarios. Además, todos los ecosistemas forestales están sujetos a cambios inherentes y variaciones naturales, que les son característicos. La degradación ocurre cuando el índice de producción de un determinado bien o servicio es constantemente inferior a un valor esperado y se sitúa fuera de la gama de las variaciones que debieran registrarse en el sitio según el régimen de ordenación seleccionado. Por lo tanto, la evaluación está a menudo basada en el juicio puesto que la variabilidad natural solo puede ser conocida mediante investigaciones o controles prolongados, y los datos disponibles respecto a un determinado periodo son por lo general deficientes (FAO, 2011).

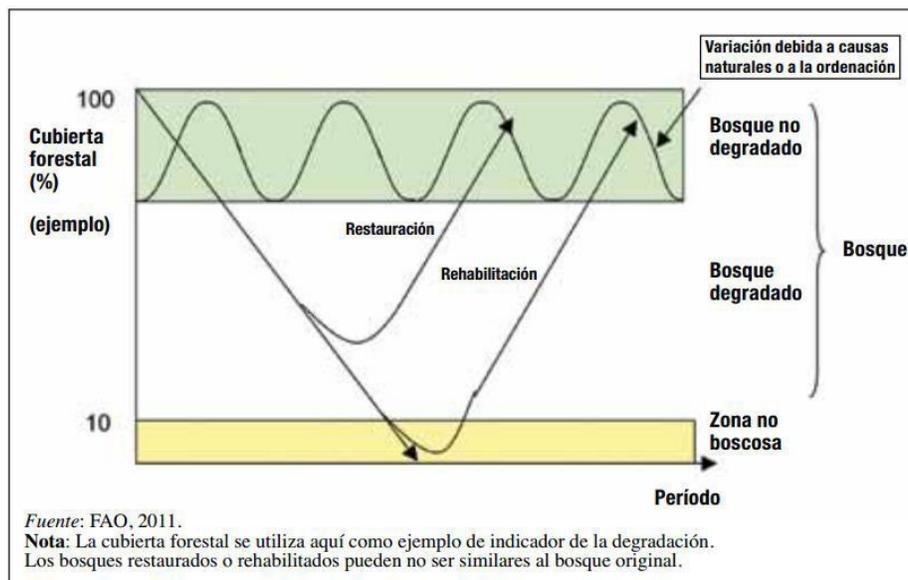


Figura 2-24. La cubierta forestal se utiliza aquí como ejemplo de indicador de la degradación (FAO, 2011).

2.15.2 Degradación por salinización

La detección y cuantificación de la degradación por salinización se da principalmente en suelos bajo riego, es decir, en áreas agrícolas. Perú cuenta con una franja costera donde la actividad principal es la agricultura, los valles de la región de Piura no escapan de este problema mundial que carcome los suelos haciéndolos infértiles y muchas veces irreversibles.

De acuerdo al IV Censo Nacional Agropecuario del 2012, la región Piura cuenta con un total de 386,777.4 ha de superficie agrícola, de la cual 262,094.2 ha constituyen cultivos bajo riego (67.8%). De éstas, la mayor parte se expande en zonas donde predomina una topografía de pendiente baja. Las condiciones de aridez y topográficas, así como la elevación de la napa freática debido a prácticas continuas de riego, promueven la ocurrencia de degradación de suelos por salinización (Elisabeth, Bui., 2013).

La detección y cuantificación de tierras degradadas por sales, se base en la predicción 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 (Willems, 2014).

Willems (2014) utiliza los compuestos máximos anuales del NDVI 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). 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 Willems (2014) es que la persistencia de valores bajos de NDVI constituye un indicador de ocurrencia de degradación de suelos.

Alaa A. Masoud (2014) utiliza la técnica **Spectral Mixture Analysis** (SMA) para la predicción de sales en valles agrícolas. El SMA se basa en que una escena de satélite está determinada por la proporción relativa de ciertos componentes espectralmente distintos. El SMA transforma los datos de radiación o de reflectancia en fracciones de algunos *endmembers* dominantes, que son componentes físicos fundamentales de la escena dentro del campo de visión del sensor remoto. Las fracciones representan las proporciones de mezcla de estos espectros *endmembers*. El SMA generalmente involucra tres pasos: a) evaluación de la dimensionalidad o número de materiales que reflejan únicamente en un paisaje para obtener los *endmembers*; b) la identificación de la naturaleza física de cada *endmember* dentro de un píxel; c) la determinación de las cantidades o proporciones de cada *endmember* en cada píxel.

2.15.3 Degradación por erosión del suelo

Generalmente, el viento no es lo suficientemente fuerte para arrancar materiales de la superficie de las rocas duras o de los suelos protegidos por una densa cobertura vegetal. Por el contrario, la acción del viento, erosionando y transportando sedimentos, se limita a aquellas superficies en las que los minerales pequeños y las partículas orgánicas están sueltas. Estas áreas son fundamentalmente los desiertos y las tierras semiáridas (estepas). El viento lleva a cabo dos tipos de actividad erosiva (Stralher, 1994). Por un lado, barre las partículas sueltas que se hallan sobre la superficie del suelo y las arrastra o levanta por el aire. Este proceso se denomina *deflación*. En los climas secos, prácticamente toda la superficie del terreno se halla expuesta a la deflación, ya que las rocas y el suelo están al descubierto. El proceso eólico de deflación es selectivo. Las partículas más finas, del tamaño de la arcilla, son levantadas muy fácilmente y transportadas en suspensión. Los granos de arena se mueven únicamente si el viento es moderadamente fuerte y tienden a desplazarse cercanos al suelo. En consecuencia, en aquellos lugares en los que exista una gran variedad de partículas en el suelo, serán transportados los más finos mientras que los gruesos quedarán rezagados (Stralher, 1994).

La erosión hídrica tiene su efecto a través del impacto de las gotas de lluvia sobre la superficie del suelo, y por el propio humedecimiento del suelo, que provocan desagregación de las partículas primarias; provoca también transporte de partículas por aspersion y proporciona energía al agua de la escorrentía superficial. Como consecuencia de la desagregación se produce un sello superficial que disminuye sustancialmente la capacidad de infiltración del suelo. En el momento en que la precipitación pasa a ser mayor que la tasa de infiltración de agua en el suelo, se produce la retención y detención superficial del agua y, posteriormente, el escurrimiento superficial del agua que no infiltra. Las pérdidas de nutrientes por la erosión, debido al creciente aumento de problemas, no solo en las áreas agrícolas sino también por los problemas de contaminación ambiental en los lugares donde sedimentan los materiales erosionados.

2.16 Temperatura superficial y el índice de vegetación

El potencial de obtener información sobre el estado de la energía y el agua de una superficie o para la clasificación de la cubierta vegetal a través de la relación entre la temperatura de teledetección de superficie (T_s) y el índice de vegetación (por ejemplo, el índice de diferencia normalizada NDVI) ha sido investigado por varios autores (Carlos et al., 1994; Gillies et al., 1997; Lambin et al., 1996; Moran et al., 1994; Nemani et al., 1993; Smith et al., 1991). La información complementaria en la banda térmica y las longitudes de onda del infrarrojo visible ha demostrado ser muy adecuado para el seguimiento de estado de la vegetación y el estrés, específicamente el estrés hídrico. El índice de vegetación es un indicador más bien conservador de estrés hídrico, ya que la vegetación se mantiene verde después de la tensión inicial del agua (Sandholt & Rasmussen, 2002). En contraste, la temperatura de la superficie puede aumentar rápidamente con el estrés de agua.

La T_s en combinación con el NDVI pueden proporcionar información sobre las condiciones en la vegetación y la humedad de la superficie (Sandholt & Rasmussen, 2002). Varios estudios se centran en la pendiente de la curva de T_s /NDVI (Nemani et al., 1993; Smith et al., 1991). El T_s /NDVI está relacionado con la tasa de evapotranspiración de la superficie y se ha utilizado para estimar la temperatura del aire (Boegh et al., 1998). El análisis de T_s /NDVI también se ha utilizado para evaluar la información relacionada con las condiciones de humedad del suelo (Goetz, 1997).

Un diagrama de dispersión de la temperatura superficial de teledetección y un índice de vegetación, en caso de una gama completa de cubierta vegetal y el contenido de humedad del suelo fraccionario, a menudo resulta en una forma triangular o una forma trapezoidal (Moran et al., 1994).

Una variedad de tipos de vegetación y las cosechas se han estudiado bajo una variedad de condiciones climáticas, la gama de escalas estudiadas van desde metros a lo global (Ingram, 2005). Por tanto, puede que no sea de extrañar que las interpretaciones difieran ampliamente. El enfoque descrito por Moran, M. S., Clarke, T., Inoue, et al. (1994) representa superficies parcialmente con vegetación.

2.16.1 Cubierta vegetal

La cubierta vegetal influye en la cantidad de suelo desnudo y vegetación visible a un sensor. Las diferencias en la temperatura de radiación entre el suelo y la cubierta vegetal afectará finalmente la temperatura superficial (Sandholt & Rasmussen, 2002).

2.16.2 La evapotranspiración

La evapotranspiración puede controlar en gran medida la temperatura de la superficie a través del balance de energía de la superficie. Cuanto menos evapotranspiración, menos energía disponible para el calentamiento sensible de la superficie. La resistencia estomática a la transpiración es un factor clave para que la disponibilidad de humedad del suelo esté parcialmente controlada (Sandholt & Rasmussen, 2002).

2.16.3 Las propiedades térmicas de la superficie

La capacidad calorífica y conductividad, y por lo tanto la inercia térmica, influyen en la temperatura superficial en el caso de superficies parcialmente con vegetación. Estas propiedades térmicas son una función del tipo de suelo y cambia con la humedad del suelo superficial (Sandholt & Rasmussen, 2002).

2.16.4 La radiación neta

La radiación de onda corta³ que llega a la superficie afecta a la temperatura superficial. El control radiativo de la temperatura superficial implica que las áreas con un menor saldo neto de radiación de onda corta (por ejemplo, debido a un alto albedo) tendrán temperaturas más bajas. El albedo es controlado por el tipo de suelo, la humedad superficial del suelo y la cubierta vegetal. La radiación incidente también afecta a la resistencia de las estomas en la transpiración (Sandholt & Rasmussen, 2002).

La Figura 2-25 muestra los factores que determinan el brillo de la temperatura superficial. Las variables de dentro de la figura se pueden estimar a partir de los datos de satélites. Siendo:

³ En la ciencia de la atmósfera, la totalidad del espectro solar se define como radiación de onda corta, pues su máxima intensidad yace en la región visible. En contraste, el espectro de radiación que escapa a la tierra es referido como radiación de onda larga (Stralher, 1994).

s_n = radiación neta de onda corta ,
 R_n = balance de radiación neta,
 $Glai$ = índice verde de area foliar,
 Fc = cubierta vegetal fraccionada, ET = evapotranspiración,
 rs = resistencia estomática,
 $M1$ = contenido de humedad del suelo (zona de la raíz),
 $M0$ = contenido de humedad del suelo en la cima

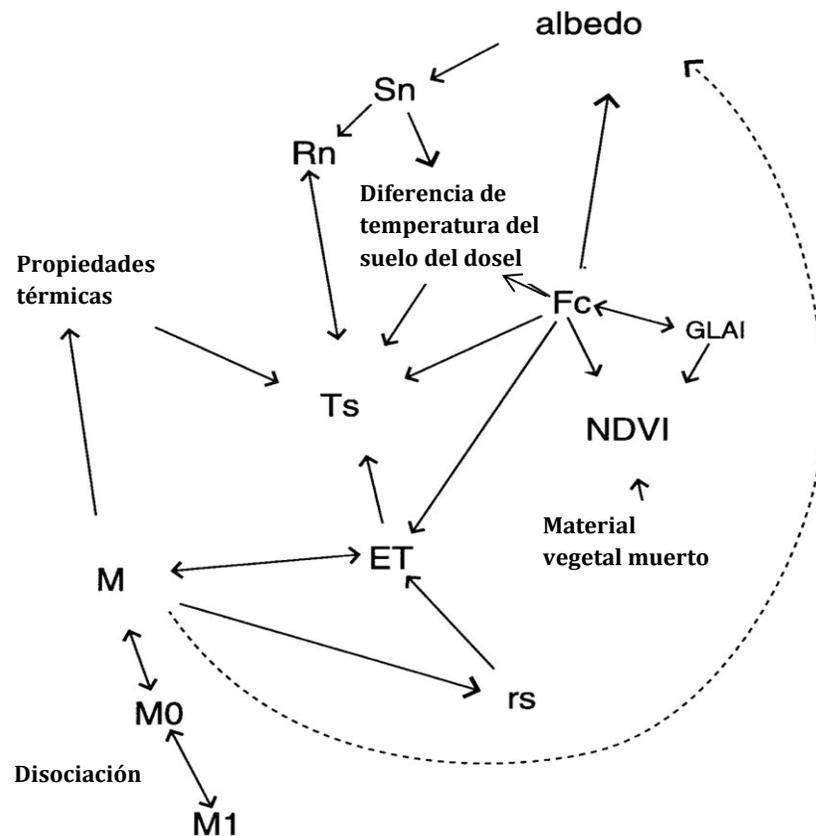


Figura 2-25. Ilustración de los factores que condicionan la temperatura superficial adaptado de (Inge Sandholt, Kjeld Rasmussen, 2002).

La Figura 2-26 muestra el concepto de $T_s/NDVI$ (adaptado al EVI de Lambin). El extremo izquierdo representa el suelo desnudo del rango de seco a húmedo y en extremo inferior derecho un suelo cubierto por mucha vegetación. Como la cantidad de vegetación verde aumenta a lo largo del eje x (NDVI), la temperatura máxima de la superficie disminuye. Para condiciones secas, la relación negativa se define por el borde superior, que es el límite superior de la T_s para un tipo de superficie dada.

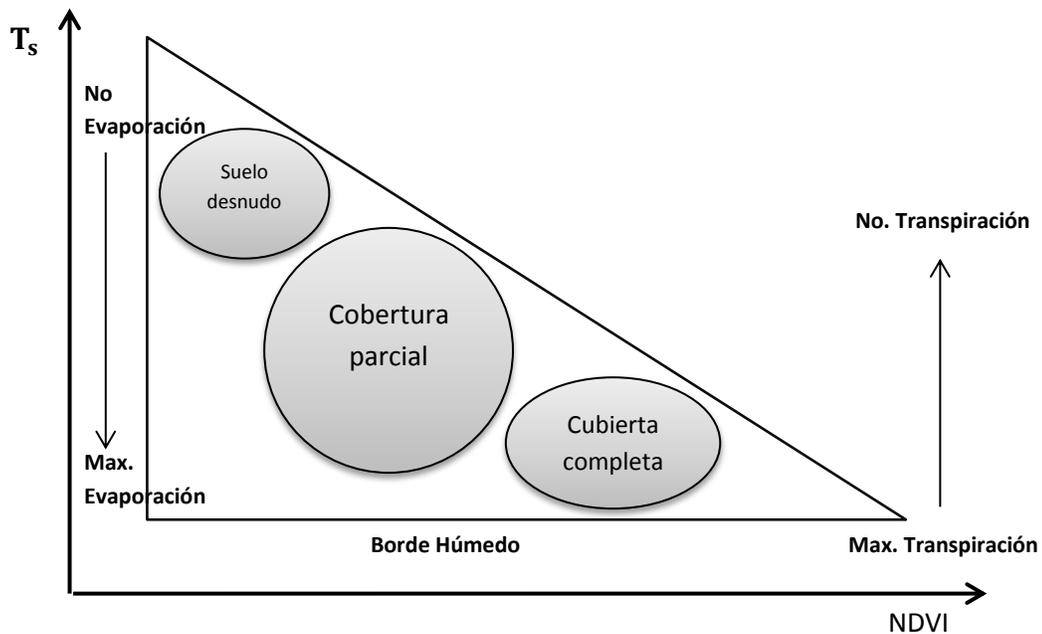


Figura 2-26. Simplificado $T_s/NDVI$ adaptado de (Lambin & Ehrlich, 1996).

2.17 Rupturas en tendencia y estacionalidad aditivas (BFAST)

Los cambios en los ecosistemas comúnmente observados desde el espacio mediante la percepción remota, se pueden dividir en tres categorías: (1) cambios cíclicos o estacionales, por ejemplo, impulsado por la interacción de la temperatura y las precipitaciones anuales que afectan la fenología de las plantas; (2) cambios graduales en la tendencia, como la tendencia de la precipitación media anual o el cambio gradual en la gestión del suelo (por ejemplo, la sequía a largo plazo, el rebrote del bosque después de un incendio) que dan lugar a cambios a largo plazo de varios años; y (3) cambios en la tendencia abrupta, causadas por perturbaciones⁴ de tipo antrópico (deforestación) o perturbaciones de tipo natural (sequías) que cambian el uso de la superficie de la tierra drásticamente.

Detectar cambios dentro de una serie de tiempo significa comprender los procesos de acción de conductores naturales o antrópicos. Por lo tanto estimar cambios dentro de la serie de datos de teledetección no es sencillo, ya que las series de tiempo tienen por sí mismo cambios estacionales, además del ruido que se origina en el entorno de detección como el ángulo de visión, errores geométricos remanentes, la dispersión atmosférica y nubes (Verbesselt et al., 2012).

La capacidad de cualquier sistema para detectar alteraciones en los ecosistemas depende de su capacidad para diferenciar el ciclo fenológico normal del cambio anormal (Verbesselt et al., 2012). Estos sistemas tendrán 3 grandes desafíos:

- Primero, la técnica de detección debe ser capaz de identificar alteraciones en las imágenes de satélite recién capturadas, de tal manera que permita una respuesta rápida o de alerta temprana.
- En segundo lugar, las técnicas de detección de cambio deben ser independientes de los umbrales de vegetación específica, pero a la vez tienen que ser robustos contra el ruido inherente y a la estacionalidad captadas dentro de las series de tiempo.

La mayoría de los métodos de detección de cambios requieren la designación de un umbral definido por el usuario que permita separar un cambio real de un cambio causado por la variabilidad en la iluminación, la estacionalidad o la dispersión atmosférica (Verbesselt et al., 2012). La determinación de los umbrales añade un coste significativo a los esfuerzos crecientes de detección de cambio en las distintas regiones del planeta (Michael A. White, 2006). Se necesita, por lo tanto, un análisis histórico de datos de teledetección para modelar el comportamiento anormal en el ecosistema.

⁴ El proceso degradador responde a fenómenos de perturbación (aunque no todas las formas de perturbación ocasionan degradación), cuyo origen, magnitud, gravedad, calidad y frecuencia puede variar. Las perturbaciones pueden ser de carácter natural (el fuego, las tormentas o la sequía) o de origen humano (las actividades de explotación, la construcción de caminos, la agricultura migratoria, la caza o el pastoreo) o combinar ambas posibilidades.

- En tercer lugar, los métodos de detección de cambio tienen que hacer frente a los datos que faltan por las nubes o defectos del sensor. Para ello es necesario de alguna manera rellenar datos mediante algún método de interpolación.

El método Bfast (Rupturas en tendencia y estacionalidad aditivas) integra la descomposición de las series de tiempo en sus componentes, tendencia, estacionalidad y efecto aleatorio, en la detección de rupturas dentro de las series temporales. *Esta metodología es aplicado a nivel mundial para detectar breakpoints, ya que analiza cada píxel de forma individual* (Verbesselt et al., 2012).

Bfast tiene la capacidad de detectar cambios fenológicos a largo plazo mediante el uso de un modelo estacional armónico.

2.17.1 Modelo de descomposición

Modelo de descomposición aditiva se utiliza para ajustar iterativamente una tendencia lineal en partes conjuntamente con un modelo estacional (Jan Verbesselt R. H., 2010).

$$Y_t = T_t + S_t + e_t \quad (t = 1, \dots, n) \quad (2.23)$$

Donde Y_t son los datos observados al tiempo t , T_t es la componente tendencial, S_t es el componente estacional y e_t es el componente aleatorio (restante). El componente aleatorio es la variación que queda en los datos muy aparte de los componentes tendenciales y de estacionalidad.

Se supone que T_t es lineal por tramos con pendientes específicos por segmento e intercepciones en $(m + 1)$ por segmentos diferentes. Por lo tanto hay m puntos de interrupción $\tau_1^*, \dots, \tau_m^*$, de manera que.

$$T_t = \alpha_i + \beta_i t \quad (\tau_{i-1}^* < t \leq \tau_i^*) \quad (2.24)$$

Donde $i = 1, \dots, m$ y definimos $\tau_0^* = 0$ y $\tau_{m+1}^* = n$.

Para la componente estacional se detecta los puntos de interrupción o puntos de corte en p estacionales que pueden presentar diferentes m puntos de interrupción dentro de la componente estacional.

El método bfast emplea una parametrización robusta para la detección de cambios fenológicos dentro de una serie de tiempo obtenido por datos satelitales. Supongamos que los puntos de interrupción se denominarán por $\tau_{j-1}^\# < t \leq \tau_j^\#$ ($j = 1, \dots, p$) y K el número de términos armónicos.

$$S_t = \sum_{k=1}^K a_{j,k} \sin\left(\frac{2\pi kt}{f} + \delta_{j,k}\right) \quad (2.25)$$

Donde los parámetros desconocidos son las amplitudes de los segmentos específicos $a_{j,k}$ y la fase $\delta_{j,k}$, f es la frecuencia conocida ($f = 23$ observaciones anuales, serie de tiempo de cada 16 días

al año). Mientras la ecuación (2.25) hace hincapié en la interpretación armónica, la ecuación (2.26) es una transformación conveniente para un modelo de regresión lineal múltiple armónico con coeficientes.

$$S_t = \sum_{k=1}^K \left[\gamma_{j,k} \sin\left(\frac{2\pi kt}{f}\right) + \theta_{j,k} \cos\left(\frac{2\pi kt}{f}\right) \right] \quad (2.26)$$

La amplitud y la fase, así como la frecuencia f/k son dados por $a_{j,k} = \sqrt{\gamma_{j,k}^2 + \theta_{j,k}^2}$ y $\delta_{j,k} = \tan^{-1}(\theta_{j,k}/\gamma_{j,k})$ respectivamente.

2.17.2 Detección de cambio iterativo dentro de las series temporales

A pesar de ser bastante intuitivo, el modelo de descomposición segmentado no es fácil de estimar. Los breakpoints⁵ en la tendencia τ_i^* ($i = 1, \dots, m$) y su correspondiente intercepción del segmento específico α_i y β_i son determinados junto con los puntos de corte estacionales $\tau_j^\#$ ($i = 1, \dots, p$), y el segmento de amplitud específico correspondiente $a_{k,j}$ y la fase $\delta_{k,j}$ para frecuencias de $23/k$ ($k = 1, 2, 3$).

Además el modelo tiene que determinar el número de segmentos requeridos en los componentes tendencia ($m + 1$) y estacional ($p + 1$) respectivamente. Sin embargo, una vez que se conozcan los puntos de interrupción, la estimación de parámetros de tendencia y temporada es sencilla. La posición óptima de estos descansos puede ser determinada minimizando la suma residual de cuadrados mediante indicadores como AIC (criterio de información Akaike). Pero el criterio de información bayesiano (BIC) es un procedimiento de selección adecuado en muchas situaciones (Zeileis, 2011).

Antes de correr el modelo de detección de cortes y la estimación de los puntos de corte, se recomienda comprobar si los puntos de interrupción se están produciendo en la serie temporal. Para esto se utiliza los mínimos cuadrados ordinarios mediante sumas móviles (MOSUM) para analizar si se producen uno o más puntos de interrupción (Zeileis, 2011).

Si la prueba o el análisis indican un cambio significativo ($p < 0.05$), los puntos de corte se calculan usando el BIC. La fecha y el intervalo de confianza de la fecha de cada ruptura se estiman también. El intervalo de confianza de la fecha de corte o ruptura indica un intervalo del 95% respecto a la fecha estimada.

⁵ Bfast permite detectar cambios graduales y abruptos mediante la manipulación del intervalo de cambio dentro del propio algoritmo.

Para aplicar el método bfast se recomienda tener una serie histórica de varios años, por lo menos, de 5 años para detectar cambios fenológicos a largo plazo. Los cambios fenológicos a largo plazo se definen más de dos años, pero una serie temporal de imágenes de satélite de 10 o 25 años son breves relativamente para detectar cambios fenológicos a largo plazo.

La iteración se inicializa con una estimación de \hat{S}_t a partir de una descomposición estándar de la estacionalidad y tendencia. La estimación de los parámetros se realiza iterando a través de los siguientes pasos hasta que el número y posición de los puntos de interrupción o corte no hayan cambiado.

- i. Si la prueba OLS-MOSUM indica que los puntos de interrupción se están produciendo en el componente tendencial, el número y posición de los puntos de ruptura ($\tau_1^*, \dots, \tau_m^*$) son estimados mediante los mínimos cuadrados de los datos desestacionalizados $Y_t - \hat{S}_t$.
- ii. Los coeficientes de tendencia α_i y la fase β_i son estimados (teniendo en cuenta la tendencia de puntos de interrupción) utilizando una regresión robusta. Esto produce la estimación de la tendencia $\hat{T}_t = \hat{\alpha}_i + \hat{\beta}_i t$ basado en la ecuación (2.24).
- iii. Si la prueba del OLS-MOSUM indica que los puntos de interrupción se están produciendo en el componente estacional, el número de los puntos de interrupción de temporada ($\tau_1^*, \dots, \tau_m^*$) son estimados mediante los mínimos cuadrados desde los datos cíclicos $Y_t - \hat{T}_t$.
- iv. Se estima los coeficientes estacionales $\gamma_{j,k}$ y $\theta_{j,k}$ (teniendo en cuenta los puntos de interrupción de temporada) mediante una regresión robusta. Esto produce el componente estacional $\hat{S}_t = \sum_{k=1}^3 a_{j,k} \sin\left(\frac{2\pi kt}{f} + \delta_{j,k}\right)$ basado en la ecuación (2.25).

CAPITULO III

ÁREA DE ESTUDIO

3. ÁREA DE ESTUDIO

3.1 Ubicación y extensión

La Región Piura se ubica en la frontera norte del territorio peruano; ocupa 35,892.49 km² de superficie continental y 1.32 km² de superficie insular, lo cual es el 2.8% del territorio nacional además de una línea de costa de 392.43 km² de largo. Sus coordenadas geodésicas se encuentran localizadas entre los 4°4'50" y 06°22'12" de Latitud Sur y 79°12'30" y 81°19'35" de Longitud Oeste del Meridiano de Greenwich (Gobierno Regional de Piura, 2012).

Las imágenes MODIS a 250m y 1000m de resolución espacial tanto para el producto MOD11A2 y MOD13Q1 respectivamente, permiten un análisis a nivel de estudio ni detallado ni grosero, sino más bien lo suficiente como para entender la dinámica de los ecosistemas a escala local, regional y global. En base a la cartografía y a una resolución de 250m y 1000m, la escala de trabajo es de 1:500 000 y 1:2 000 000 respectivamente.

3.2 Características físicas del área de estudio

El medio físico que presenta el territorio de Piura, está referido a sus componentes naturales físicos tales como la geología, fisiografía, geomorfología y suelos. En este estudio se describirá de forma general cada uno de los componentes físicos del área de estudio.

3.2.1 Geología

Gran parte del territorio de la Región de Piura se encuentra localizado en la llanura costera (60%) y otra dentro de la cadena andina (40%) lo cual le confiere una fisiografía muy heterogénea con paisajes y ecosistemas muy especiales y diversos. Los sucesivos acontecimientos geológicos que se han producido en la región norte de Perú a lo largo de tiempo de los diferentes tipos de rocas que conforman el territorio de la Región, y estructurales; los cuales han ido modelado su morfología y relieve, determinando así, la configuración geológica actual del territorio piurano (Gobierno Regional de Piura, 2012).

Las unidades geológicas han sido clasificadas de acuerdo a sus características litológicas, sedimentológicas, estratigráficas, estructurales y orden de ocurrencia en el tiempo; lo cual permite diferenciar hasta 85 unidades lito-estratigráficas. En general, en la región de Piura afloran rocas sedimentarias en 62.95% (2'291418.5 Ha), rocas ígneas (volcánicas e intrusivas), 27.72% (888, 055.90 Ha) y rocas metamórficas en 9.33% (317962.90 Ha); cuyas edades varían desde el precámbrico hasta el cuaternario reciente (Gobierno Regional de Piura, 2012).

En la región costera de Piura, la geología está representada por una unidad metamórfica que consiste en esquistos, filitas, cuarcitas, pegmatitas y granitos. Las rocas metamórficas dominadas

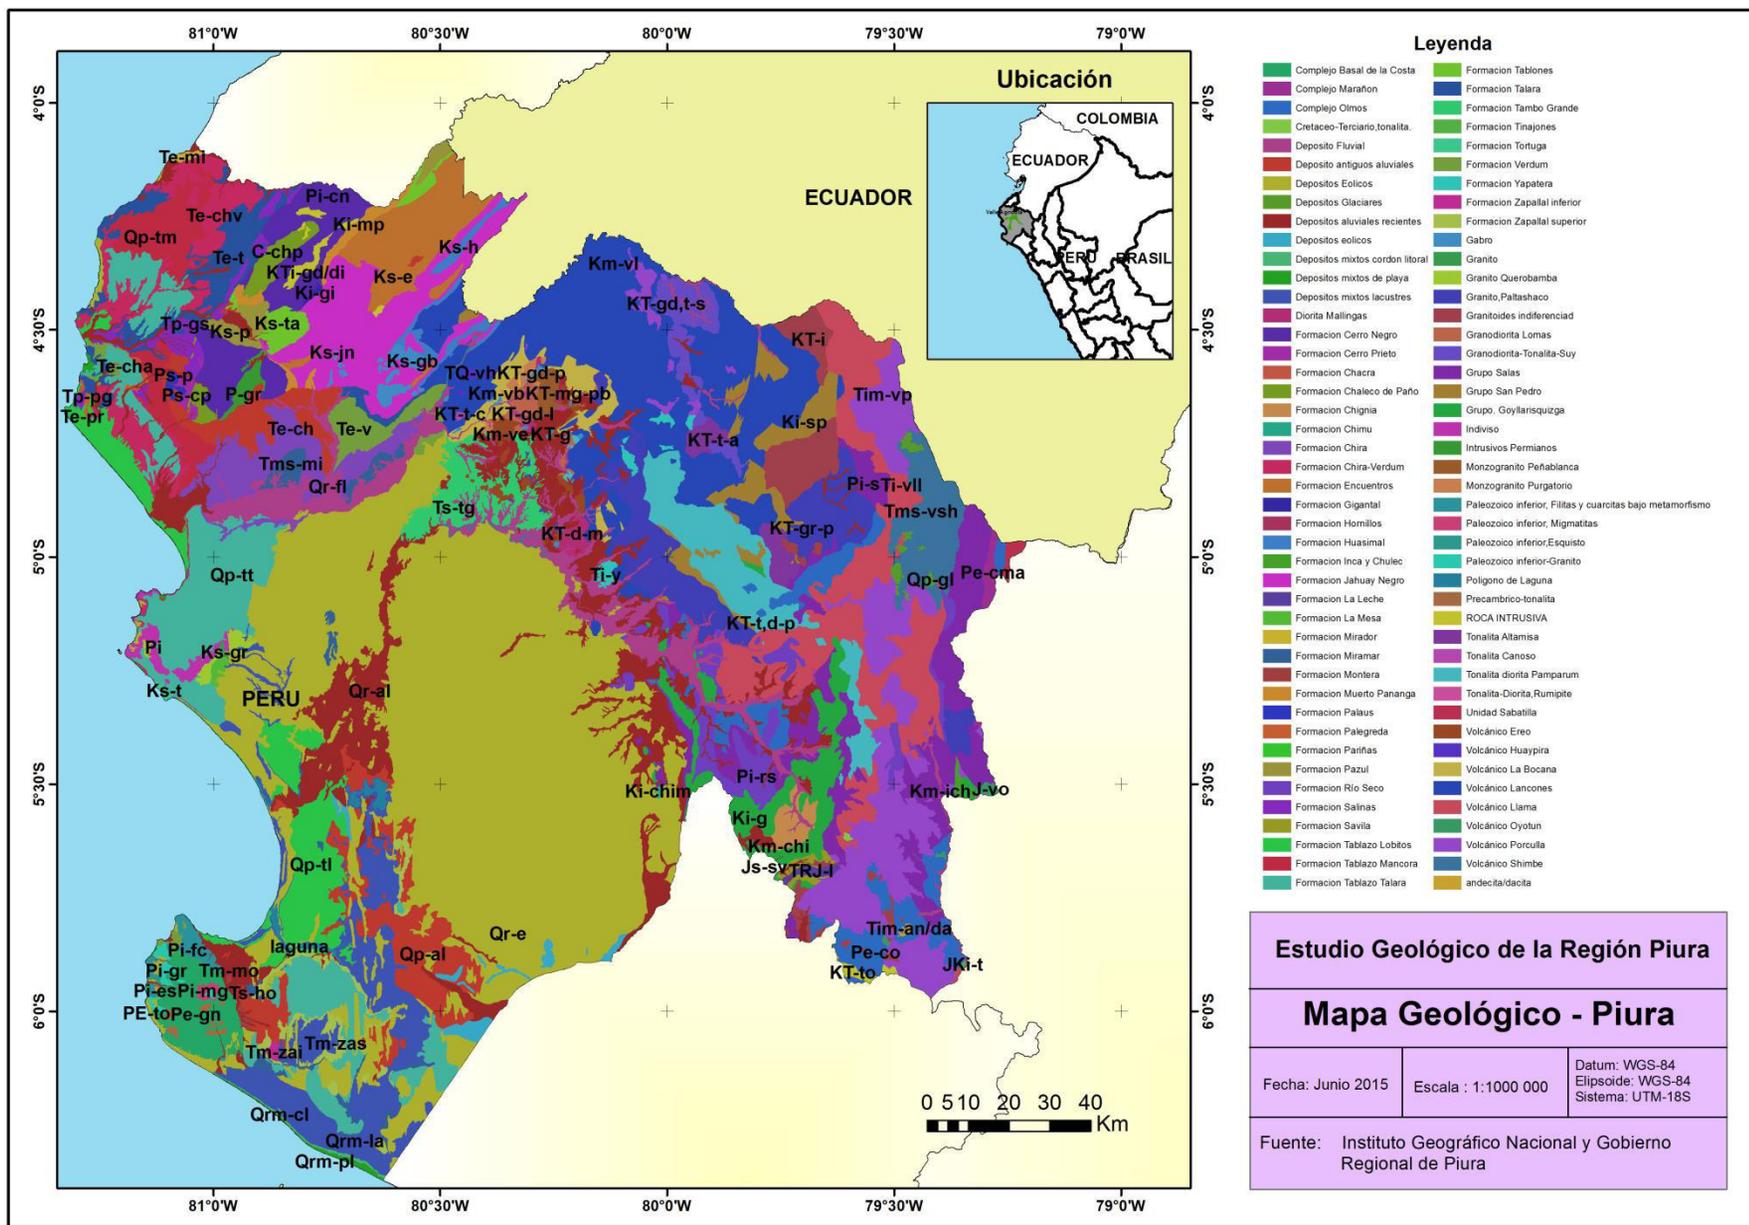
por micaesquistos generan alta acidez en los suelos, lo que afecta la capacidad de fertilidad de los mismos.

En conclusión, el territorio piurano está conformado por rocas sedimentarias, rocas ígneas (volcánicas e intrusivas) y rocas metamórficas. Las rocas intrusivas cubren la menor proporción del territorio de Piura, ocupa el 7.49% de su extensión, con mayor amplitud en la sierra. El espacio geográfico de la Región Piura está dominado por las rocas sedimentarias y ocupan el 62.95% del territorio total y, de ello el 98% ocupa la región costera; a ellas está asociada casi la totalidad del potencial de recursos no metálicos, como petróleo y gas, suelos agrícolas, aguas subterráneas y potasio y magnesio, bentonitas, arcilla común, arcillas refractarias, baritina, andalucita, materiales de construcción entre otros, que generalmente son alternativas de la región.

Los grandes yacimientos polimetálicos de la Región que cuenta con estudios de factibilidad económica, pero no con licencia socio ambiental se ubican en Tambo Grande y Rio Blanco. La actividad minera no metálica esta diversificada en amplios sectores de la costa; siendo Boyovar el mega proyecto en desarrollo de minerales industriales de mayor trascendencia en la Región.

En la Figura 3-1 se muestra las formaciones geológicas de la región de Piura en la cual se puede apreciar el gran porcentaje de formaciones identificadas en la Zonificación Ecológica Económica.

Predicción de Tierras Degradadas a Partir del Análisis de Series Temporales del Índice Mejorado de Vegetación y Temperatura de superficie de Suelo mediante Imágenes MODIS - Caso Estudio Piura



Mapa 3-1. Mapa geológico de Piura.

3.2.2 Fisiografía

La fisiografía del departamento de Piura se muestra en la zona de la planicie costera y zona transicional de la región altoandina (Figura 3-2).

a) *Paisaje Aluvial*

Cauces superficiales de régimen intermitente.

b) *Paisaje marino*

Este paisaje se caracteriza por presentar sedimentos inconsolidados y consolidados del Cuaternario, los cuales se encuentran distribuidos en la planicie marina y en las dos grandes depresiones continentales que existen en la zona.

c) *Paisaje eólico*

Constituye un paisaje en el cual el viento, actuando como agente modelador ha impreso sus efectos, reflejados por una cobertura de sedimentos arenosos de espesor, forma y altura variables. Se ha identificado tres subpaisajes principales: Llanura eólica, dunas (sobrematerial de origen marino) y arenales amorfos.

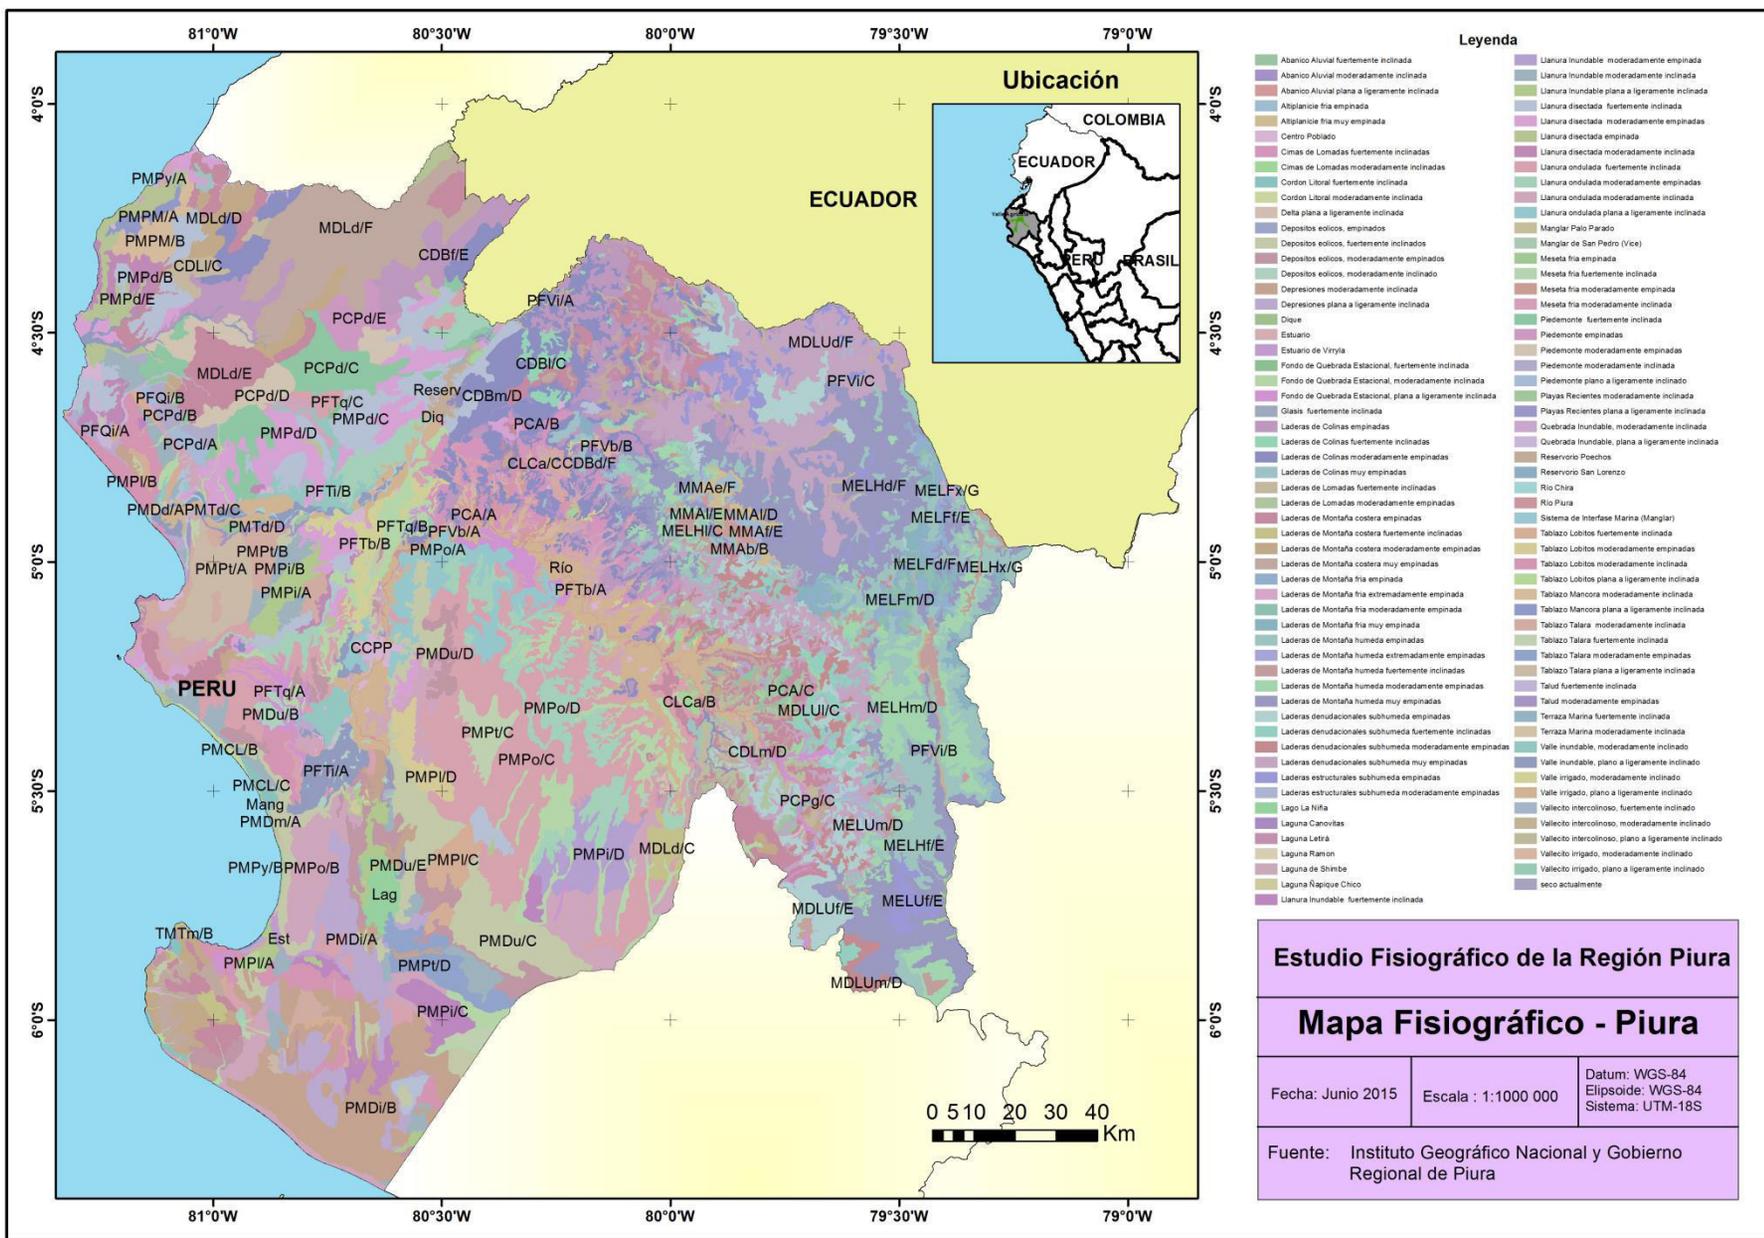
d) *Paisaje colinoso*

Este paisaje está representado por evidencias de un modelado paleoclimático o relictos de formas preexistentes.

e) *Paisaje montañoso*

Dentro del ambiente típicamente desértico predominante en la zona, sobresale el paisaje montañoso por su magnitud en elevación (480 m. s. n. m) y por su aspecto agreste y rocoso, en el que se hallan perfectamente conservadas sus formas estructurales y en el que es fácil observar las numerosas fallas por fracturas ocurridas en diferentes eventos tectónicos.

Predicción de Tierras Degradadas a Partir del Análisis de Series Temporales del Índice Mejorado de Vegetación y Temperatura de superficie de Suelo mediante Imágenes MODIS - Caso Estudio Piura



Mapa 3-2. Mapa Fisiográfico de Piura.

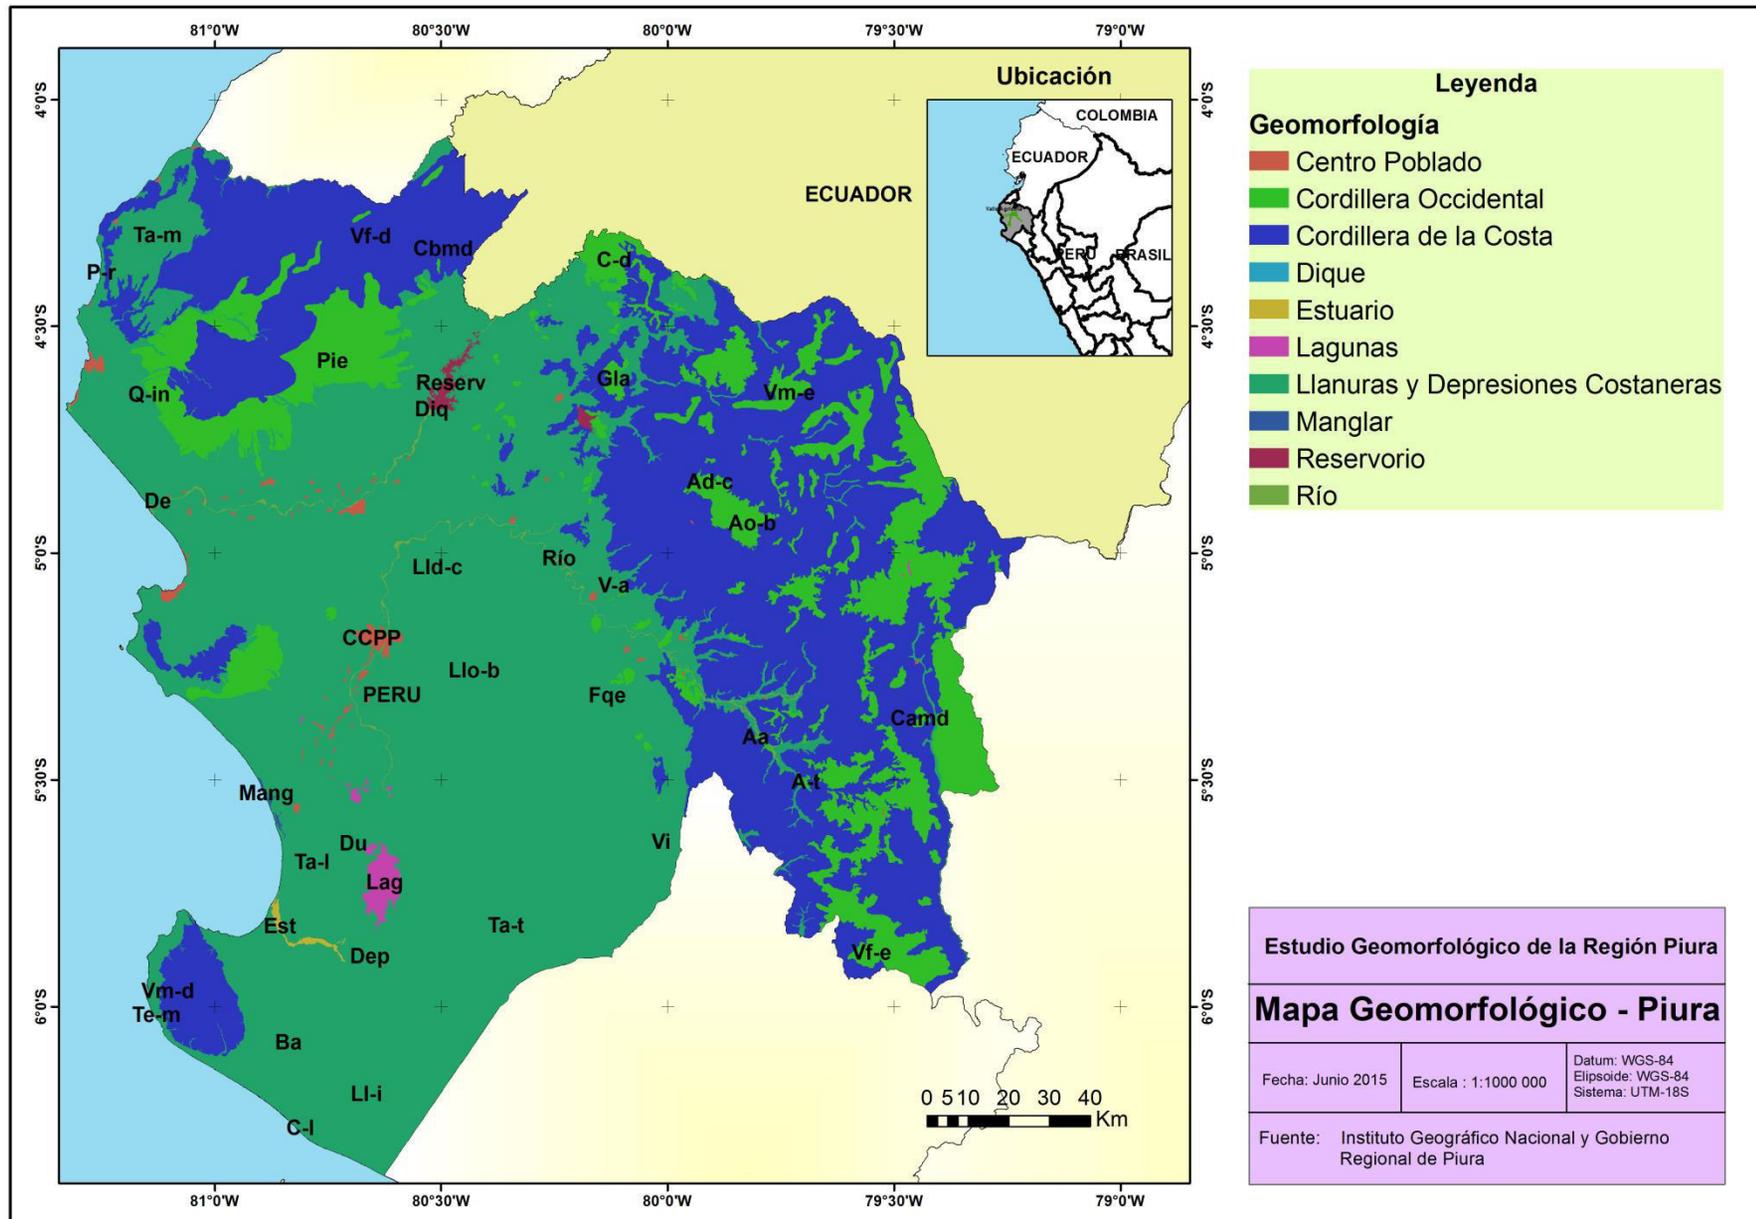
3.2.3 Geomorfología

Los grandes procesos formadores del relieve ocurridos en el departamento de Piura, están vinculados a los eventos tectónicos, material y a las modificaciones bioclimáticas que se han generado desde el inicio de su aparición. Las condicionantes morfológicas como la inestabilidad, vulnerabilidad y riesgo, siempre han condicionado el uso y la ocupación del territorio de Piura.

Morfológicamente el departamento está constituido por tres grandes unidades morfoestructurales, las cuales son la Cordillera costera, las llanuras y depresiones costaneras y la Cordillera Occidental (Figura 3-3). En base a ello, es que se ha originado los principales y grandes procesos geodinámicos que han ido formando el relieve a través de diferentes periodos geológicos.

La morfogénesis de la Cordillera, se presentó fundamentalmente por movimientos epirogénesis dando lugar a la formación de elevaciones, siendo la más representativa, el cerro Illescas. Las llanuras costeras, presenta una estructuración geológica de naturaleza sedimentaria.

El resultado de estos procesos geológicos ha generado variadas geoformas. En la cordillera costera, se presenta vertientes montañosas, colinas y piedemontes. En las llanuras y depresiones costeras, se presenta terrazas marinas, llanuras de inundación, valles y formaciones de acumulación eólica conocidas como dunas. Finalmente en la Cordillera Occidental encontramos vertientes montañosas fuertemente inclinadas, piedemontes, abanicos aluviales, etc.



Mapa 3-3. Mapa Geomorfológico de Piura.

3.2.4 Suelos

Dentro de la zona costera de Piura, existen los tipos de suelos como:

a) *Fluvisoles*

A este grupo pertenecen los suelos formados sobre las bases de depósitos recientes o modernos de origen esencialmente aluviónico, de drenaje libre y bajo un relieve predominantemente plano con gradiente generalmente por debajo del 2%. Se encuentran en las áreas o valles agrícolas irrigados de los ríos Chira y Piura.

b) *Regosoles*

Estos suelos conforman las arenas desérticas de las planicies costeras de Piura. Estas arenas secas o regosoles éutricos, más propiamente dicho, están formados por suelos esencialmente arenosos y sueltos, de origen eólico y de drenaje excesivo. El relieve topográfico es bastante variable desde plano a ondulado y monticulado.

c) *Soloncharks*

Los Solonchaks de los suelos salinos por excelencia que tipifican las tierras bajas del desierto costero de Piura., conformados por suelos a base de depósitos recientes generalmente de origen aluvional, pero con concentraciones salinas distribuidas a todo lo largo del perfil hasta un poco más de 1,20m de profundidad. Las conductividades eléctricas sobrepasan largamente la línea crítica de los 15mm. Y por lo general, suelen presentar horizontes sálicos, generalmente entre los 100cm de profundidad.

d) *Yermosoles*

Los yermosoles constituyen los grupos edáficos-típicos de las planiciecosteras desérticas y de baja concentración salina. Se localizan en forma conspicua en las amplias planicies de la costa. Dentro de este grupo se distinguen los Yermosoles cálcicos, caracterizados por la presencia abundante de carbonato de calcio en la masa asó como en la forma pulverulenta o de horizontes cálcicos.

e) *Xerosoles*

Los xerosoles conforman a un grupo edáfico de mayor desarrollo pedalógico, dentro del régimen árido prevalente, así como el interés que presentan para propósitos agrícolas. Se han desarrollado a partir de materiales finos, de drenaje moderado y bajo un relieve topográfico variable, desde plano a ondulado variando a monticulado.

Dentro de la zona andina de Piura, existen los tipos de suelos como:

f) *Región lítica*

Esta región comprende el formidable flanco occidental árido de los andes piuranos, extendiéndose altitudinalmente desde los 1000 hasta los 3900 de altitud. El relieve es abrupto y fuertemente disectado, con pendientes de más de 70%. El clima es predominantemente árido a semiárido con precipitaciones pluviales hasta 800 mm anuales y temperaturas medias-anuales que oscilan entre $6^{\circ}C$ y $12^{\circ}C$, siendo un tanto más elevadas en el sector norte de esta región.

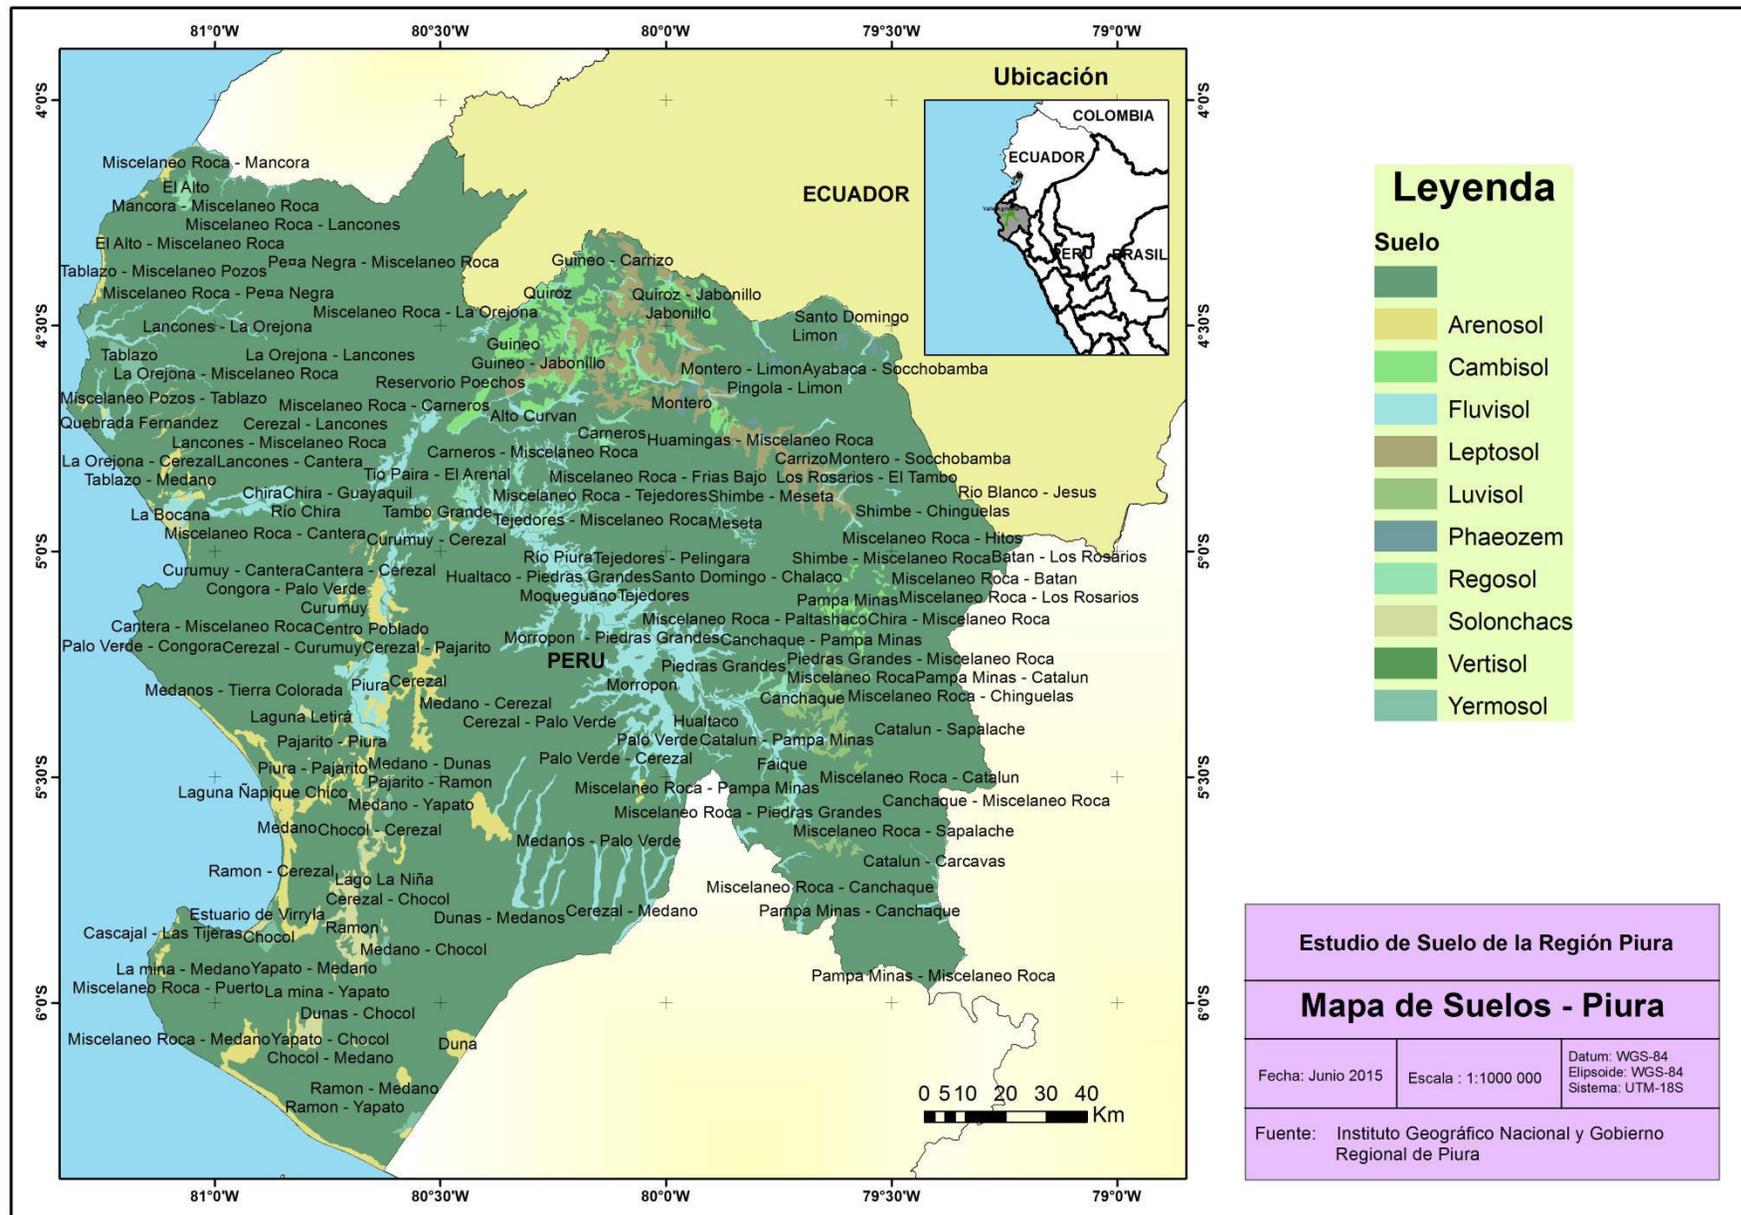
g) *Región paramosólica*

Esta región edáfica comprende las áreas altoandinas (puna alta) que se extiende generalmente entre los 3000 y 3900 de altitud. Climáticamente presenta temperaturas que varían entre $0^{\circ}C$ hasta $6^{\circ}C$ y con precipitaciones pluviales mínimas de 250mm en los bordes más occidentales y máximo de 2000mm en las zonas contiguas a la ceja de selva. Las zonas norte y centrosur son las más húmedas de esta región.

h) *Región acrisólica*

Esta región edáfica, denominada acrisólica por la presencia definida y típica de suelos fuertemente meteorizadas y de naturaleza ácida. Geográficamente, esta región comprende el grueso del flanco oriental boscoso, ocupando las partes medias e inferiores de la denominada selva alta. Esta diversidad de tipos de suelos se observan en la Figura 3-4.

Predicción de Tierras Degradadas a Partir del Análisis de Series Temporales del Índice Mejorado de Vegetación y Temperatura de superficie de Suelo mediante Imágenes MODIS - Caso Estudio Piura



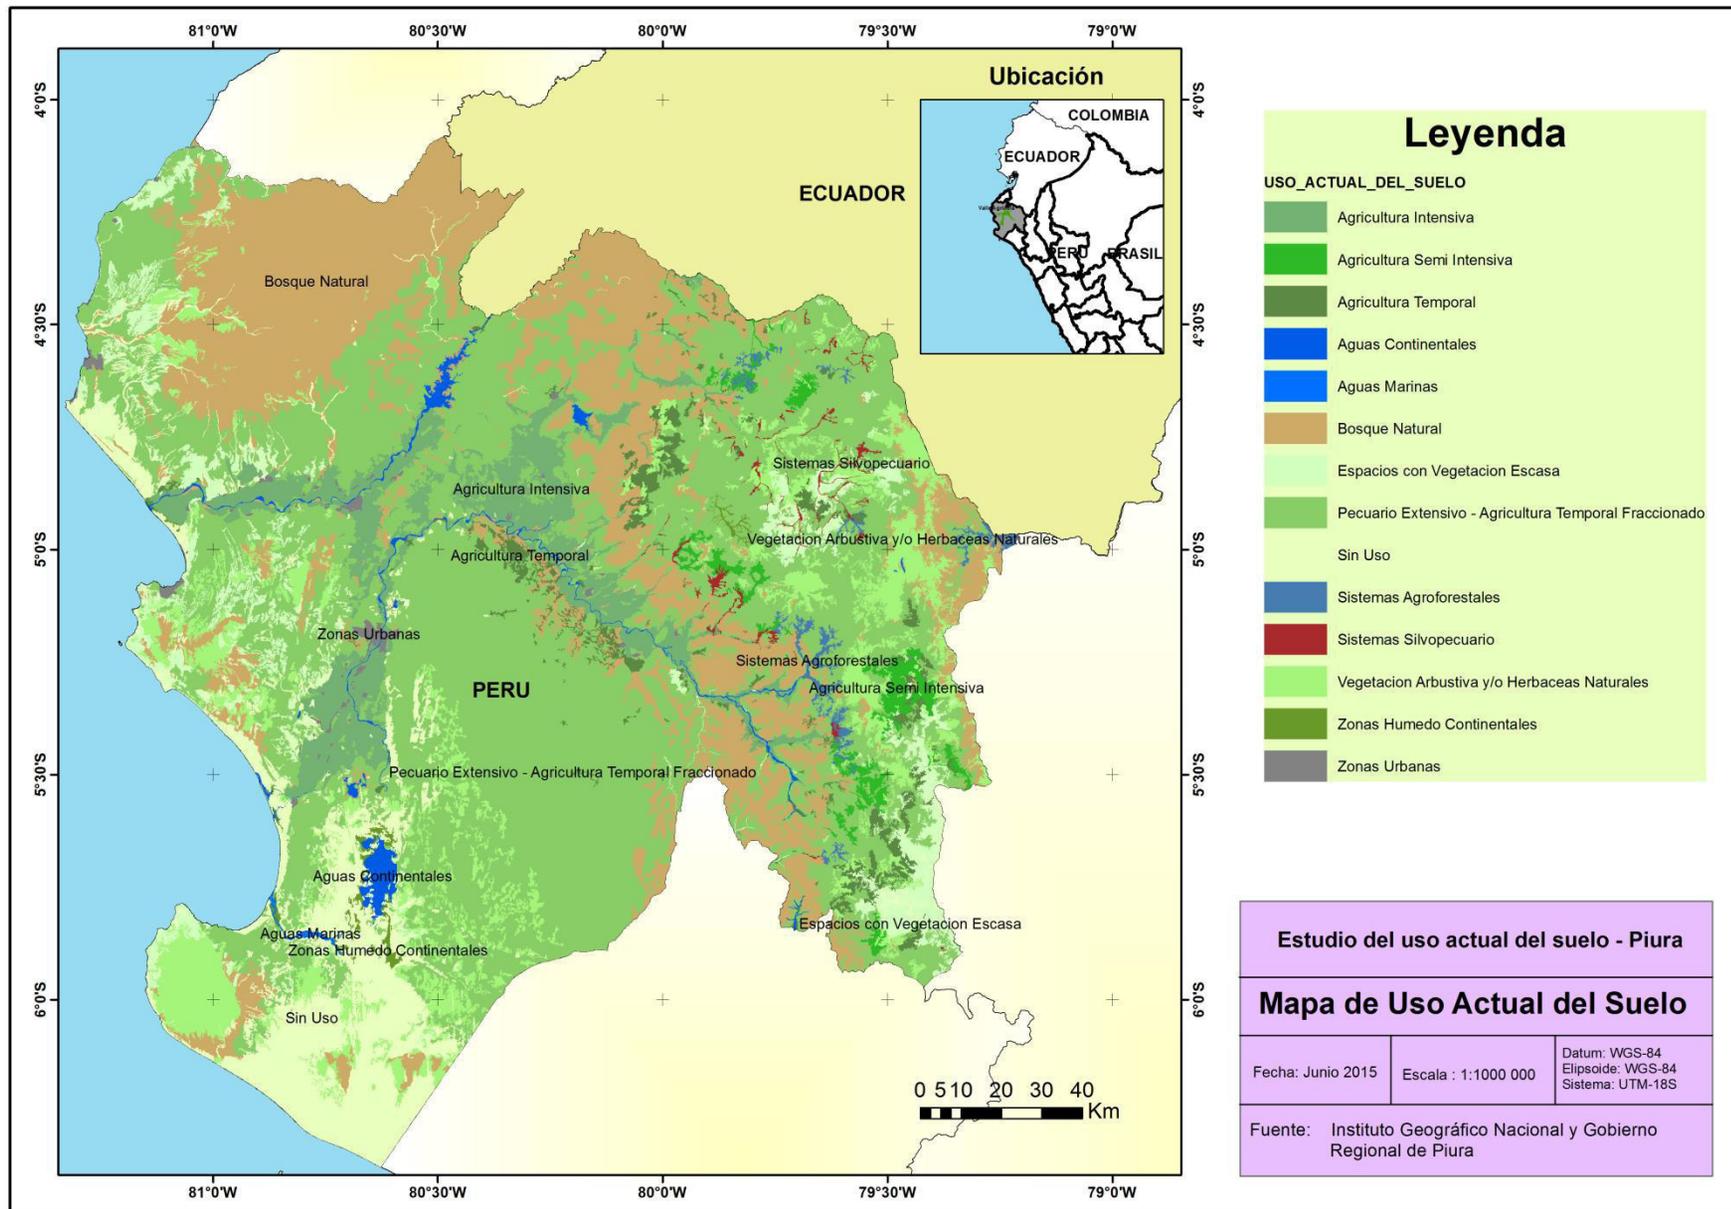
Mapa 3-4. Mapa de Suelos de Piura.

3.2.5 Uso actual de la tierra

El área de estudio comprende toda la superficie de la región Piura, identificándose 32 unidades de uso actual, de las cuales 17 son asociaciones, es decir la combinación de 2 o 3 tipos de ocupación o uso del suelo (Figura 3-5).

El trabajo realizado durante la elaboración de la Zonificación Ecológica Económica (ZEE) por el gobierno regional de Piura consistió en la utilización de imágenes de satélite ASTER con una resolución de 15m y a una escala de 1:1000000, imágenes Landsat, imágenes de Google Earth que permitieron visualizar con mayor claridad y clasificar los diferentes usos actuales del suelo en la región. Todo esto se complementó con el trabajo de campo para la verificación in situ de todas las actividades que se desarrolla en la región; apoyado en datos georreferenciados y tomas fotográficas. El trabajo de la ZEE de Piura se realizó en las ocho provincias de la región, distribuidos según las regiones naturales del Perú, en la costa, sierra y selva alta.

Predicción de Tierras Degradadas a Partir del Análisis de Series Temporales del Índice Mejorado de Vegetación y Temperatura de superficie de Suelo mediante Imágenes MODIS - Caso Estudio Piura



Mapa 3-5. Mapa de uso actual del suelo de Piura

3.2.6 Características climáticas de las tierras secas de Piura

Si bien, las tierras secas suelen incluir las áreas áridas, semiáridas y secas subhúmedas y presentar condiciones similares a los desiertos en un proceso de degradación de la tierra, se incluye también las tierras hiperáridas (desiertos), ya que éstas también son susceptibles de intervención productiva en el contexto del desarrollo sostenible (MINAM, 2012). En términos ambientales, las tierras secas se caracterizan por:

- Precipitaciones escasas poco frecuentes, irregulares e impredecibles.
- Gran diferencia entre las temperaturas diurnas y nocturnas.
- Suelos con poca materia orgánica y ausencia de agua.
- Plantas y animales adaptadas a las variables climáticas (resistencia las sequias, tolerantes a la salinidad, resistentes al calor y capaces de sobrevivir sobre condiciones de falta de agua).

La aridez nos informa sobre la escasez estacional y/o anual de los recursos hídricos. Sobre la base del índice de aridez (definido como la razón entre la precipitación anual y la evapotranspiración potencial anual - P_a/ET_0). La Convención de las Naciones Unidas de Lucha contra la Desertificación

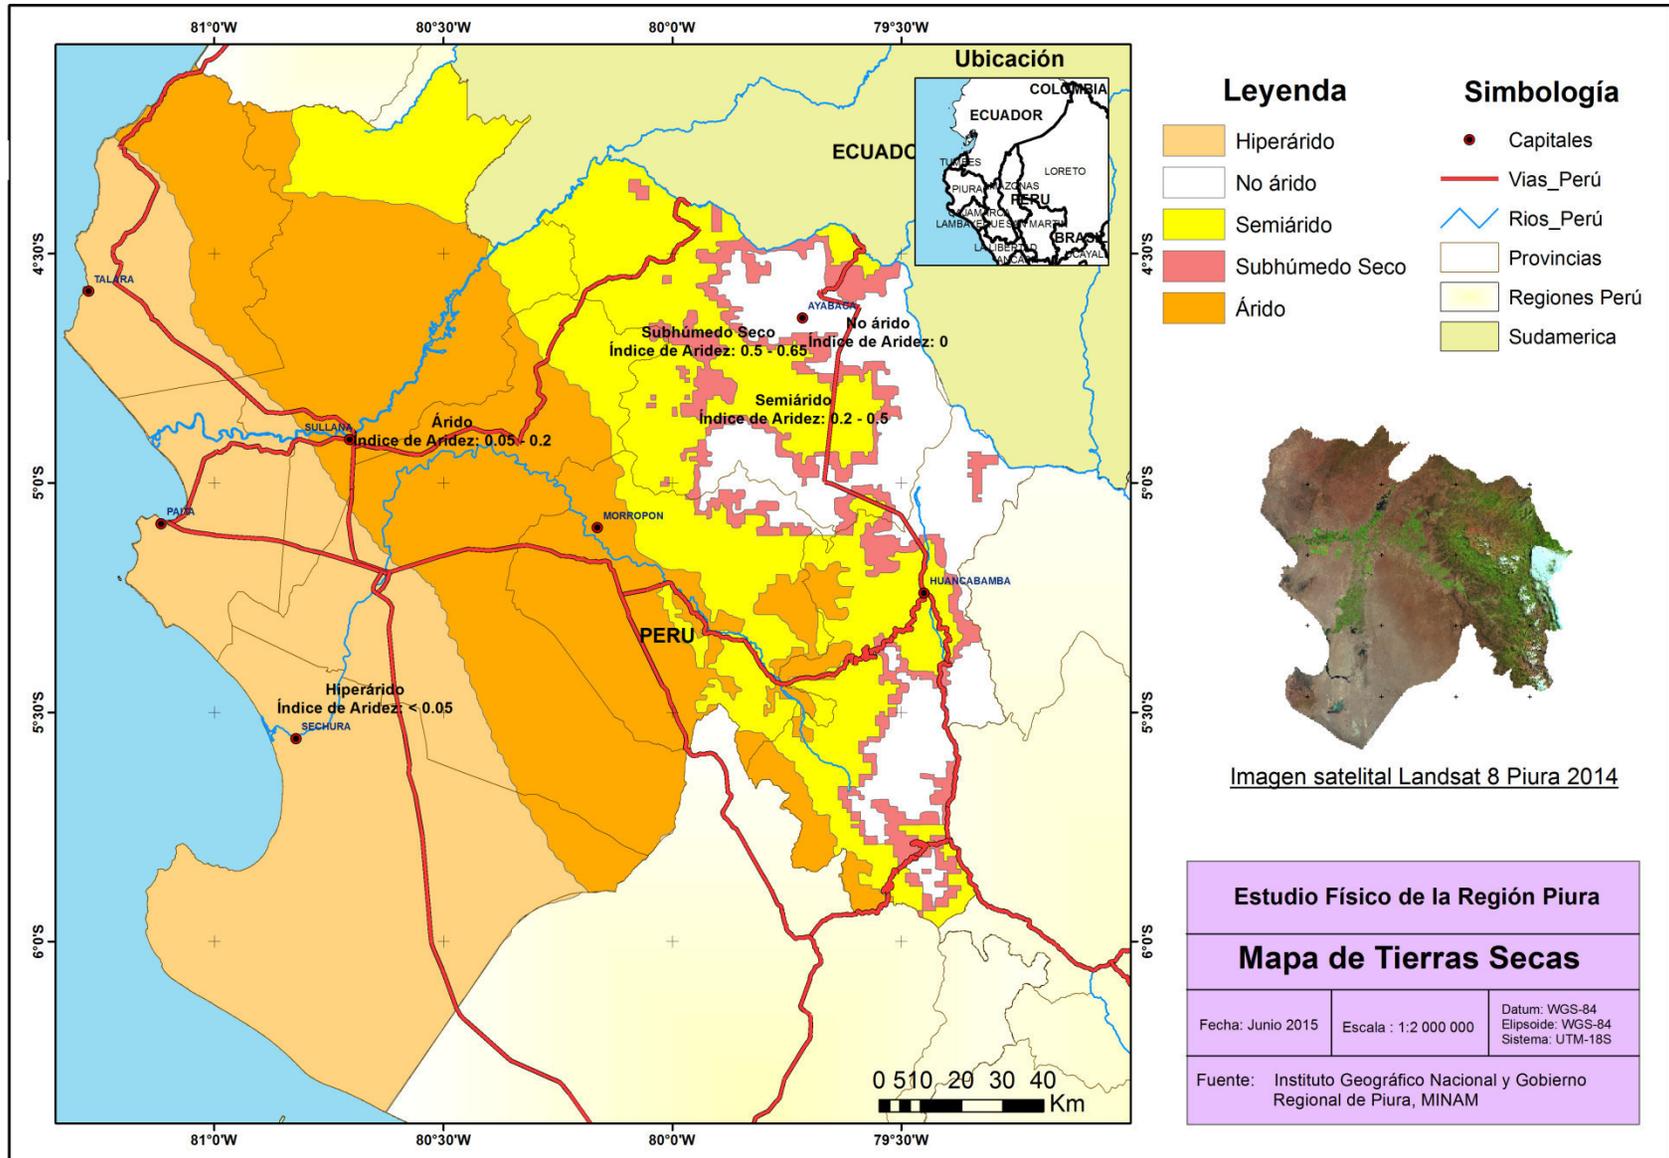
y Mitigación de los Efectos de la Sequía (CNUCLD) ha clasificado las tierras secas o zonas áridas del mundo en cuatro clases: hiperáridas, áridas, semiáridas y subhúmedas secas. La región Piura comprende estas zonas, siendo las primeras (hiperáridas) las de mayor extensión (alrededor del 32% de la superficie departamental) (Willems, 2014) (Tabla 3-1), de acuerdo al mapa de tierras secas a escala 1:2 000 000 (MINAM, 2012) (Figura 3-6).

CATEGORÍAS DE TIERRAS SECAS	ÍNDICE DE ARIDEZ $I_a = P_a/ET_0$	EXTENSIÓN	
		Hectáreas	% del Territorio Regional
Hiperárida	< 0.05	1 186 169.00	32.89
Árida	0.05 - 0.20	1 184 675.00	32.85
Semiárida	0.20 – 0.50	753 286.00	20.89
Subhúmeda Seca	0.50 – 0.65	145 334.00	4.03
Tierras no Secas	>0.65	337 045.00	9.35
Total Tierras secas Piura		3269464.00	90.65
Área total de Piura		3 606 509.00	100.00

Tabla 3-1. Índice de aridez y extensión de tierras secas de la Región Piura, estimados a partir del mapa de tierras secas del MINAM (Willems, 2014).

Las zonas hiperáridas se caracterizan por una baja e irregular precipitación (la variación interanual puede ser del 100%) y escasa vegetación perenne, lo que hacen de la agricultura y pastoreo actividades prácticamente inviables. Por su parte, las zonas áridas se caracterizan por registrar precipitaciones anuales entre 80-150 y 200-350 mm, con una variación interanual entre el 50% y 100%. Las zonas semiáridas tienen una precipitación anual de 300-400 y 700-800mm en verano y de 200-250 a 450-500mm en invierno. Bajo estas condiciones climáticas es posible el pastoreo y la agricultura de regadío, aunque con gran variabilidad en las producciones. Finalmente, las zonas sub-húmedas secas tienen una variabilidad interanual de precipitación menor a 25% y la agricultura puede practicarse de manera regular (Willems, 2014).

Predicción de Tierras Degradadas a Partir del Análisis de Series Temporales del Índice Mejorado de Vegetación y Temperatura de superficie de Suelo mediante Imágenes MODIS
 - Caso Estudio Piura

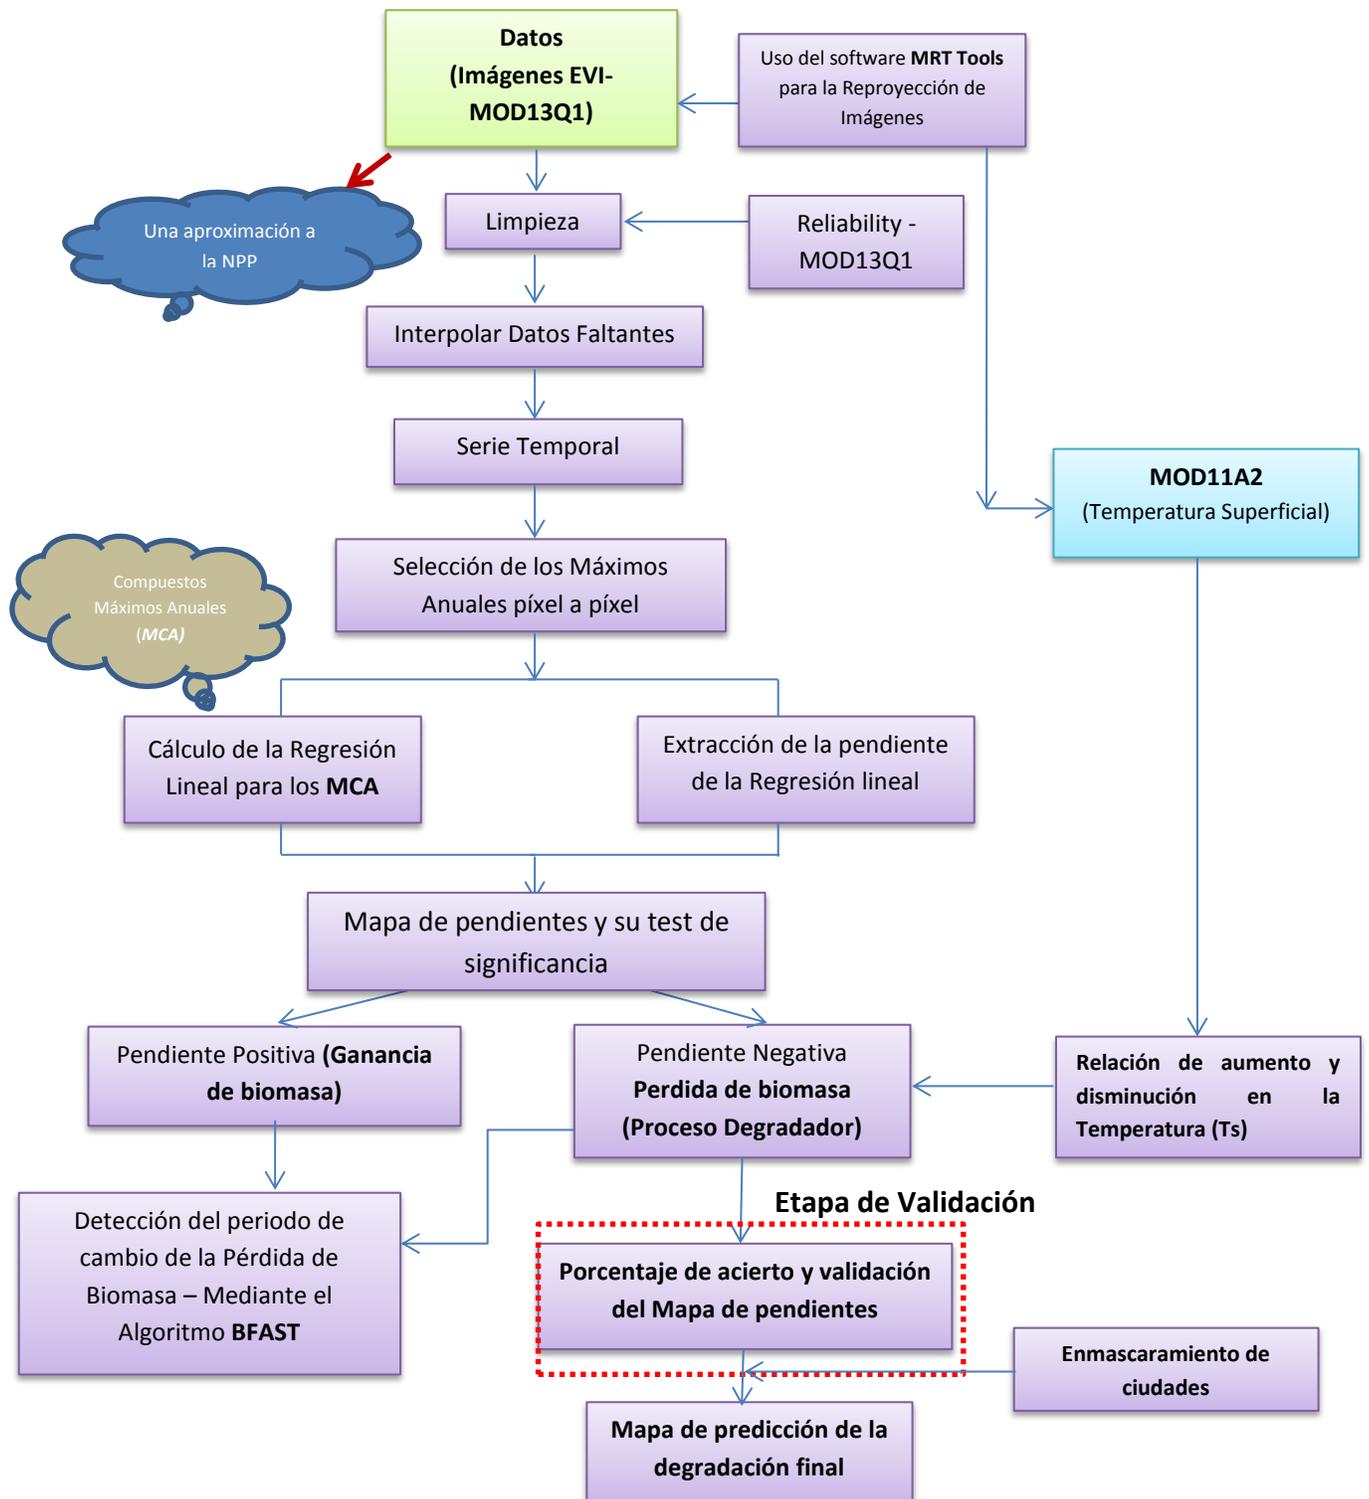


Mapa 3-6. Mapa de Tierras Secas de la Región de Piura (Adaptado de: MINAM, 2012)

CAPITULO IV

DATOS Y METODOLOGÍA

4. DATOS Y METODOLOGÍA



Esquema 4-1. Metodología para la detección y cuantificación de la degradación.

Existen diferentes productos obtenidos a partir de las imágenes MODIS. En este estudio utilizamos algunos de los productos enfocados al estudio de las cubiertas terrestres (MODLAND) obtenidos con el satélite Terra. La descripción desarrollada de los productos se encuentra en el Capítulo 2 de esta tesis. Los datos MODIS utilizados en el presente estudio fueron:

- Índices de vegetación (MOD13Q1).
- Temperatura superficial (MOD11A2).

4.1 Índice Mejorado de Vegetación (EVI)

El Índice Mejorado de Vegetación (Mod13Q1.005) fue utilizado, como variable biofísica - indicador como una aproximación a la Productividad Primaria Neta (Prince, 1991), siendo la definición de este último el crecimiento de la vegetación por unidad de área y por unidad de tiempo (NPP), ya que existe una relación casi lineal entre el NPP y el NDVI en praderas tropicales, tierras de cultivo y bosques dispersos (Fensholt et al., 2006). Para la detección y cuantificación de la degradación de la tierra, los **tiles** que abarcan el área de estudio fueron: h09v09 y h10v09 (Fig. 4-2). Estos fueron **mosaiqueados** y recortados según la región estudiada. En total se descargaron mosaicos desde el 2001 al 2014, que sería 322 imágenes. Además de los datos del índice Mejorado de Vegetación, una capa de calidad (reliability) fueron mosaiqueados de igual manera para cada periodo de la toma de la imagen.

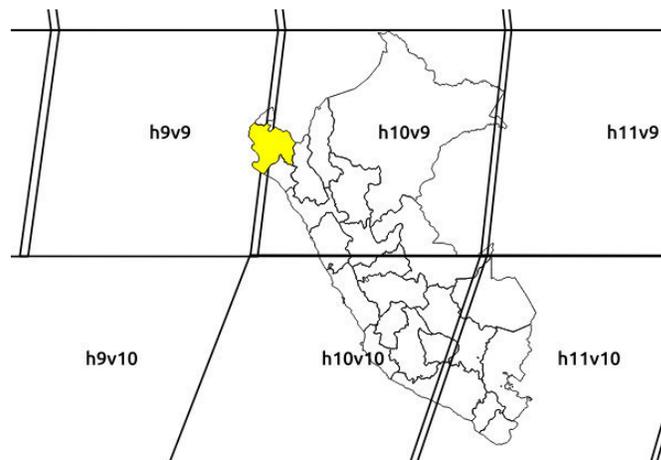


Figura 4-1. Tiles que serán usados para la investigación.

4.2 Datos de calidad MOD13Q1

En la versión 5 de las imágenes MODIS se incorpora una capa de reliability (Figura 4-3) que contiene información resumida sobre la fiabilidad o confiabilidad de los datos, en donde: 0 = Fiable (sin nubes, sin nieve, sin carga atmosférica de aerosoles); 1 = Semi-fiable (sin nubes, sin nieve, el objetivo es visible y las correcciones atmosféricas han mejorado la calidad de los datos); 2 = Nieve (superficie cubierta total o parcialmente por nieve); 3 = Nubes (presencia total o parcial de nubes); 4 = Sin datos (información no procesada por razones diversas) (Kamel Didan). Estas informaciones de calidad se encuentran resumidas en la Tabla 4-1.

Tabla 4-1. Pixel de fiabilidad MOD13Q1

Valor de calidad	Resumen QA	Descripción
-1	Relleno/ sin datos	No procesado.
0	Buenos datos	Use con confianza.
1	Datos marginales	Use, pero mire la información de QA.
2	Nieve/hielo	Objetivo cubierto de nieve/hielo
3	Nublado	Objetivo no está visible, cubierto de nubes.

Debido a que la evaluación de los últimos 6 años de las colecciones de datos MODIS C3 y C4, reveló diferencias insignificantes entre las asignaciones de calidad para NDVI frente al EVI. Productos C5 - MOD13 incluyen una capa única de calidad para ambos índices, en lugar de una capa para cada uno (Tabla 5). Esto reduce el volumen de datos, así como la confusión del usuario con múltiples capas de calidad.

La Tabla 4-2 muestra la relación entre el índice de utilidad VI y los bits de control de calidad obligatorio - Modland. Los píxeles con el valor del índice de 0000 y 1111 siempre tienen los valores de bit Modland QA de 00 y 11, respectivamente. Los bits 6-7 se utilizan para indicar la cantidad de aerosoles, y los bits 8 y 9 indican si una corrección de la corrección de adyacencia y la atmósfera-superficie BRDF acoplados, respectivamente, se aplican o no. Bit 10 indica una posible existencia de nubes mixtas (Ramon Solano, 2010).

Los bits de control de calidad están diseñados para documentar las condiciones bajo las cuales se adquiere y procesa cada píxel. Las imágenes descargadas fueron filtradas utilizando los parámetros de calidad que los propios productos facilitan y que permiten identificar la presencia de nubes, contaminación atmosférica y errores en la adquisición de los datos (Figura 4-4). Antes de los análisis de procesamiento se han utilizado las imágenes filtradas consideradas de buena calidad como recomendación (Roy et al., 2002).

Tabla 4-2.Descripción de los datos de Evaluación de la Calidad IV-QA (Adaptado de: Solano, 2010)

Bits	Nombre del parámetro	Valores	Descripción
0-1	Calidad del IV (MODLAND QA Bits)	00	IV producido con buena calidad
		01	IV producido, pero necesario comprobar otra QA
		10	Píxel producido, pero lo más probable que este nublado
		11	Píxel no producido debido a otras zonas diferentes a las nubes
2-5	Utilidad del IV	0000	De la máxima calidad
		0001	Baja calidad
		0010	Disminución de la calidad
		0100	Disminución de la calidad
		1000	Disminución de la calidad
		1001	Disminución de la calidad
		1010	Disminución de la calidad
		1100	La calidad más baja
		1101	Calidad tan baja que no es útil
		1110	Datos L1B defectuosa
		1111	No es útil para cualquier otra razón/ no procesada
6-7	Cantidad de aerosol	00	Climatología
		01	Bajo
		10	Intermedio
		11	Alto
8	Nube adyacente detectado	0	No
		1	Sí
9	Corrección BRDF	0	No
		1	Sí
10	Nubes mixtos	0	No
		1	Sí
11-13	Terreno/máscara de agua	000	Océano superficial
		001	Tierra (nada más que tierra)
		010	Las costas del océano y las costas del lago
		011	Aguas continentales someras
		100	Agua efímero
		101	Aguas continentales profunda
		110	Océano moderado o continental
		111	Océano profundo
14	Posible nieve/hielo	0	No
		1	Sí
15	Posible sombra	0	No
		1	Sí

Predicción de Tierras Degradadas a Partir del Análisis de Series Temporales del Índice Mejorado de Vegetación y Temperatura de superficie de Suelo mediante Imágenes MODIS - Caso Estudio Piura

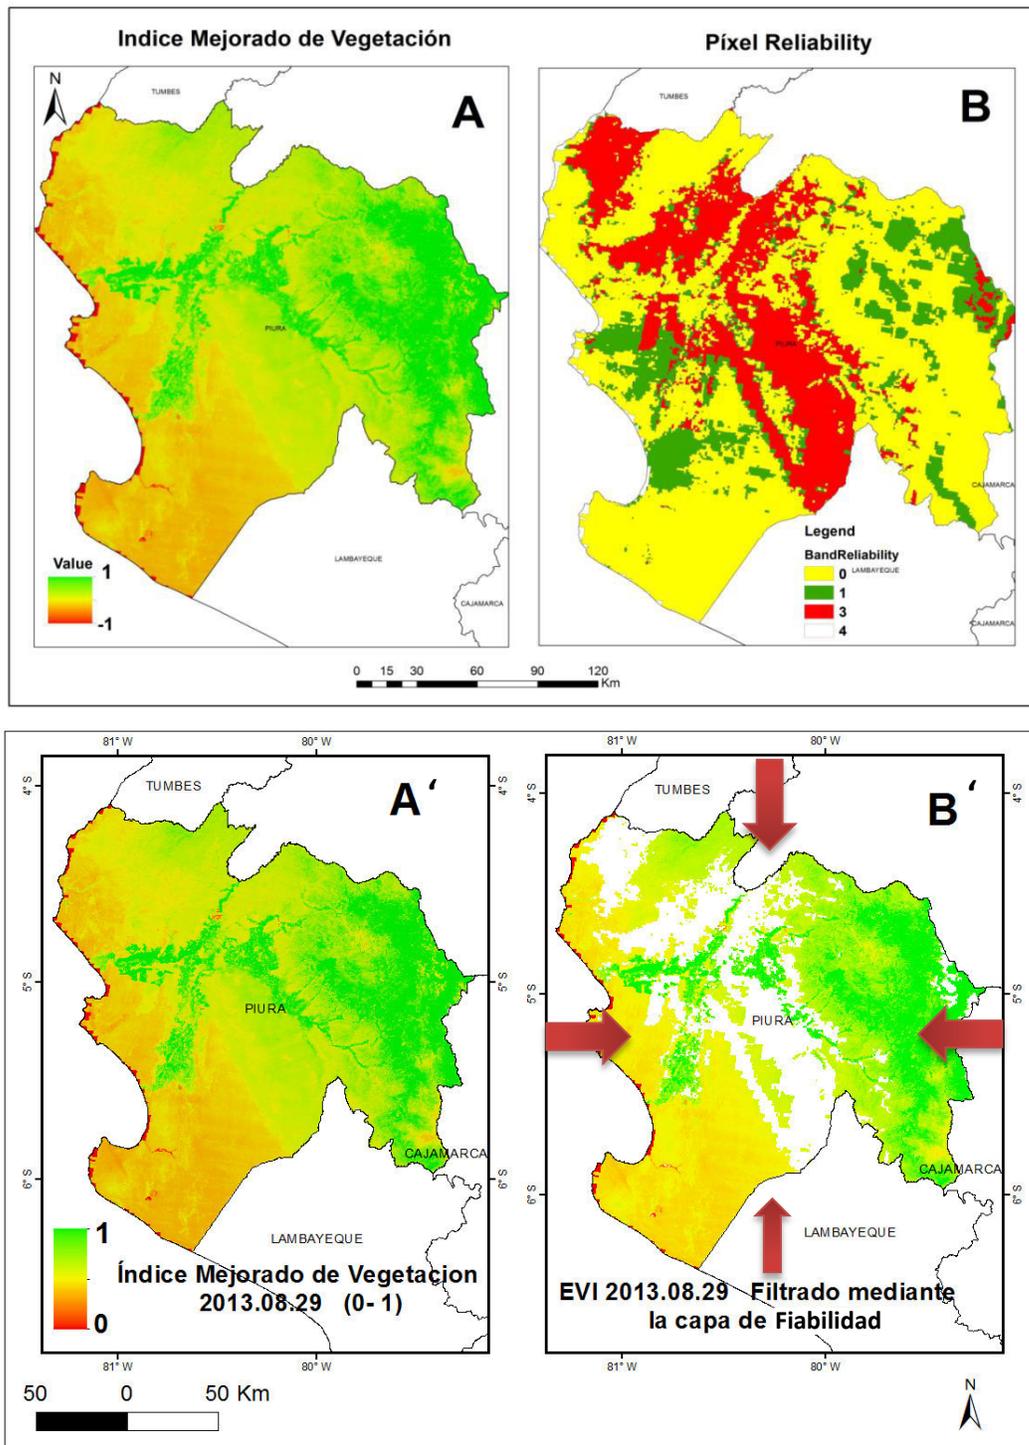


Figura 4-2. Con la banda de fiabilidad (B) se filtra los píxeles sucios como se muestra en la figura (B').

4.3 Interpolación de Datos Faltantes (“NA”)

La interpolación de datos faltantes es una técnica muy usada cuando no tenemos datos y necesitamos rellenar de tal manera que tengamos una serie completa. Hay muchos métodos que permiten interpolar pero la mayoría son métodos que interpolan en un plano x, y- espacio- tiempo. Dentro de estos podemos citar a *Krging*, *IWD*, *Spline*. La mayoría de usuarios usan estos métodos, por ejemplo, para interpolar curvas de nivel de tal manera que tengamos un Modelos de Elevación Digital, u otros de repente interpolan datos de precipitación para tener un grid de píxeles en formato raster. Todas estas interpolaciones se realizan en una dimensión –espacio-, pero qué hay de la dimensión -tiempo-. Se necesita entonces una metodología que interpole en dos dimensiones 1) espacio y 2) tiempo (Figura 4-4). La primera porque cada píxel de 250m ocupa un espacio en la tierra y lo segundo porque tenemos 322 imágenes como una serie de temporal (tiempo).

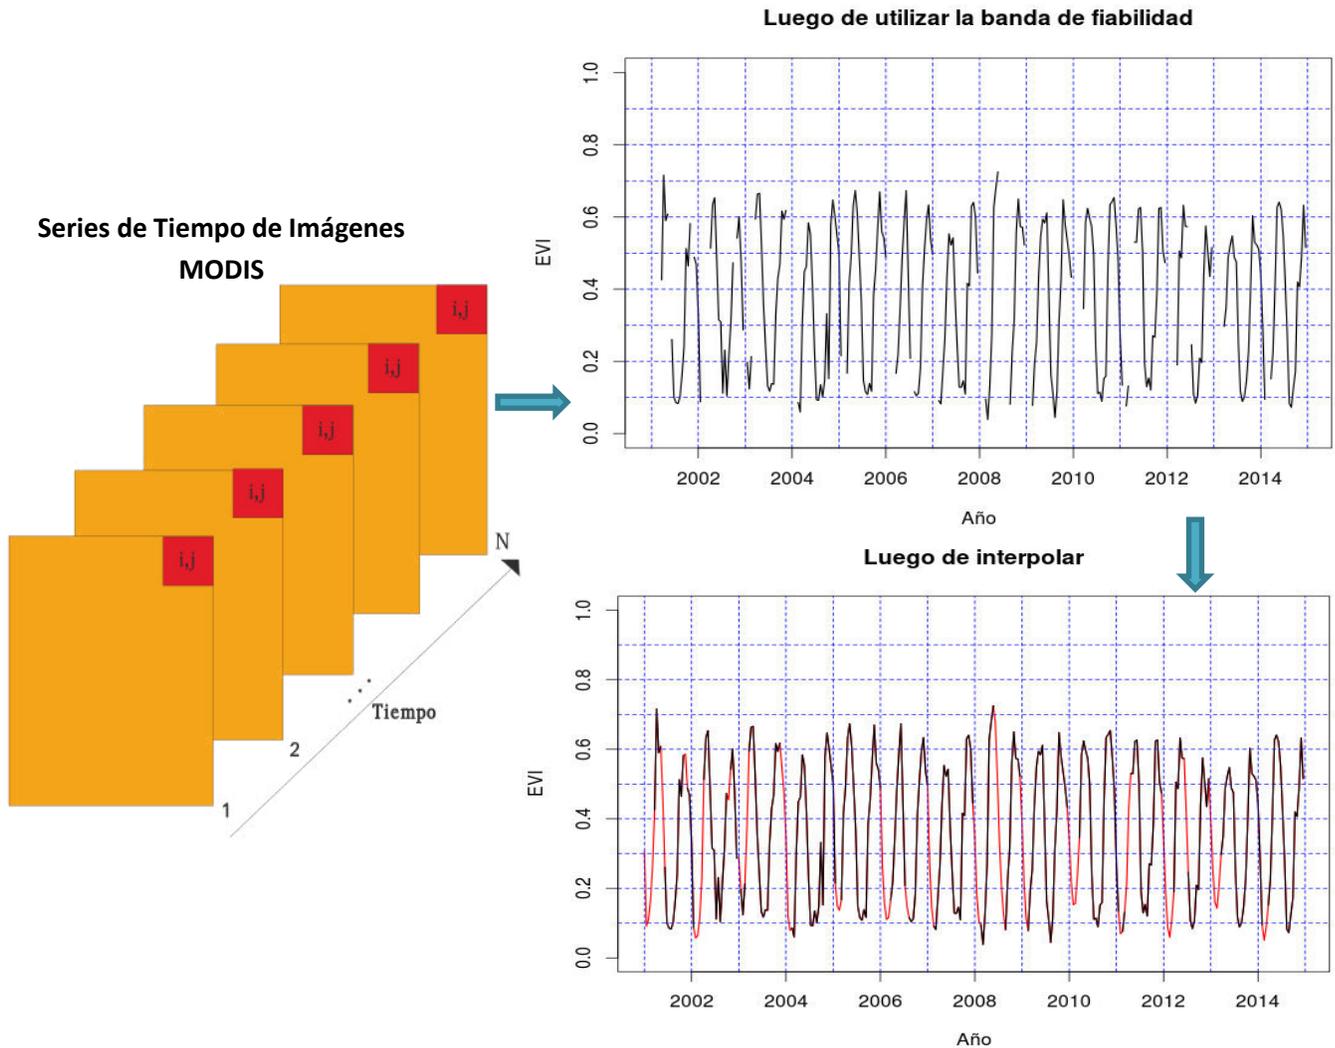


Figura 4-3. Metodología de la interpolación de datos faltantes “NA” al utilizar la banda de confiabilidad.

De lo anterior es necesario contar con un método de interpolación que trabaje en base al componente estacional de una serie temporal. Dicho de otro modo, el corazón de la interpolación será el tiempo. Dentro de las bondades que ofrece R como lenguaje de programación, se ha usado el paquete "forecast". Dentro de este paquete hay un algoritmo "na.interp" que permite aproximar datos faltantes en una serie temporal. *La precisión y la matemática que hay detrás de este algoritmo de interpolación no es objeto de estudio*, lo que sí se puede afirmar es que no se ha encontrado otro método que interpole (en espacio y tiempo) con una aproximación muy cercana a lo real.

4.4 Máximos Compuestos Anuales de EVI

La disponibilidad de algoritmos complejos que detectan perturbaciones en las series temporales trabaja con los componentes propios de las series, como la tendencia, la estacionalidad y la minimización del ruido aleatorio. Pero de alguna manera eliminar la componente estacional maximiz-

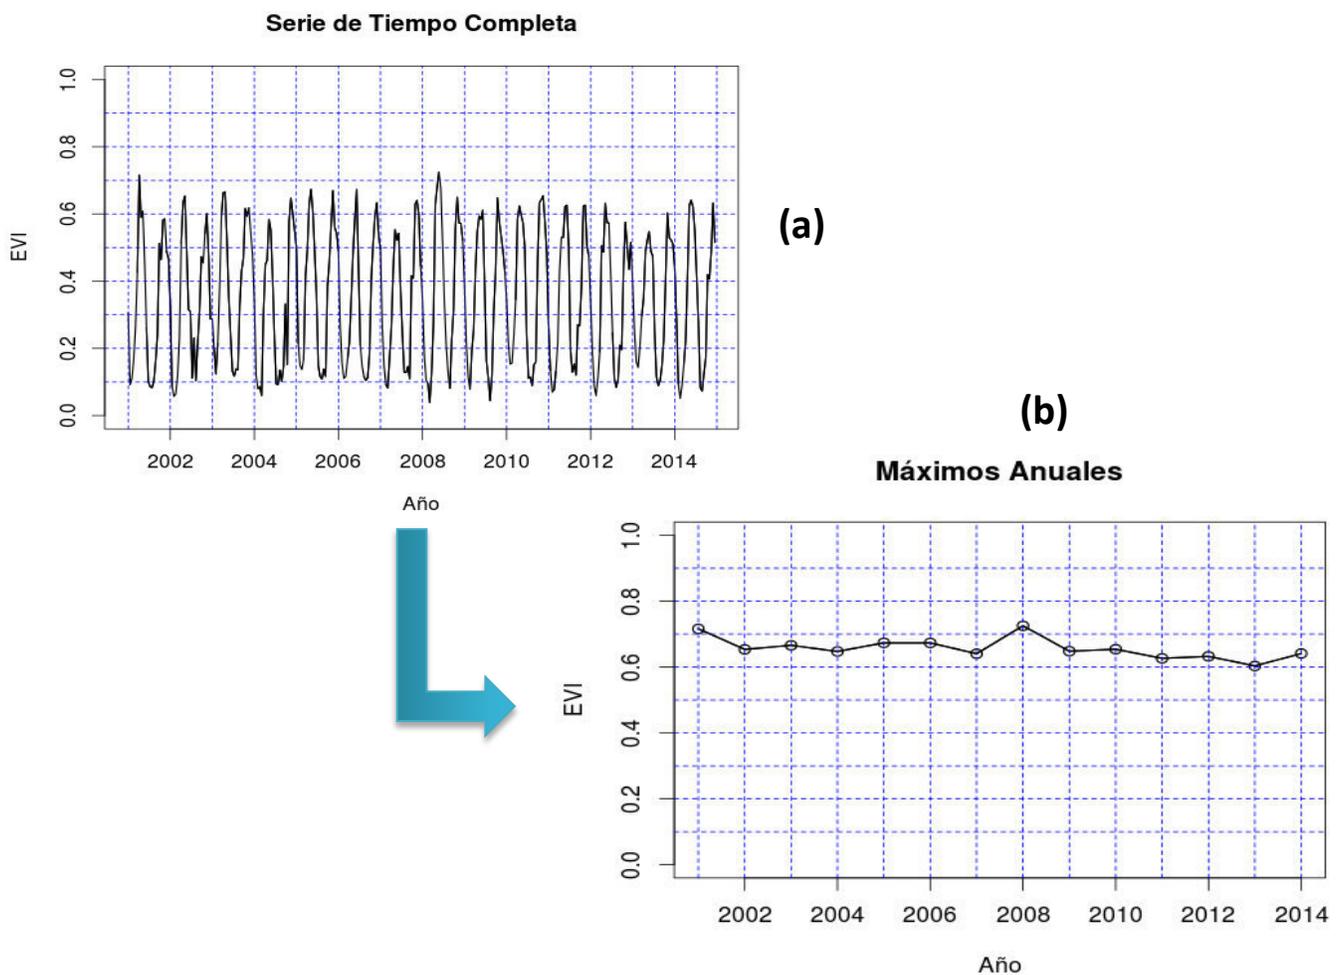


Figura 4-4. En la figura se muestra que los Máximos Compuestos Anuales (b), son datos donde se ha eliminado la componente estacional. Se aprecia con más precisión la pérdida o ganancia de la biomasa.

a la posibilidad de detectar con mayor precisión el comportamiento de las perturbaciones que dan origen a la degradación de la tierra. Por ello se ha empleado los **Máximo Compuestos Anuales** (Figura 4-5) o máximo anuales como “concepto metodológico” que nos ayude a detectar posibles zonas degradadas. En la Tabla 4-1 podemos apreciar las ventajas y desventajas de usar los MCA según Holben (1986).

Tabla 4-3. Información general de las principales ventajas y desventajas de los principales suavizadores a los índices biofísicos.

Procedimiento	Qué hace	Ventajas	Desventajas
Máximos Valores Compuestos (MVC)	Se identifica el valor más alto para el NDVI o EVI para un periodo y zona determinada (Holben, 1986).	Sin modelado. Funciona bien porque la mayoría de los errores son negativos y se ha eliminado la estacionalidad (Holben, 1986).	Podrían estar contaminados por la cobertura de nubes (Holben, 1986).
Ajuste de curvas	Funciones polinómicas o de Fourier se ajustan a las series de tiempo del EVI o NDVI (Van Dijk, 1997).	La trayectoria se puede predecir y la serie de tiempo se puede resumir en varios índices vinculados a la función (Van Dijk, 1997).	El Análisis de Fourier puede caracterizar cada trayectoria anual del NDVI; pero están afectadas por un sesgo, por tanto, falsas bajas o altas afectan la modelización de la serie (Van Dijk, 1997).
Regresión logística escalonada	Una serie de funciones logísticas a trozos se utilizan para representar la dinámica de la vegetación interanual. Se estiman cuatro fechas clave de transición: verde-up, la madurez (la fecha en que el área de la planta de hoja verde es máxima), la senescencia y la latencia (Zhang, X. et al., 2003).	Debido a que el método trata cada pixel individual sin establecer umbrales o constantes empíricas, es aplicable a nivel mundial; que permite a los tipos de vegetación exhibir múltiples modos de crecimiento y senescencia dentro de un solo ciclo anual (Zhang, X. et al., 2003).	Fuertemente afectada por las falsas bajas y altas en los valores (Zhang, X. et al., 2003).
Mejor Método de extracción de Slope Index (BISE)	Observaciones del NDVI son juzgados como confianza y no dependiendo de si la tasa de cambio en el NVDI es plausible (Viovy, N. et al., 1992).	El algoritmo es robusto en falsos máximos que provocan aumentos rápidos inverosíblemente en el NDVI (>0.01 en el valor de NDVI por día) (Viovy, N. et al., 1992).	El punto de este método sensible es estimar correctamente en qué medida un tasa de cambio en el NVDI es plausible (Van Dijk, 1997), según la resolución temporal en estudio (Viovy, N. et al., 1992).

Los Máximos Compuestos Anuales son los valores máximos en una serie histórica de valores de un año, es decir, el valor más alto para un periodo considerado (Holben, 1986). Las imágenes EVI del producto MOD13Q1-MODIS están cada 16 días. Al año hay un total de 23 imágenes. Dentro de estas 23 imágenes habrá una fecha en donde los valores del índice fue el máximo, esta es la lógica para encontrar los máximos anuales pero píxel a píxel. Para lograr encontrar los máximo anuales píxel a píxel se utilizó R como lenguaje de programación.

4.5 Pendiente de la regresión lineal de los Máximos Compuestos Anuales

Por cada año de recopilación de datos MODIS hubo 23 períodos que se filtraron utilizando el resumen de fiabilidad pixel a pixel de tal manera que sólo la mejor calidad de (bandera de calidad de 0 o 1) píxeles fueron retenidos para su posterior análisis y el resto fue rellenado mediante interpolación en las series de tiempo. A partir de estos datos MODIS, un valor máximo del índice mejorado de vegetación (Holben, 1986) fue elegido entre los 23 puntos (máximo valor de composición) y sirvió como un indicador de la producción de la vegetación (Bai et al., 2008), una vez identificado el máximo valor anual de 23 datos, se utilizó la pendiente de una regresión lineal como indicador de la tendencia de la pérdida (proceso degradador) o ganancia de biomasa.

Es sabido que la pendiente en una regresión lineal nos da la inclinación de un conjunto de puntos que están correlacionados. Ésta pendiente desde el punto de vista matemático puede ser positiva o negativa. El análisis de la pendiente de una regresión lineal es muy usada para estudios de monitoreo de la pérdida de biomasa. La lógica es muy simple- una tendencia decreciente (Figura 4.7) paulatina de la variable biofísica indica una pendiente lineal negativa, en este caso indica un proceso degradador, es decir, se trata de una pérdida en la biomasa. Por otro lado, una tendencia creciente (Figura 4.8) paulatina o abrupta de la variable biofísica indica una pendiente lineal positiva, en este otro caso indica un incremento en la extensión agrícola o un mejoramiento en la cobertura de la tierra.

De lo anterior. Utilizar modelos de regresiones lineales es –“un cercano cumplimiento del proceso físico real de cambio de la cubierta de la tierra en el suelo”-. Estos modelos regresionales van a permitir detectar, la magnitud y tiempo de cambios en la cubierta terrestre píxel a píxel.

Encontrar clases de tipos de regresiones lineales de pérdida de biomasa (Indicación de un proceso degradador) es posible debido principalmente por la magnitud y el valor de la pendiente de la ecuación. Todo ese proceso para cada píxel de la zona de estudio, se hace bastante simple si se realiza en cualquier lenguaje de programación. Para esta investigación se ha empleado R libre y de código abierto.

Como se aprecia en la Figura 4-6. La ecuación (4.1) puede mostrar la tendencia de los MCA en la cual, el factor b será el indicador de la tendencia.

$$f = a + bx \quad (4.1)$$

f: La función de degradación

x: año

a: Intercepto

b: Parámetro o influencia asociada a la variable independiente

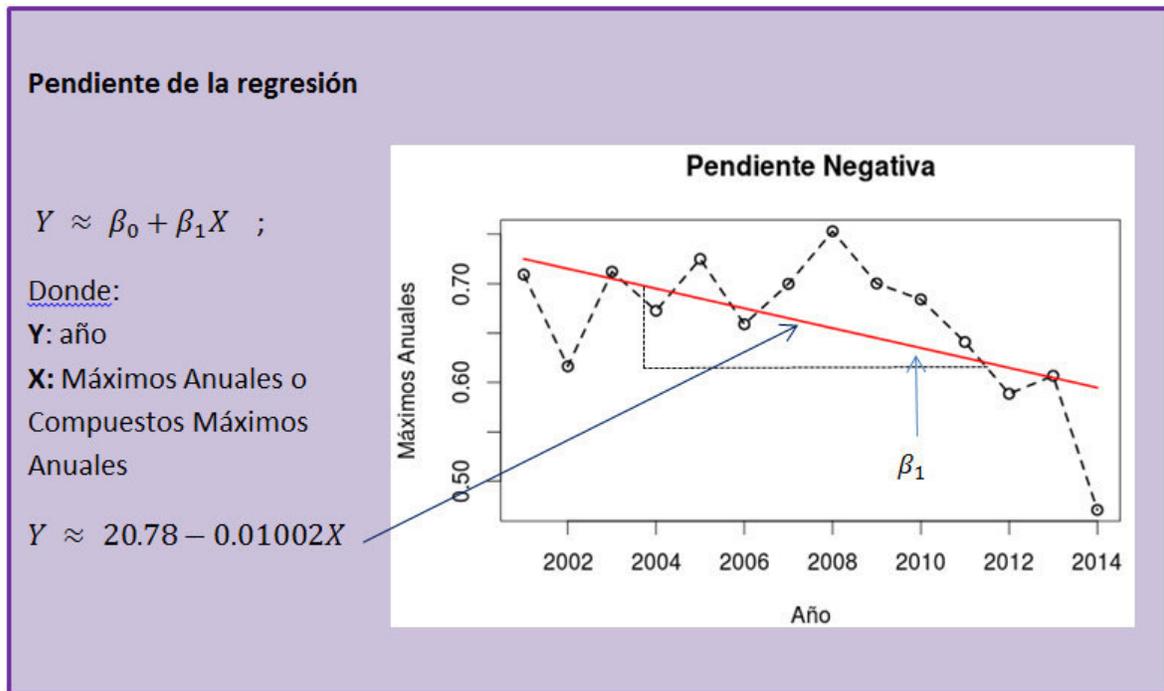


Figura 4-5. β_1 es la pendiente – indicador del proceso degradador.

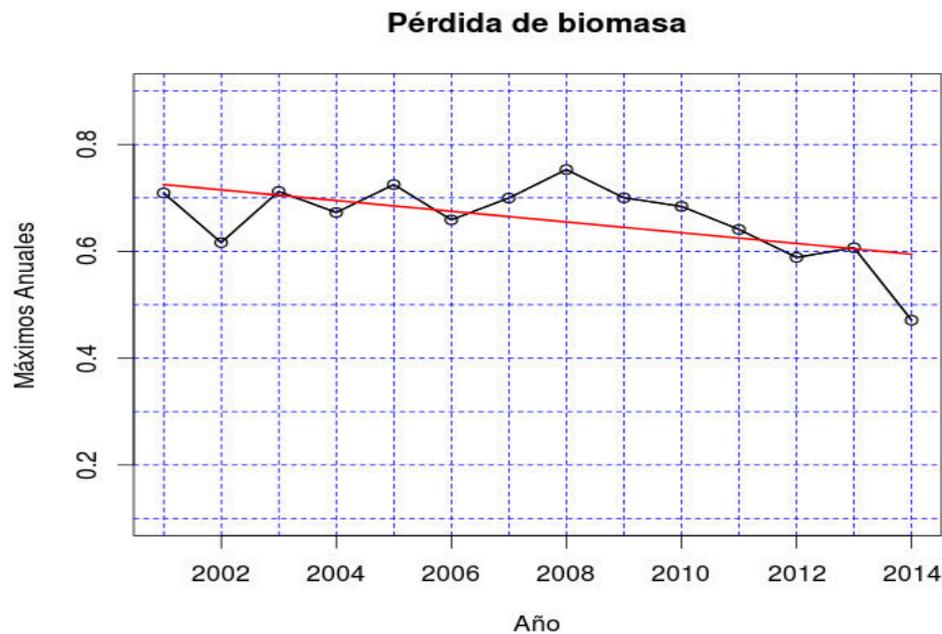


Figura 4-6. Figura que muestra para el píxel i, j la pendiente de la regresión lineal. Es una pendiente negativa lo que indica, un decrecimiento gradual de la variable biofísica (pérdida de biomasa).

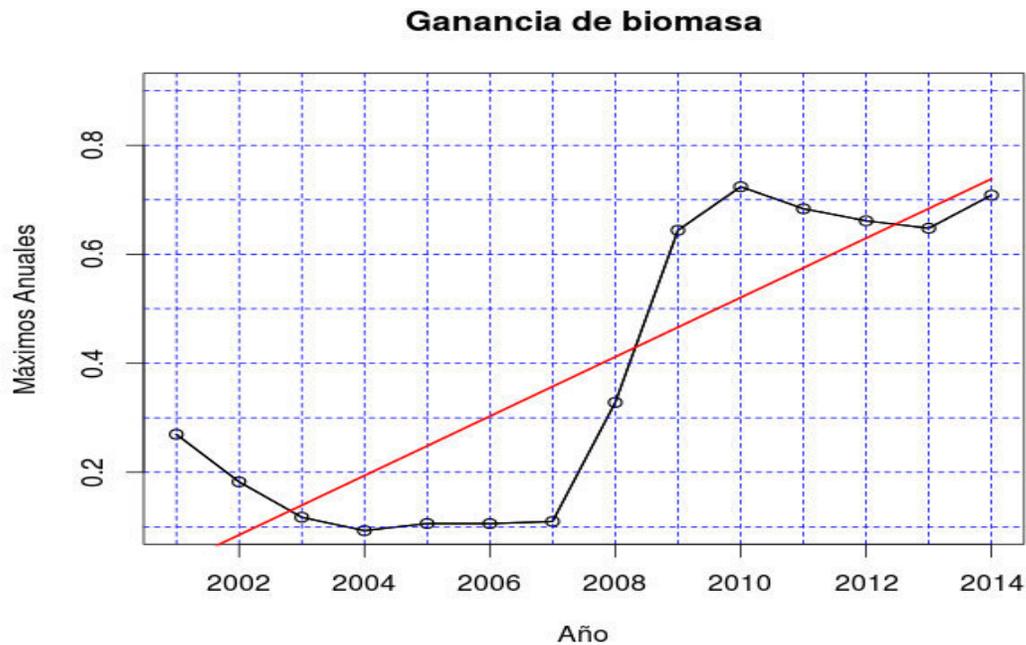


Figura 4-7. Figura que muestra para el píxel i, j la pendiente de la regresión lineal. Es una pendiente positiva lo que indica, crecimiento abrupto de la variable biofísica (incremento de la biomasa).

4.6 Procesamiento de las imágenes MOD11A2

Para el caso de las imágenes de temperatura de superficie de suelo que tienen una resolución de 1km, se seleccionó aquellas libres de nubes o en lo posible libre de artefactos atmosféricos una imagen por año. No se pudo aplicar los máximos anuales como en el caso del índice EVI, porque la descarga fue incompleta, faltando algunos de ellos en los meses de enero y febrero y en algunos julio y agosto por lo que seleccionar los máximos no fue lo idóneo. Por ello se seleccionó imágenes en lo posible de temporadas secas y en base a ellas se extrajo las pendientes de las regresiones lineales.

4.7 Identificación del Inicio del proceso degradador

Para la identificación del inicio del periodo de pérdida de biomasa o proceso degradador, usaremos el algoritmo, Rupturas en Tendencia y Estacionalidad Aditivas (Verbesselt et al., 2010), usando el paquete **bfast** de R y la función **BFAST** disponible en <http://bfast.r-forge.r-project.org/> (accedido el 23.07.2014). En el capítulo 2 se hizo una descripción metodológica de este algoritmo muy robusto para la detección de cambio – abrupto y gradual de detección de cambio en la estacionalidad o también llamado *breakpoints* en series de tiempo (Zeileis, 2011). Detectar el inicio del periodo en que comienza la pérdida de biomasa es complejo si queremos identificarlo usando los Compuestos Máximos Anuales, ya que muchos algoritmos de detección de cambio requieren de muchos datos (por lo menos 20 o 30). Se ha intentado identificar *breakpoints* con los MCA y BFAST (Verbesselt et al., 2010), pero no se logró resultados. Para dar solución a este problema, se ha trabajado con las series de tiempo completas, es decir, se ha usado las 322 imágenes desde el periodo 2001-2014. Antes de aplicar el algoritmo **BFAST**, se ha suavizado las series mediante promedios móviles de orden 5. La suavización de las series de tiempo es necesaria antes de realizar cualquier proceso de análisis. La razón del suavizamiento es eliminar atipicidades o valores anómalos que pudieran afectar al análisis posterior. Una vez aplicado el suavizamiento de las series de tiempo pixel a pixel se aplicó el algoritmo. Con **BFAST** encontraremos *breakpoints* o puntos de ruptura dependiendo del comportamiento de la serie. Si hay disminución o aumento en los valores de la variable biofísica, entonces **BFAST** los identificará mediante regresiones robustas los *breakpoints* tal como se puede ver en las Figuras 4.9 y 4.10.

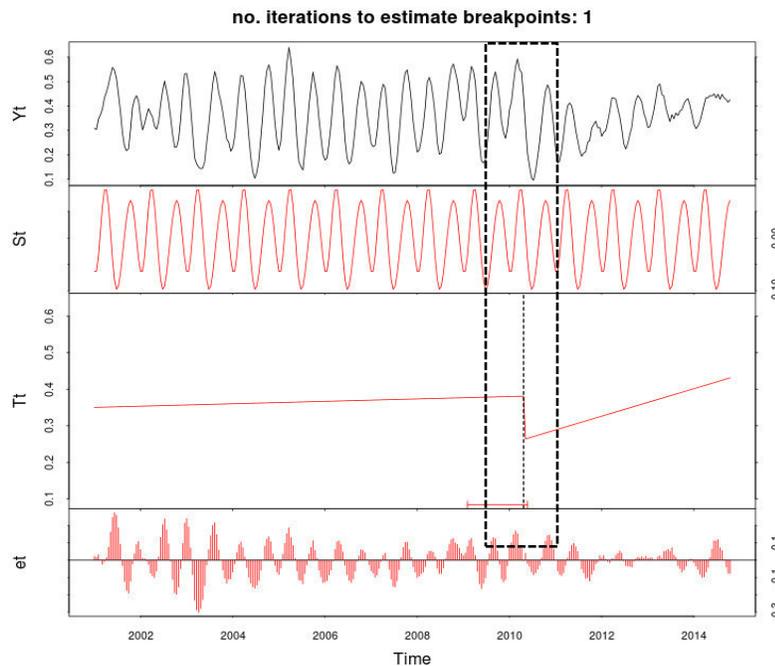


Figura 4-8. Bfast detectó una ruptura en la tendencia de la serie de tiempo. El periodo de cambio ocurrió en el 2010 en adelante.

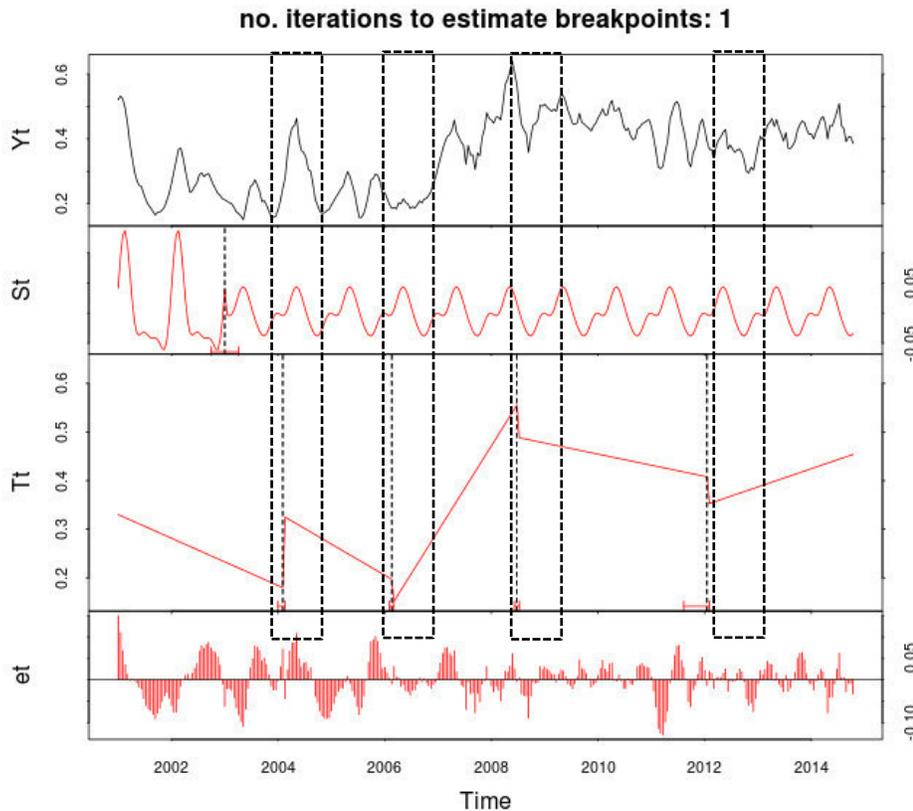
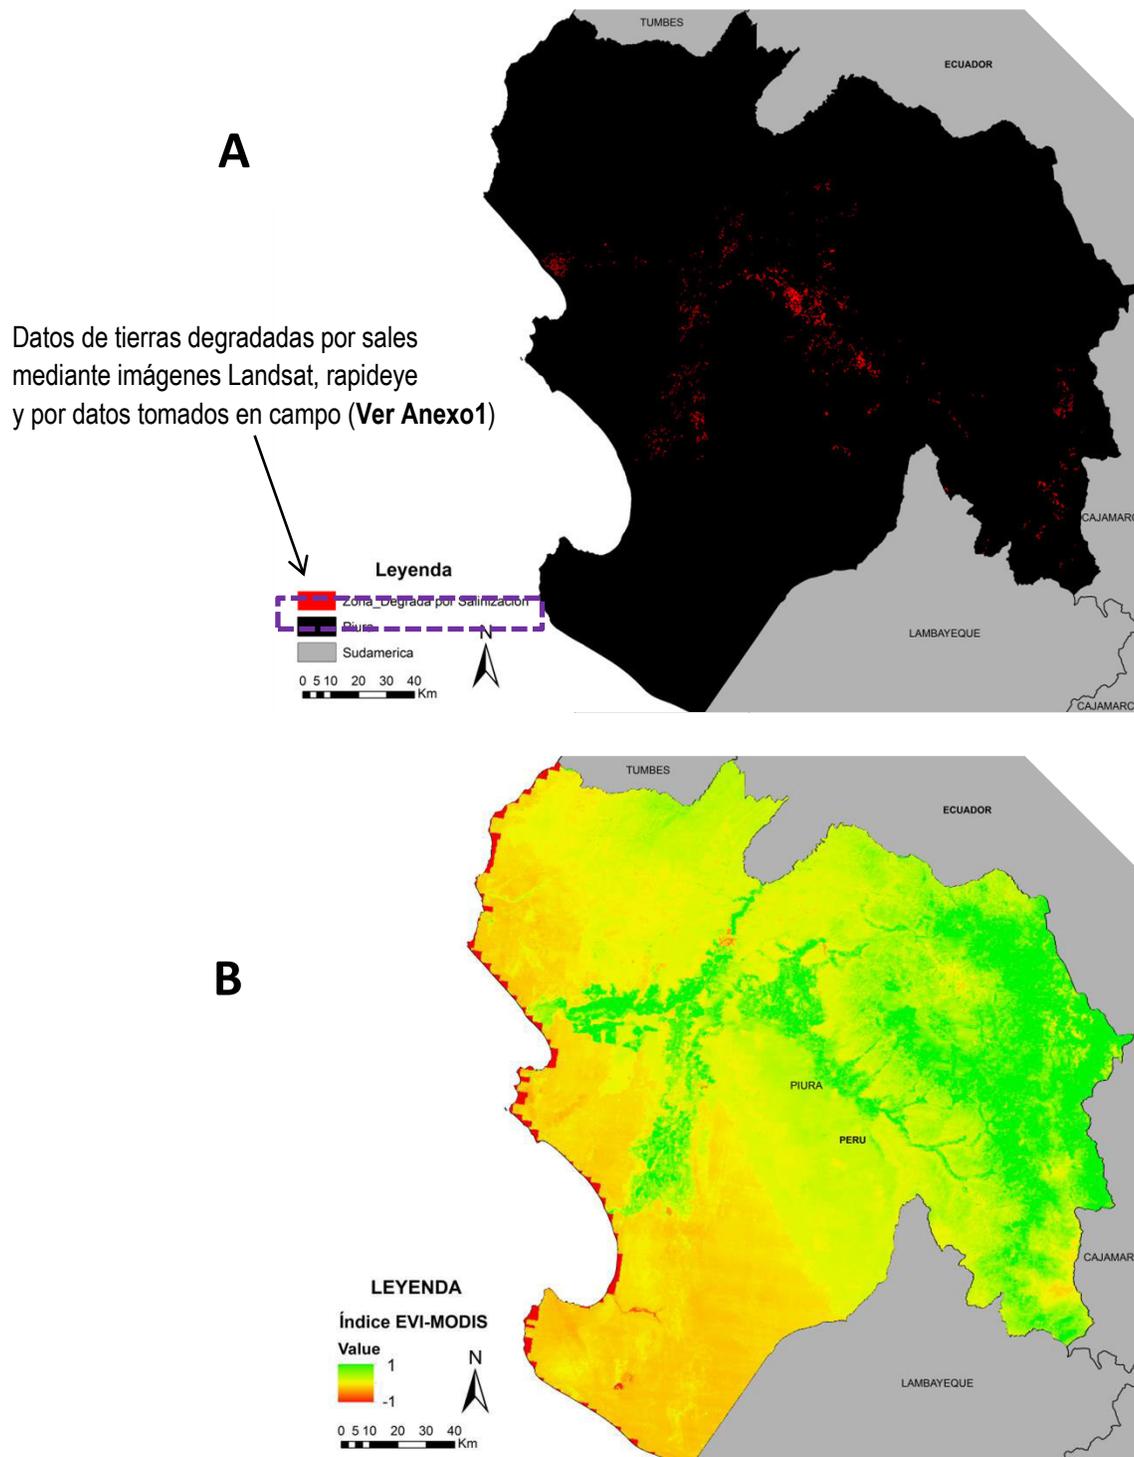


Figura 4-9. Bfast detectó cuatro periodos de cambio, esto da a entender que es una serie compleja en donde hubo subidas y bajadas de la variable biofísica.

En la Figura 4.10 **BFAST** encontró cuatro rupturas a lo largo de la serie de tiempo. El razonamiento del presente estudio es simple. A lo largo de la serie de tiempo, **BFAST** encontrará probablemente más de un *breakpoint*, es decir, la serie de tiempo en momentos será estable, presentará una caída en los valores del índice, luego posiblemente recupere la caída y pasado un determinado tiempo, dependiendo de las perturbaciones, nuevamente tendrá una caída indicando una disminución en la biomasa- lo cual es un indicador de que hay un proceso degradador. De todo lo mencionado, nos interesa analizar el primer *breakpoint* de la serie de tiempo (si es que lo hay), ya que encontrar los periodos de cambio nos dará una noción sobre cuándo comienza el proceso de degradación de la tierra.

Entonces se acondicionó el algoritmo **BFAST** mediante **R** para detectar el último periodo de pérdida o ganancia de biomasa. Dentro de las bondades que el algoritmo nos da, no hay ninguna opción que permita separar cambio negativo de los positivos, por ello solo se tendrá un mapa con el último periodo de pérdida o ganancia de biomasa (Decrecimiento del índice o crecimiento del mismo).

4.8 Validación de los resultados



Mapa 4-1. En la imagen A se muestra los datos disponibles de salinización tomados con imágenes de alta resolución y datos de campo. Estos datos permitirá la comprobación del resultado final.

Una vez identificados las pendientes de las regresiones lineales píxel a píxel, es necesario mostrarlo en un mapa de pendientes. Este mapa generado será el resultado final de la detección y cuantificación de la degradación que tiene que ser validado por datos tomados en campo y con imágenes de mediana y alta resolución.

4.9 Datos obtenidos con imágenes Landsat, Rapideye y Campo.

Se cuenta con datos tomados en campo y con información disponible sobre degradación por salinización (Figura 4.11 A) de áreas degradadas por salinización generadas con imágenes de alta resolución como Landsat y Rapideye, a su vez estos datos obtenidos mediante imágenes de satélite fueron validados mediante visitas realizadas en campo (**para más detalle ver Anexo 1**).

La comprobación de los resultados de la metodología presentada (Mapa de pendientes de la regresión lineal de los MCA) será bastante simple. Primero -por un lado-, la idea es encontrar cuánta área se superponen (intersección entre el mapa final de pendientes negativas y los datos disponibles), de manera que la intersección respecto al total de áreas obtenidas con imágenes de alta resolución y validados en campo, nos dará el porcentaje de acierto.

4.10 Códigos en R empleados en la metodología

```
# DESCARGA DE IMAGENES MODIS Y REPROYECCION DEL SISTEMA DE COORDENADAS

setwd("/home/yonatan/modis")
source('ModisDownload.R')
library(raster)
library(RCurl)
library(knitr)

source('ModisDownload.R')
path<-"/home/yonatan/modis"
input<-list.files(path, "*.hdf", all.files=T, recursive=T)
for(i in 1:length(input)){
  outname<-paste(substr(input[[i]],1,17), ".tif", sep='')
  reprojectHDF(hdfName=input[i], filename=outname, MRTpath="/home/yonatan/MRT/bin",
    bands_subset = '1 1 1 1 0 0 0 0 0 0 0', resample_type=
    "NEAREST_NEIGHBOR", proj_type="GEO", proj_params =
    '0 0 0 0 0 0 0 0 0 0 0 0 0 0 0', datum='WGS84',
    pixel_size=0.0022500022500023)
}
```

```
# FILTRANDO LOS PIXELES CON LA BANDA DE FIABILIDAD

{lista_evi<-list.files("/home/yonatan/MOD13Q1_2014", "Gapp.tif", all.files=T,
                      recursive=T, full.names=F)
lista_reliability<-list.files("/home/yonatan/MOD13Q1_2014", "reliability.tif", all.files=T,
                              recursive=T, full.names=F)

datos<-stack(lista_evi)
x<-rnorm(299,100,5)
for(m in 1:length(lista_evi)){
  evi<-raster(lista_evi[m])
  fiabi<-raster(lista_reliability[m])
  #evi[(fiabi==2) | (fiabi==3) | (fiabi==4)] <- NA
  evi[ fiabi==255 ] <- x[m]
  writeRaster(evi, paste(substr(names(datos[[m]]), 1, 41), "P3.tif", sep=''))
}

# APILANDO LAS IMAGENES FILTRADAS

{lista<-list.files("/home/yonatan/Mosaico_Piura", "P3.tif", all.files=T,
                  recursive=T, full.names=F)
data<-Stack(lista[23:344])
esc_data<-data/10000
plot(esc_data[[1]])
dim(data)
arre<-as.array(esc_data)

b1<-raster("Mosaic_2014.12.19.250m_16_days_EVI_Piura_filter_Gapp_P6.tif")
b2<-b1/10000}

# GENERANDO LOS MAXIMOS COMPUESTOS POR AÑO

{for(i in 1:dim(data)[1]){
  for(j in 1:dim(data)[2]){
    r<-ts(arre[i,j,], start=c(2001,1), freq=23)
    interpR<-na.interp(r)
    resu<-summary(interpR[300:322])
    max<-getElement(resu, "Max.")
    b2[i,j] <- max
  }
}
writeRaster(b2, 'Compuestos_Maximos_2014_P6.tif', drivename="GTiff")}
```

Predicción de Tierras Degradadas a Partir del Análisis de Series Temporales del Índice Mejorado de Vegetación y Temperatura de superficie de Suelo mediante Imágenes MODIS - Caso Estudio Piura

```
# MAPA DE PENDIENTES Y SU NIVEL DE SIGNIFICANCIA

{b1<-raster("Mosaic_2014.07.12.LST_Day_1km_1_fill_inside.tif")}

for(i in 1:dim(data)[1]){
  for(j in 1:dim(data)[2]){
    r<-ts(arre[i,j,],start=c(2001,1), freq=1)
    try(interpR<-na.interp(r))
    r1<-as.numeric(interpR)
    y<-as.vector(r1)
    x<-1:14
    reg<-lm(y~x)
    b1[i,j]<-anova(reg)$'Pr(>F)'[1]
  }
}

writeRaster(b1,'A_PvalueLST.tif',drivername="GTiff")}

# DETECTANDO BREAKPOINTS CON BFAST

{b1<-raster("Mosaic_2014.12.19.250m_16_days_EVI_Piura_filter_Gapp_P1.tif")
b2<-b1/10000
#sfInit( parallel=TRUE, cpus=4 )
for(i in 1:dim(data)[1]){
  for(j in 1:dim(data)[2]){
    r<-ts(arre[i,j,],start=c(2001,01), freq=23)
    interpR<-try(na.interp(r))
    filtro<-filter(interpR,filter=rep(1/5,5))
    filter<-ts(filtro[3:320],start=c(2001,01), freq=23)
    plot(filter)
    #r1<-ts(interpR[1:138],start=c(2001,01), freq=24)
    #dd<- breakpoints(interpR~1, h = 0.15)
    bfast<-bfast(filter,h=0.15, season="harmonic", max.iter=1)
    rupturas<-bfast$output[[1]]$Vt.bp
    bfasstM<-bfastmonitor(filter, start = c(2006,01))
    plot(bfasstM)
    rup<-bfasstM$breakpoint
    value<- (tail(rup,n=1))
    b2[i,j]<-value
    dd<- try(breakpoints(filter~1, h = 0.15))
    plot(filter)
    lines(confint(dd))
    lines(fitted(dd, col = 4))
    rup<-dd$breakpoint
    value<- ceiling(((14*rup)/322) + 2000)
    m<-try(any(value==2003,na.rm=TRUE))
    if(m==TRUE){
      b2[i,j]<-1
    }else{
      b2[i,j]<-0
    }
  }
}
```

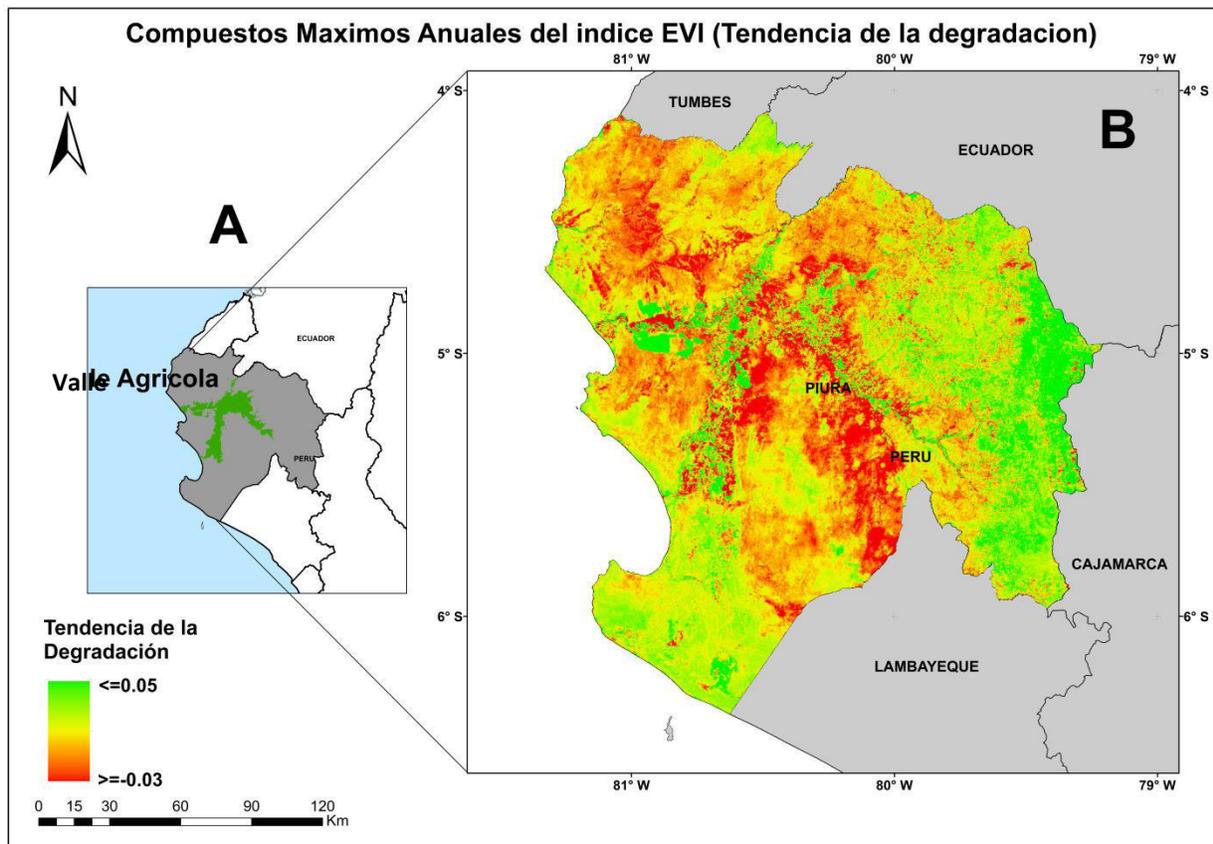
CAPITULO V

RESULTADOS Y VALIDACIÓN

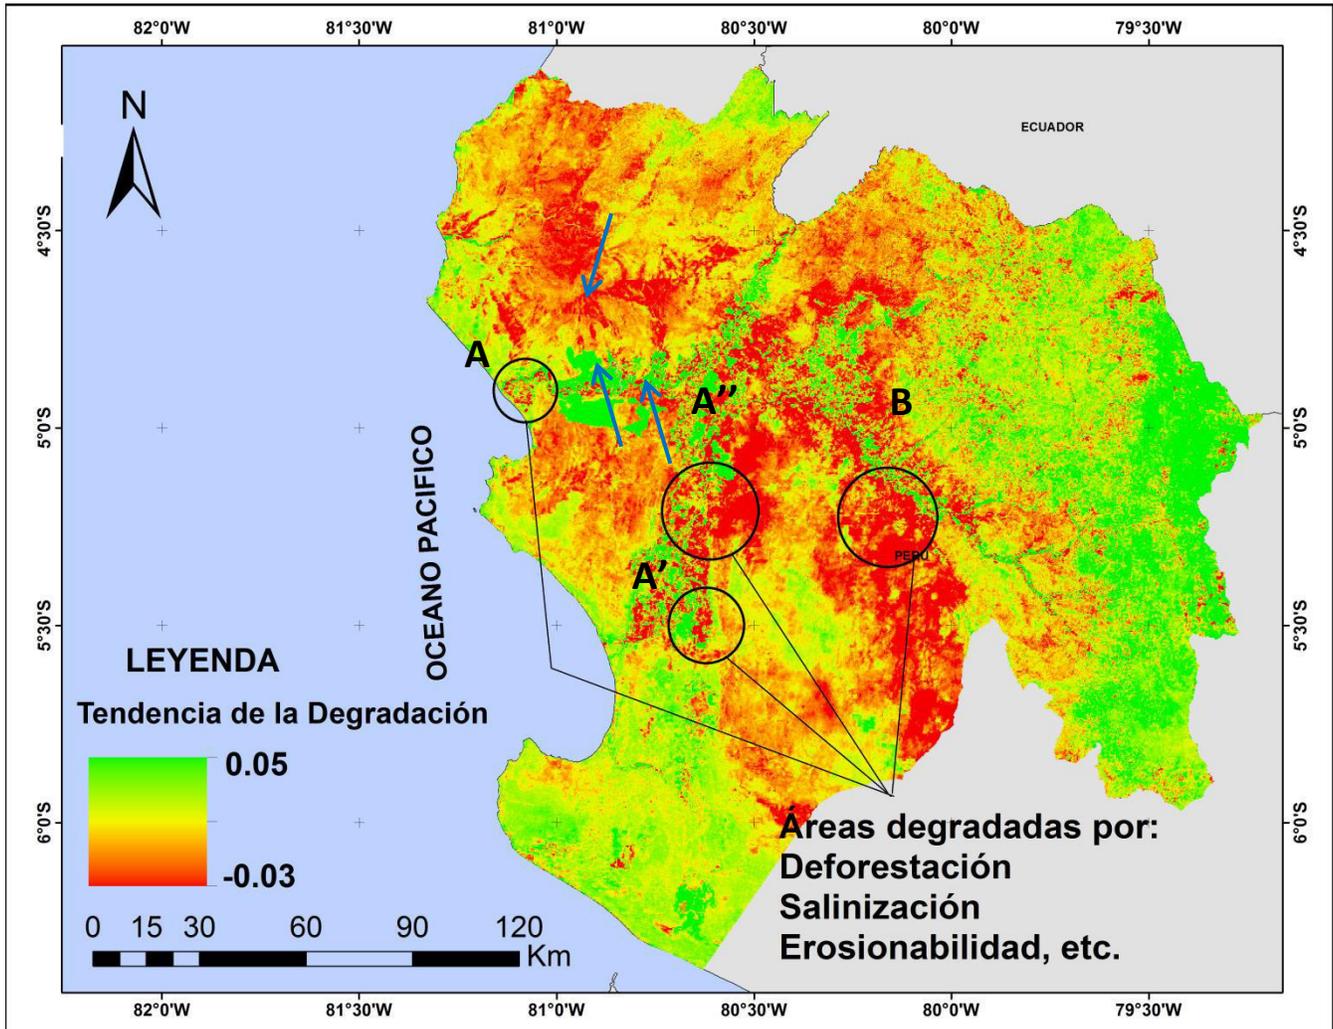
5. RESULTADOS Y VALIDACIÓN

5.1 Análisis empírico mediante el índice EVI – Máximos Compuestos Anuales (MCA)

Luego de analizar las pendientes de las regresiones lineales de los MCA, es necesario extraerlo de tal manera que obtengamos un mapa de tendencias. En muchas investigaciones científicas relacionadas al estudio de la degradación de la tierra, es muy familiar trabajar con mapas de pendientes de las ecuaciones lineales en las series de tiempo (Viovy, 1992), de tal manera que la tendencia de la degradación será netamente dependiente del valor que tome la pendiente de una regresión lineal, hablando en términos empíricos. Los resultados obtenidos analizando los MCA del índice EVI que arroja la tendencia de la degradación (Mapa 5-1), muestra en colores rojos intensos áreas con tendencia negativa indicativo de que hay perturbaciones que afectan a la cobertura. Por otro lado, los colores en verde que muestra el mapa (Mapa 5-1), resalta zonas con tendencia creciente y estable de la cobertura.



El Mapa 5-1, también puede interpretarse haciendo notar que en pendientes negativas, hubo una disminución parcial de la biomasa, por el contrario; en zonas donde la pendiente es positiva hubo cierta ganancia de biomasa.



Mapa 5-2. Resultado de extraer las pendientes de las ecuaciones lineales píxel a píxel en los MCA.

La tendencia de la degradación (Mapa 5-2) muestra zonas críticas en tonalidad roja. Las áreas con círculos en color negro (A, A', A'') son áreas agrícolas con problemas de salinización originados por el mal drenaje y donde las sales abrazan al agua. Estas áreas son el resultado de la mala utilización de agua de riego, el nivel freático y el drenaje son factores que originan pérdidas de suelos agrícolas algunas veces irreversibles si no hay una reacción inmediata para revertir dicho proceso.

En el Mapa 5-2 el círculo en color negro (B) muestra también áreas con tendencia negativa de la degradación. Esta zona es un tipo de cobertura identificado como bosque seco según la ZEE del gobierno regional de Piura. La deforestación de árboles en esta zona, son usados generalmente como leña por los pobladores. Pero, también la tala se da para actividades comerciales de estas.

Por otro lado las áreas señaladas con flechas en color azul, la tendencia de la degradación no muestra un valor negativo (colores rojos), sino muestra una tonalidad verde (Mapa 5-2). Este color representa una tendencia positiva en la cobertura (Mapa 5-1). Este valor con pendiente positiva indica que la cobertura sufrió un cambio de uso, es decir, hay una expansión agrícola notable en ambos lados del río. Esta ganancia de suelos para la agricultura se debe a que en la región hay mucha actividad industrial agrícola que cada vez necesita más suelos para cultivar. Pero estas zonas cuentan con riego tecnificado para evitar así que sufran de salinización como se muestra en los círculos en color negro (A, A', A'').

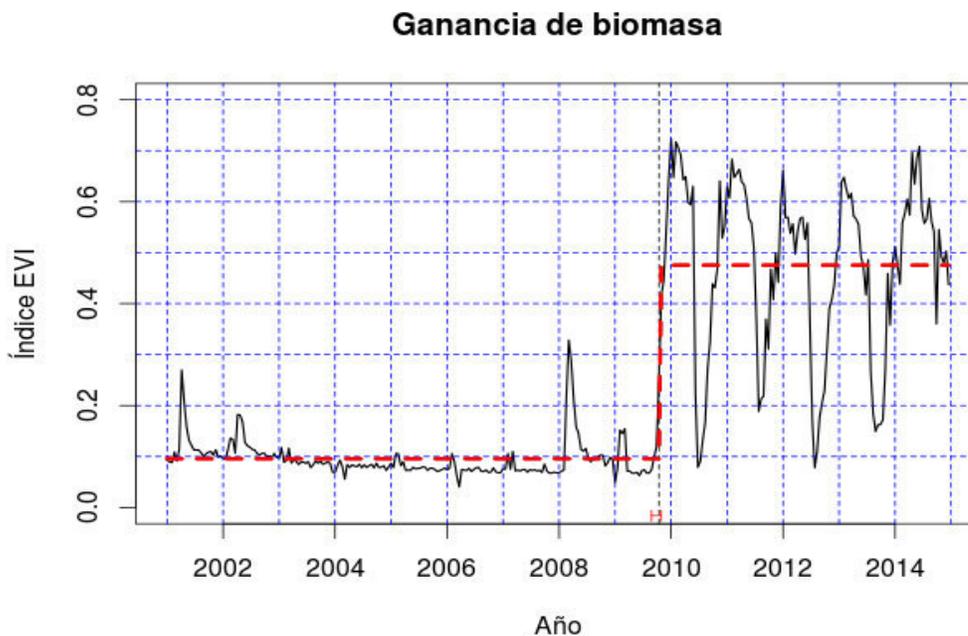
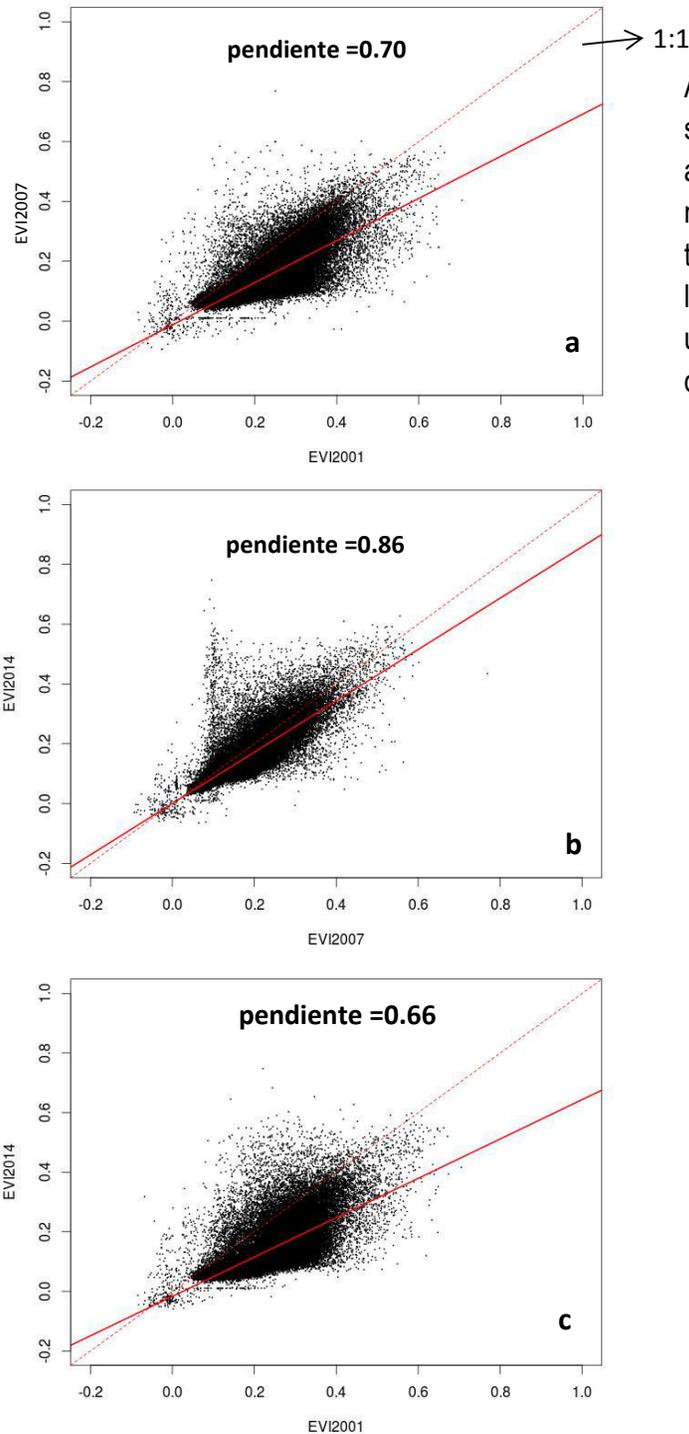


Figura 5-1. Área donde hubo un cambio en el uso del suelo por agricultura en el 2010.

El análisis de regresión y los gráficos de dispersión⁶ (Mapa 5-2), para la cobertura de bosque seco, mostraron que hubo una disminución del año 2001 respecto al 2007 con pendiente (0.70), al igual que el año 2007 respecto al 2014 con pendiente (0.86). Pero para el año 2001 respecto al 2014 hubo una disminución mayor en la cobertura con pendiente (0.66); lo cual es lógico, porque se está analizando un periodo más largo con probabilidades de que haya cambios mayores tal como

⁶ Los gráficos de dispersión o scatter plot muestran comparación entre la relación de dos variables en un plano bidimensional X vs Y.

muestra la Mapa 5-2 (c). Para tener un mejor entendimiento de lo ocurrido entre dos fechas puntuales, se realizó una gráfica de dispersión (Mapa 5-2).



Aquellos puntos que están sobre la línea diagonal 1:1, son aquellos píxeles que se mantuvieron constantes en el tiempo. El desplazamiento de la línea diagonal indica que hubo un cambio en el valor del píxel de un tiempo inicial a uno final.

Figura 5-2. Satter plot del EVI para los periodos 2001 vs 2007 (a), 2007 vs 2014 (b) y 2001 vs 2014 (c).

Como un análisis previo, se identificó cuatro cuadrantes para identificar el cuadrante de estudio y la relación entre la temperatura y el índice EVI.

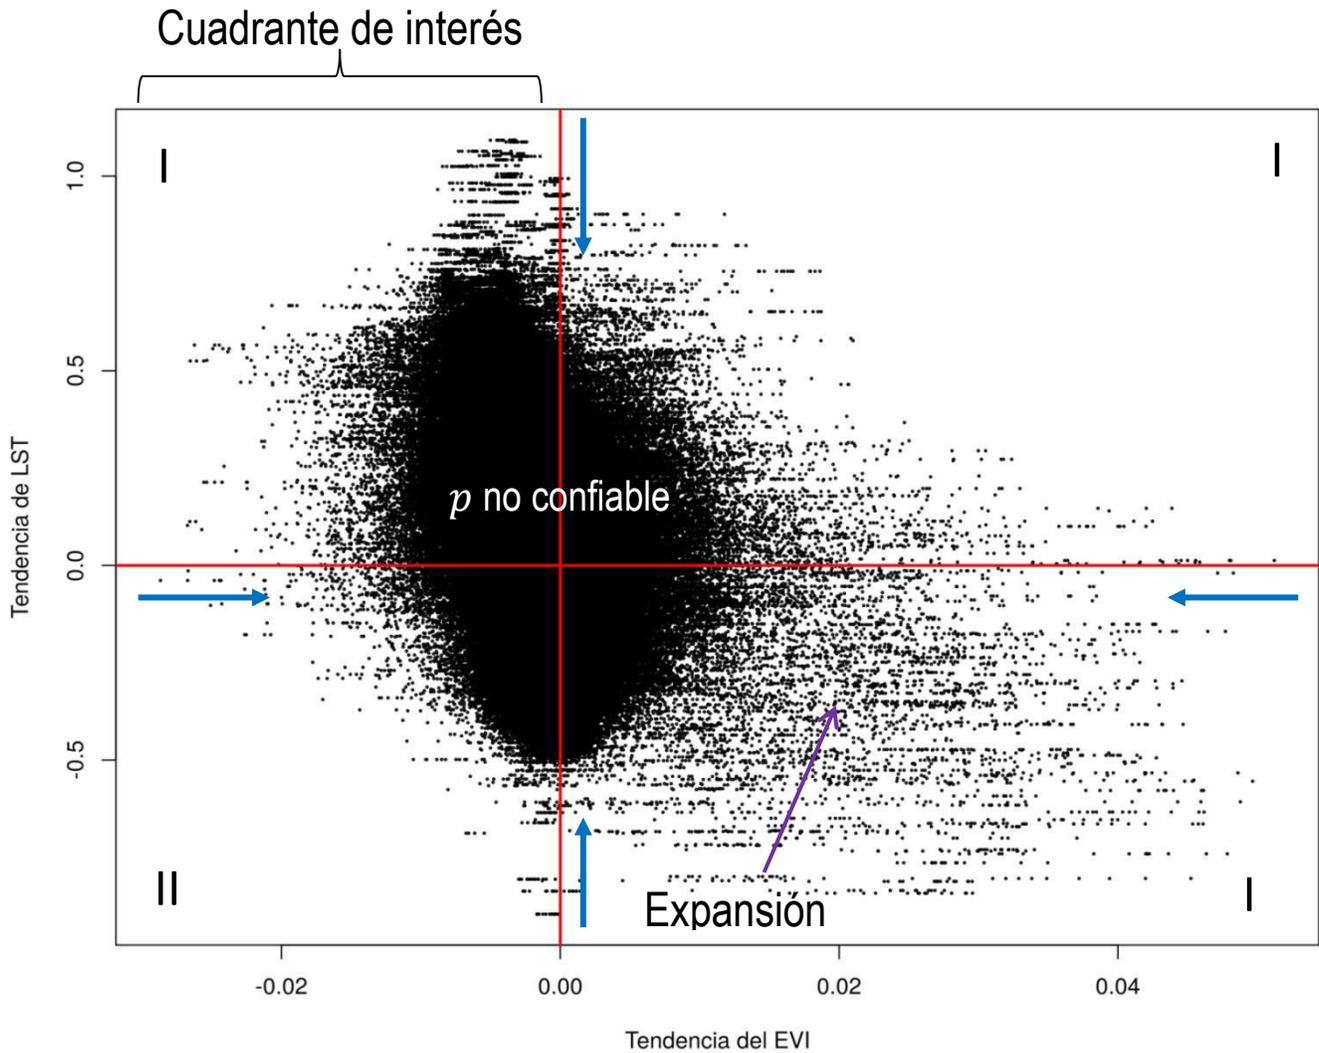


Figura 5-3. Diagrama de dispersión en función a los cuadrantes de estudio.

1. Cuadrantes I y III son anómalos.
2. Cuadrante II (objeto de estudio), cuadrante IV (expansión agrícola)
3. Confiable = periférico.
4. No se tiene en cuenta el test de significancia.

Se realizó el mismo análisis para áreas donde se produjo la expansión agrícola (Mapa 5-2), con flecha azul, mostrando el análisis de regresión lineal (Figura 5-4). Lo resaltante de estos gráficos de dispersión (Figura 5-4) se da en la Figura 5-4 (b) donde se hace una comparación del año 2007 respecto al 2014 y claramente se aprecia mayores valores en los píxeles del año 2014. La extensión agrícola señalada con flecha azul (Mapa 5-2) se dio a inicios del 2008 en adelante tal cual muestra la serie temporal (Figura 5-1), donde el "breakpoint" o la ruptura de la tendencia fue en el año 2010. Lo mismo se puede observar en el EVI2001 respecto al EVI2014 (Figura 5-4 c). Si navegamos y analizamos los resultados del mapa de pendientes (Mapa 5-2) por el valle agrícola, especialmente los valores donde la pendiente es negativa (indicador de una degradación probable) y lo verificamos mediante imágenes de alta resolución de Google Earth, veremos que aquellos píxeles con valores negativos (en color rojo) sufrieron pérdida de suelo por salinización (Figura 5-5 y Figura 5-6). La explicación de esta pérdida de la productividad del suelo por sales, recae en la propiedad de la ósmosis, ya que las sales abrazan el agua de las plantas haciendo que estas se sequen y dejen de producir. Con todo, los problemas de salinidad en los valles se debe a un mal drenaje acompañada de un riego no tecnificado que en conjunto suben el nivel freático trayendo consigo las sales y finalmente haciendo que estas absorben el agua de las plantas.

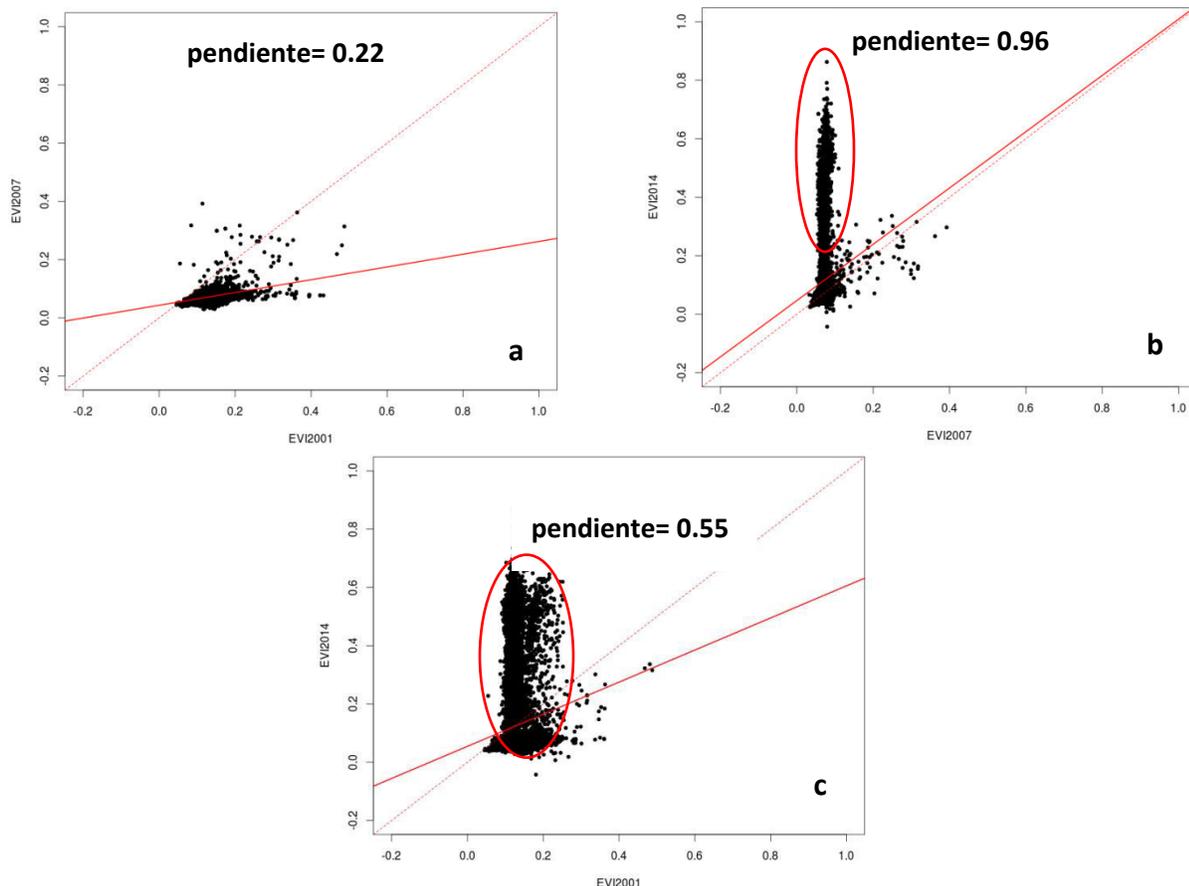


Figura 5-4. Regresión lineal de los índices EVI para los periodo 2001, 2007 y 2014. 2001 vs 2007 (a), 2007 vs 2014 (b) y 2001 vs 2014 (c).

Predicción de Tierras Degradadas a Partir del Análisis de Series Temporales del Índice Mejorado de Vegetación y Temperatura de superficie de Suelo mediante Imágenes MODIS - Caso Estudio Piura

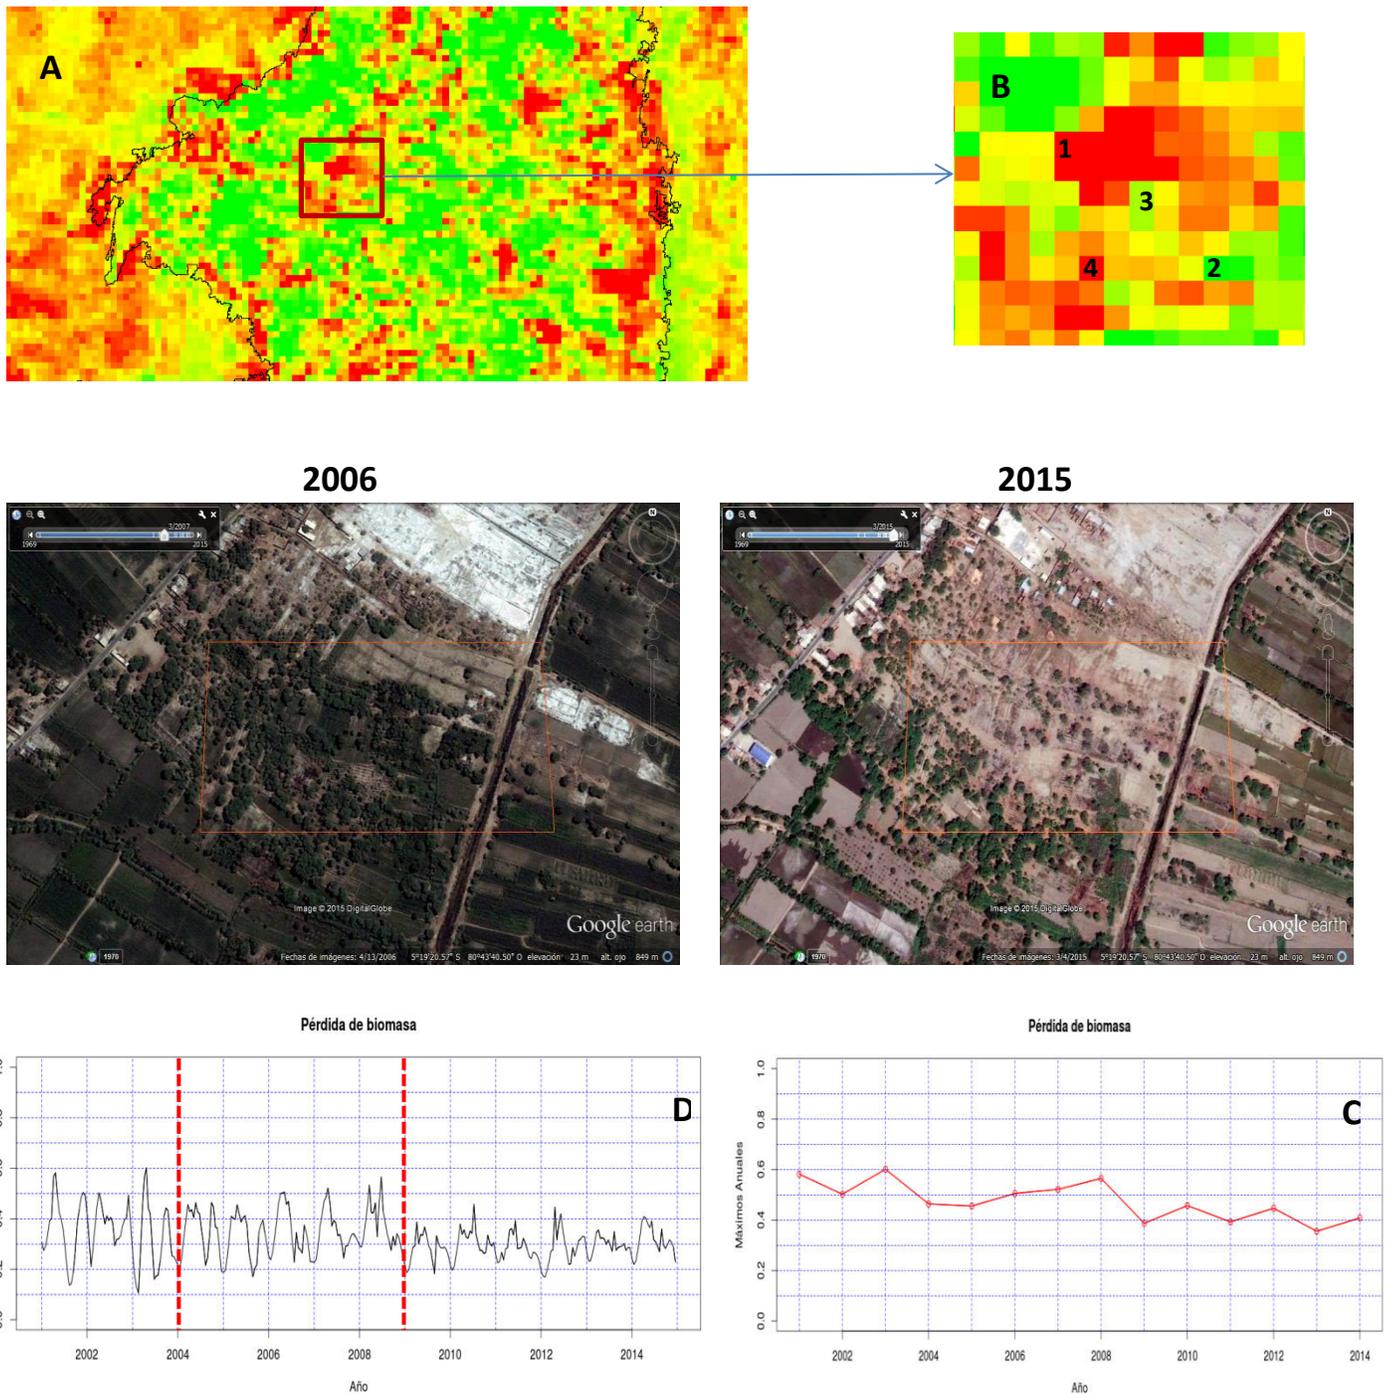
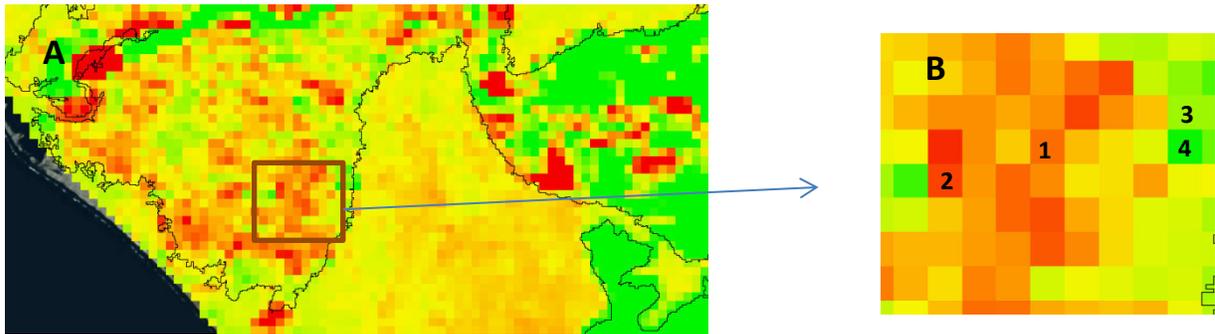


Figura 5-5. El análisis de tendencias de la cubierta vegetal utilizando MODIS EVI entre enero del 2001 y diciembre del 2014 señala una reducción de la cobertura (en color rojo - Figura B, C y D - para el punto 1) durante la mayor parte de la zona, aunque algunas partes de la sección muestran aumentos en el EVI (por ejemplo los puntos 2 y 3). La dinámica de la cobertura de la zona es, por tanto, bastante compleja y variable. Con todo, la evolución de la cubierta vegetal de la zona (Figura 5-5 A) para el período de 2001 al 2014, muestra importantes variaciones interanuales, en gran parte determinada por las sales dentro del valle y fuera del valle por las condiciones climáticas. (Área de análisis - valle agrícola de Piura).

Predicción de Tierras Degradadas a Partir del Análisis de Series Temporales del Índice Mejorado de Vegetación y Temperatura de superficie de Suelo mediante Imágenes MODIS - Caso Estudio Piura



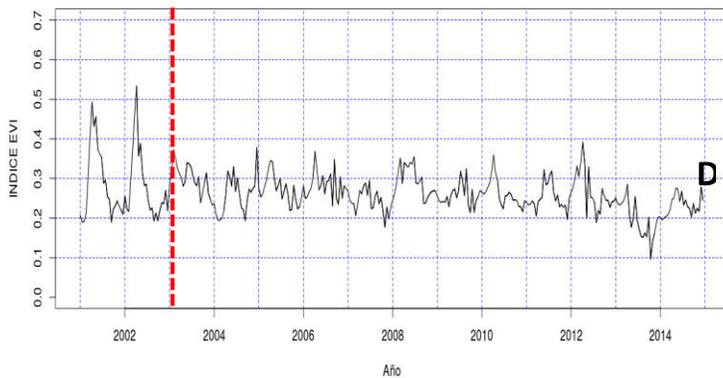
2003



2013



Pérdida de biomasa



Pérdida de biomasa

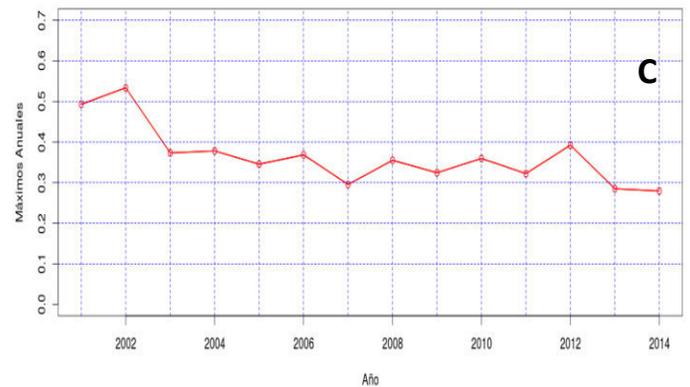
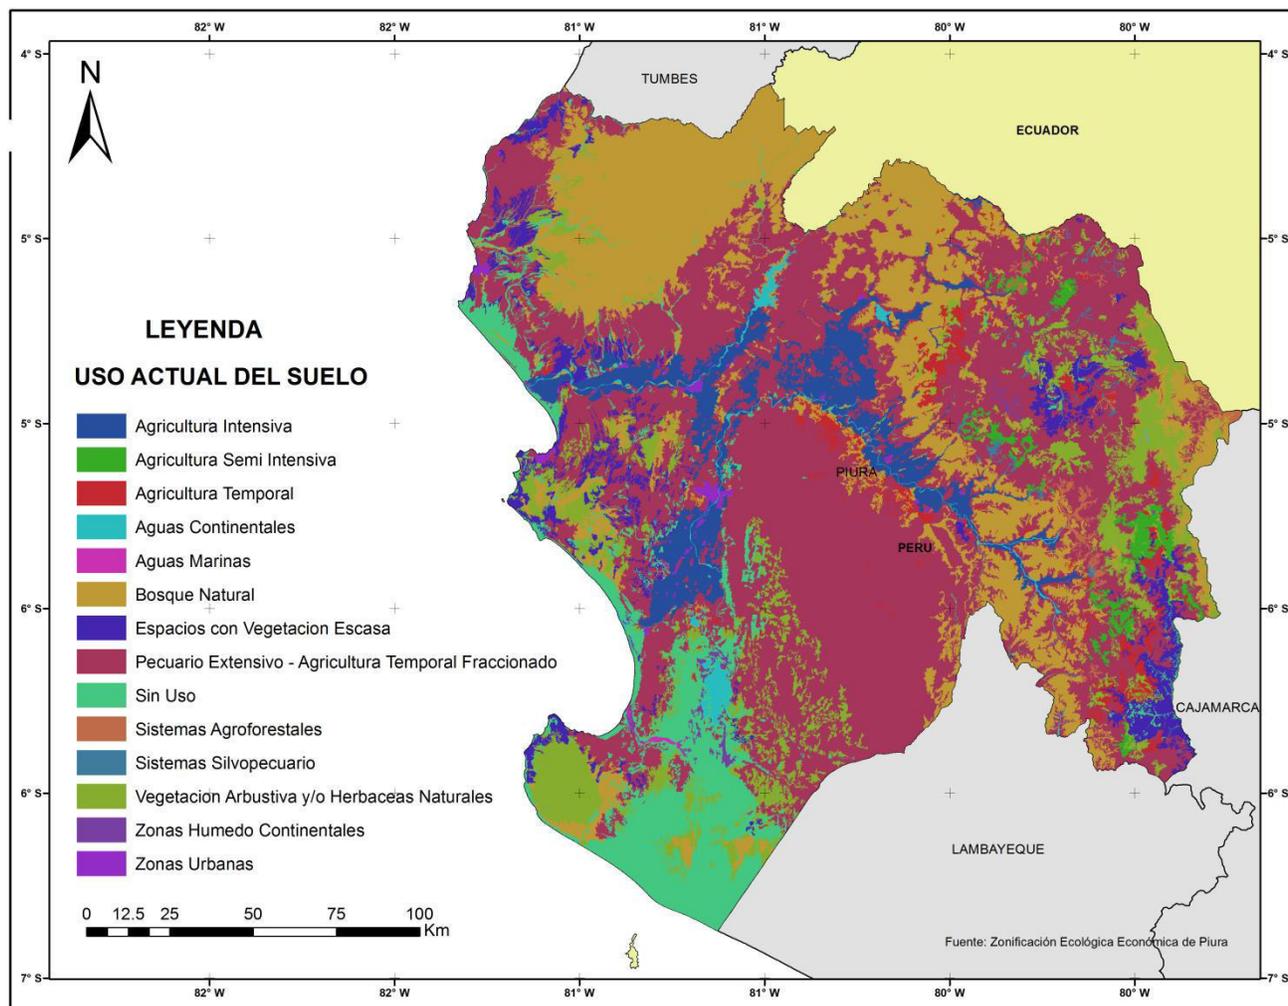


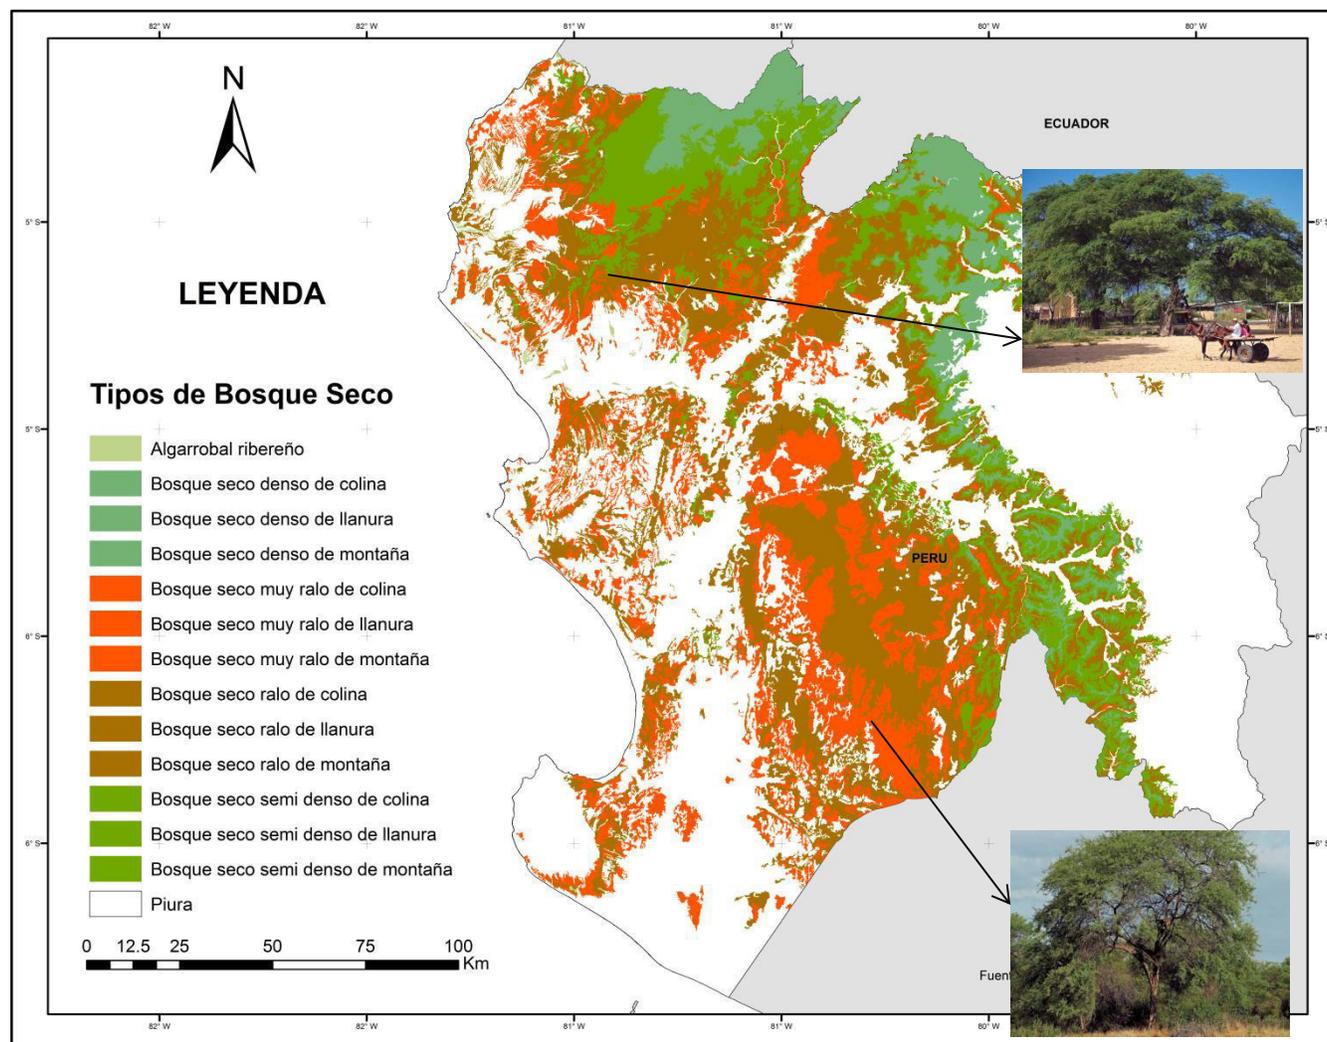
Figura 5-6. Haciendo un mismo análisis de tendencias de la cubierta vegetal utilizando MODIS EVI entre enero del 2001 y diciembre del 2014 señala una reducción de la cobertura (en color rojo - B, C y D - para los puntos 1 y 2) durante la mayor parte de la zona, aunque algunas partes de la sección muestran aumentos en el EVI (por ejemplo los puntos 3 y 4). La dinámica de la vegetación de la zona es, por tanto, bastante compleja y variable. Con todo, la evolución de la cubierta vegetal de la zona (A) para el período de 2001 al 2014, muestra importantes variaciones interanuales, tanto positivas como negativas, esto está determinada por las sales dentro del valle y fuera del valle por las condiciones climáticas (Valle Agrícola).

Predicción de Tierras Degradadas a Partir del Análisis de Series Temporales del Índice Mejorado de Vegetación y Temperatura de superficie de Suelo mediante Imágenes MODIS - Caso Estudio Piura



Mapa 5-3. Uso actual del suelo según la Zonificación Ecológica Económica de Piura.

La tendencia de la degradación de la variable biofísica (índice EVI) tiene una relación con el uso del suelo. Según el mapa de tendencia de la degradación (Mapa 5-2) los valores con tendencia muy negativa ocurren en zonas donde el uso es agricultura intensiva-valles agrícolas-, y en zonas donde el uso es pecuario-bosque seco-, según el tipo de cobertura de la Zonificación Ecológica Económica de la Región de Piura (Mapa 5-3).

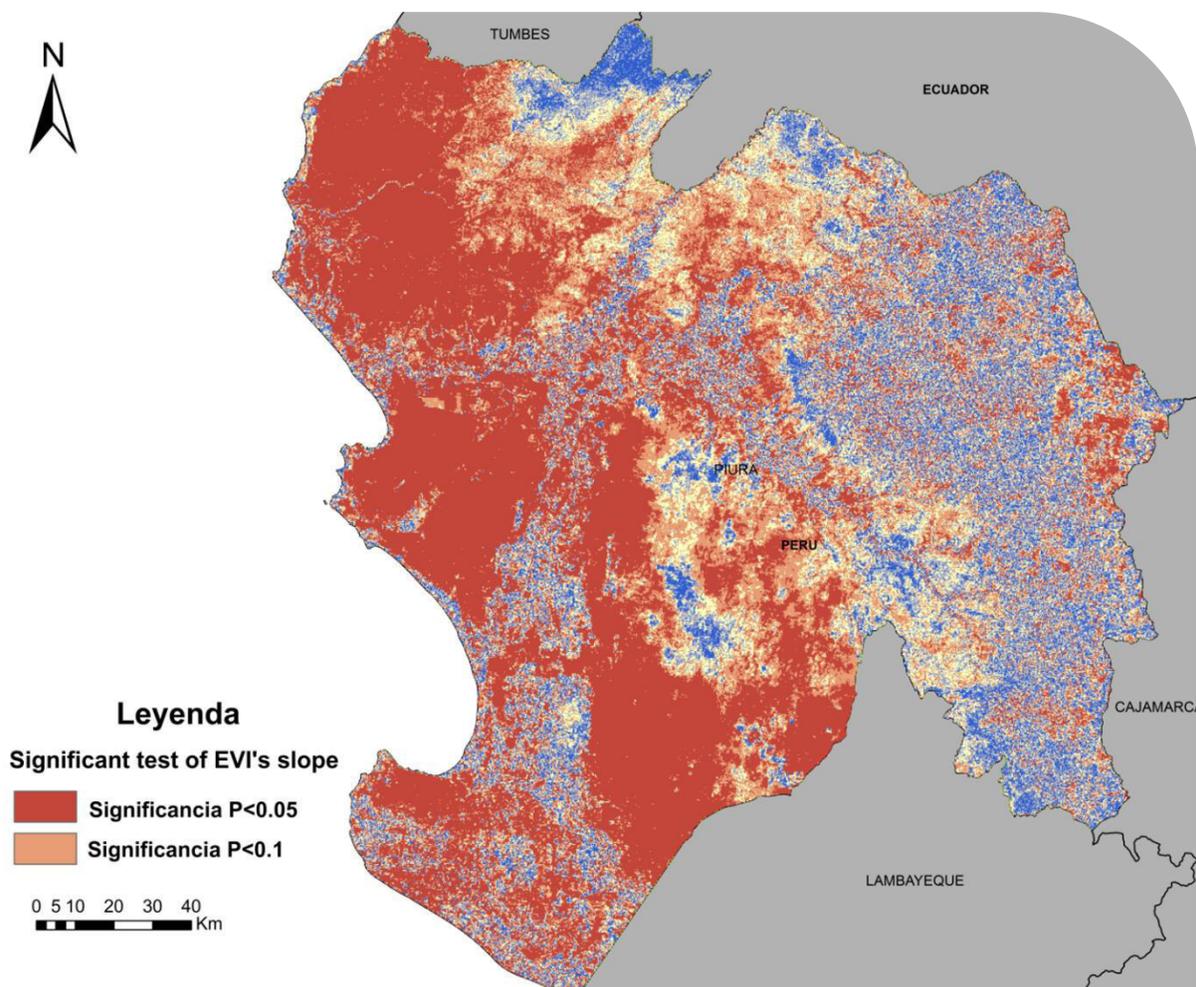


Mapa 5-4. Bosques secos según el tipo de cobertura de la Zonificación Ecológica y Económica-Piura 2012.

En los bosques secos con alturas de 0-250 m.s.n.m predominan los árboles de algarrobo (*Prosopis piurenses*), sapote (*Capparis scrubida*) y especies arbustivas como el overo (*Cardia lutea*) (Ministerio de Agricultura y Riego, 2013), donde la variabilidad climática está afectando no solo al desarrollo fenológico y producción del algarrobo con el incremento leve de la temperatura, sino que está dando origen a la proliferación de plagas debido al estrés hídrico que sufren los bosques secos.

5.2 Test de Confianza

Se realizó una prueba de significación para determinar la magnitud del cambio en la pendiente del EVI con el tiempo (Mapa 5-5). La Tabla 5.1 resume los resultados independientemente de si este cambio fue positivo o negativo. A nivel de confianza del 95%, no hubo cambios significativos en el EVI más que el 29.8 % del área de estudio.



Mapa 5-5. Significancia en el píxel de cambios interanuales del EVI sobre el periodo 2001 – 2014.

Tabla 5-1. Nivel de significancia o de confiabilidad de las regresiones lineales.

Nivel de Significancia	Números de píxeles	Área (km ²)	Porcentaje (%)
P<0.05	165 746.55	10 359.16	29.8%
P<0.10	217 767.04	13 610.44	38.1%

5.3 Detección del periodo de cambio mediante bfast

Como se mencionó en la metodología, una serie temporal a lo largo de su periodo histórico, tendrá en algunos casos más de una ruptura en el componente tendencial. Las rupturas o *breakpoints* son cambios en la reflectancia de la cubierta por alguna perturbación natural o antrópica. Entonces, aplicando este algoritmo muy robusto en **detección de cambio** se encontró los periodos de cambio abruptos de uso por agricultura (Figura 5-7).

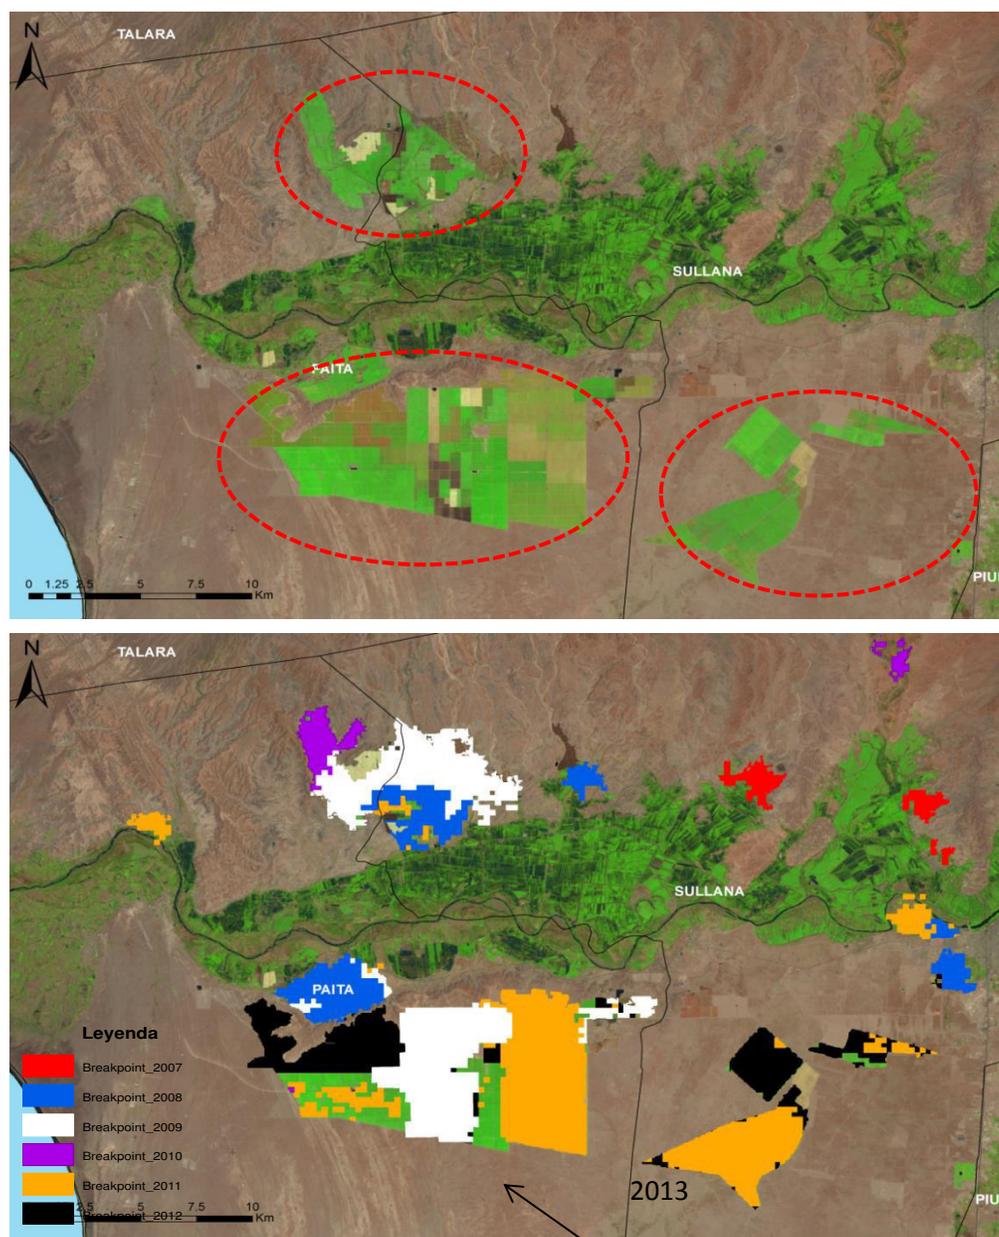
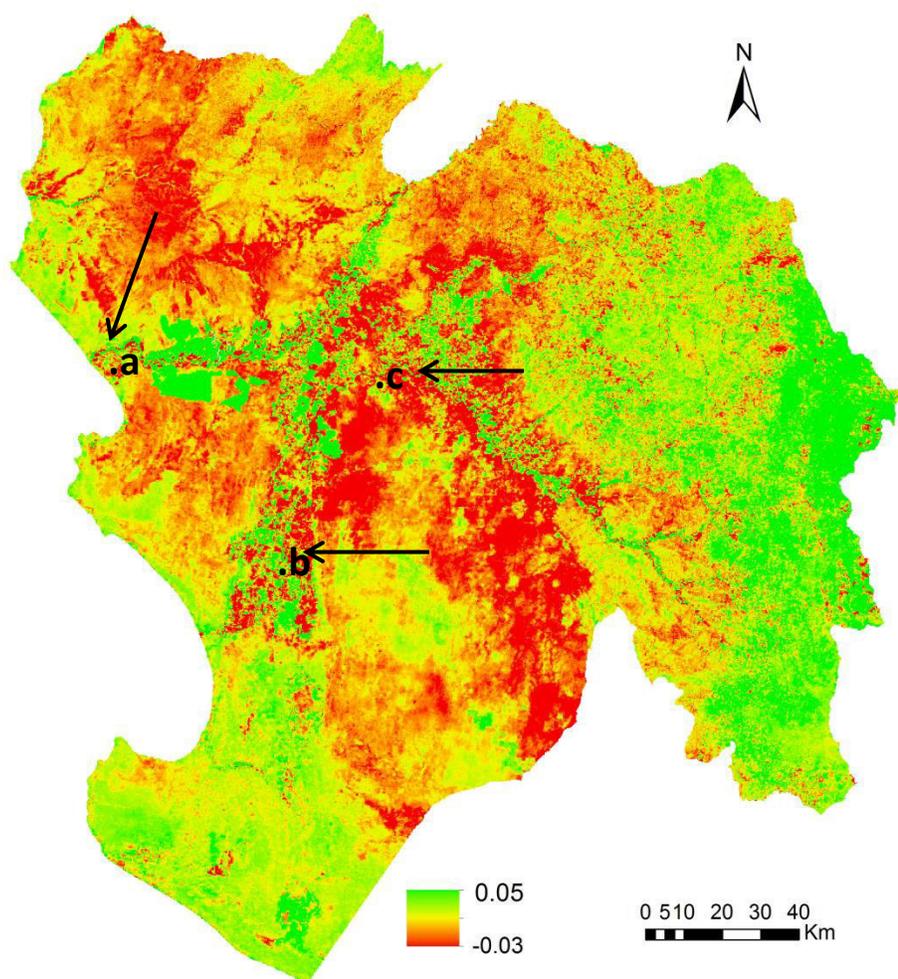


Figura 5-7. Se muestra los años en que se expandió la agricultura mediante bfast- Imagen L8-2014.

Bfast tal como se describe en el marco teórico, es una técnica que detecta cambios graduales y abruptos dentro de una serie de tiempo. No es posible aplicar **bfast** para detectar y cuantificar degradación de la tierra por cuatro motivos: 1) cada serie de tiempo tendrá muchas rupturas en la tendencia confundiendo el análisis del inicio de la degradación, 2) el ruido dentro de las series temporales, se puede confundir con la estacionalidad afectando la precisión del algoritmo y por consiguiente detectando falsos *breakpoints*, 3) teniendo tantos *breakpoints* dentro de una serie de tiempo no es posible estudiar extensas coberturas por el simple hecho que no es posible analizar el comportamiento píxel a píxel de cada serie, y 4) no es posible automatizar y generar mapas de degradación teniendo tantas rupturas en la tendencia. Sin embargo, **bfast** es muy poderoso en la detección del inicio del periodo donde se inicia una caída en la tendencia (proceso degradador probable).



Mapa 5-6. Se muestra los píxeles aplicando el método bfast en a, b y c.

A manera de ejemplo se tomarán 3 píxeles de los cuales se analizarán las series históricas con el método bfast (Figura 5-8, Figura 5-9 y Figura 5-10).

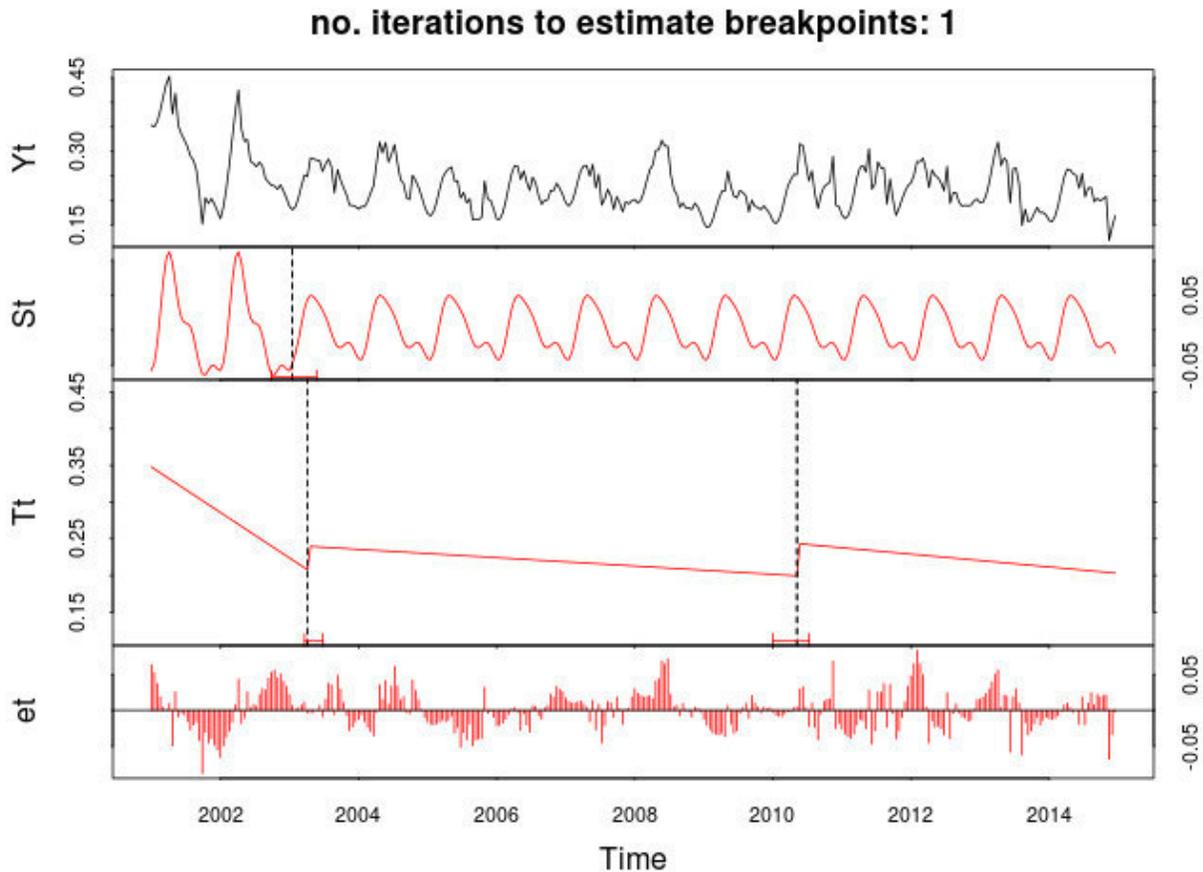


Figura 5-8. Disminución del índice EVI y detectado con bfast para el punto a (Mapa 5-6)

La Figura 5-8 muestra el análisis que realiza el algoritmo **bfast** en la detección de cambios. **Bfast** trabaja con los componentes de las series de tiempo (tendencia, estacionalidad y ruido). Para eso usa técnicas de regresión por trozos con la finalidad de encontrar *breakpoint* en la componente tendencia de la serie de tiempo.

Utiliza la misma metodología para encontrar rupturas en la componente estacional pero para eso usa también las series de Fourier para simular la estacionalidad natural de la cobertura. Esta misma metodología se usa para encontrar las rupturas abruptas en la serie debido a la expansión agrícola.

Predicción de Tierras Degradadas a Partir del Análisis de Series Temporales del Índice Mejorado de Vegetación y Temperatura de superficie de Suelo mediante Imágenes MODIS - Caso Estudio Piura

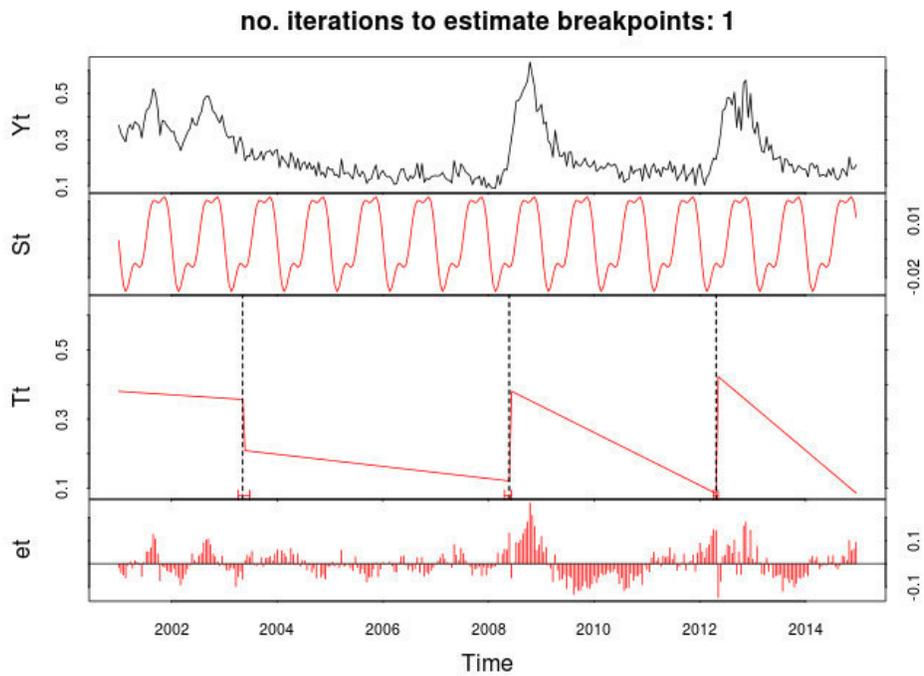
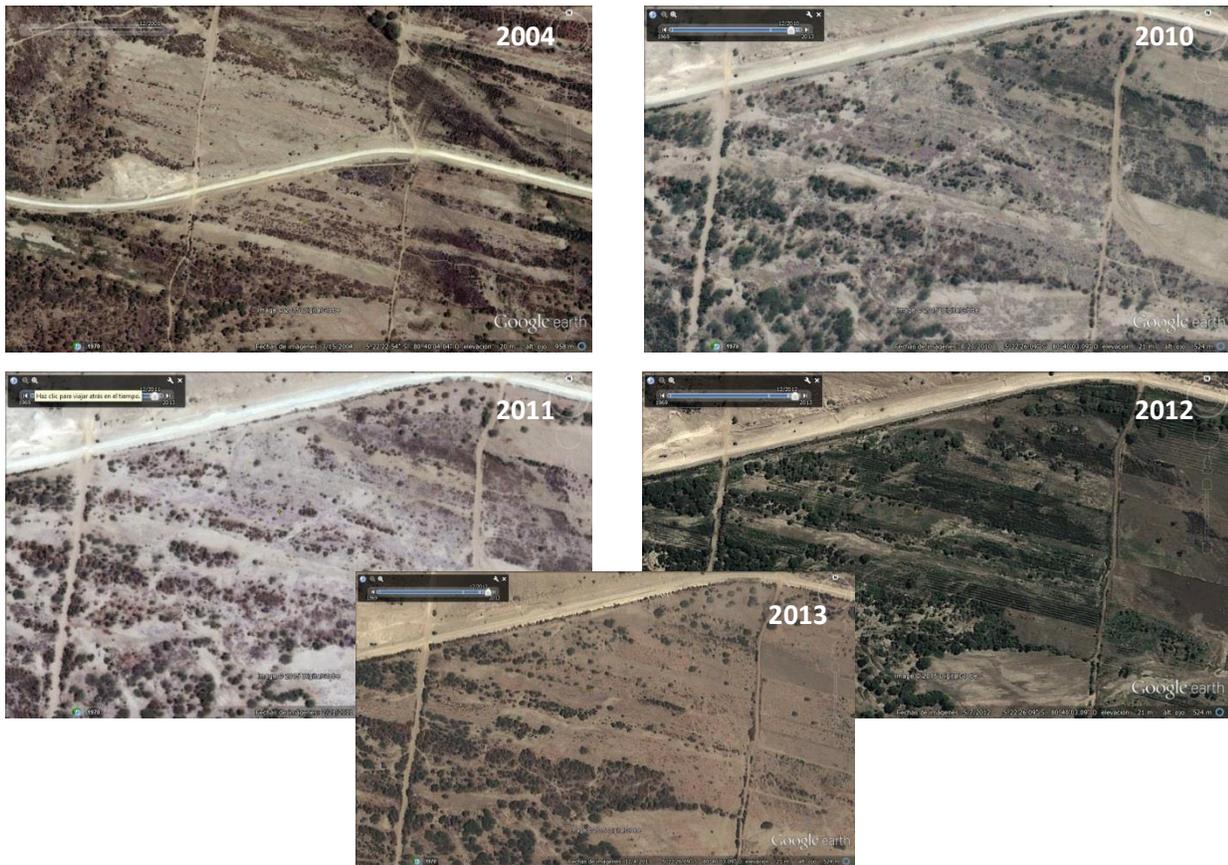


Figura 5-9. Disminución del índice EVI y detectado con bfast para el punto **b** (Mapa 5-6)

Predicción de Tierras Degradadas a Partir del Análisis de Series Temporales del Índice Mejorado de Vegetación y Temperatura de superficie de Suelo mediante Imágenes MODIS - Caso Estudio Piura

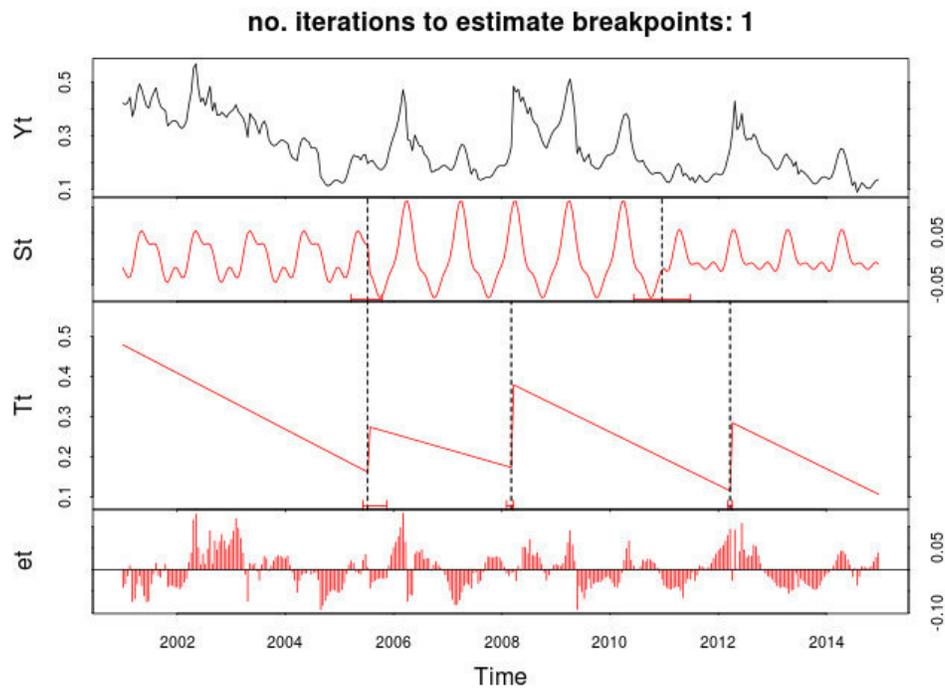


Figura 5-10. Disminución del índice EVI y detectado con bfast para el punto c (Mapa 5-6).

5.4 Análisis mediante la temperatura superficial (T_s)

La relación entre las perturbaciones antrópicas -como la deforestación de coberturas (bosques secos, bosques tropicales, etc) y perturbaciones naturales (como la erosión, sequias, etc)- con respecto a la temperatura superficial (T_s) guardan relación directa e inversa. Ya que el potencial para obtener información sobre el estado de la cubierta vegetal a través de la relación entre la temperatura superficial (T_s) y el índice de vegetación (por ejemplo el NDVI) ha sido investigado por varios autores (Carlos et al., 1994; Gillies et al., 1997; Lambin et al., 1996; Moran et al., 1994; Nemani et al., 1993; Smith et al., 1991).

Al igual que con el índice EVI, se ha realizado un análisis de pendientes de las regresiones lineales píxel a píxel para aquellas imágenes en lo posible sin artefactos atmosféricos. Y es que la información complementaria en la banda térmica y las longitudes de onda infrarroja y visible han demostrado ser muy adecuado para el seguimiento del estado de la vegetación y el estrés, específicamente relacionado al estrés hídrico (Lambin, 2006).

La temperatura superficial T_s en combinación con el EVI puede proporcionar información sobre la vegetación superficial. Varios estudios se centran en la pendiente de la curva de T_s / NDVI (en este estudio se hará la pendiente T_s /EVI).

La correlación entre el índice de vegetación mejorado (EVI) y la temperatura superficial (T_s) (Figura 5-11) para el año 2014 de la región de Piura, guarda una relación inversa. Si la temperatura disminuye se incrementa el valor del índice, mientras que si la temperatura aumenta el índice disminuye. La correlación muestra una relación inversa relativamente apreciable con $r = 0.67$ tal cual menciona (Lambin & Ehrlich, 1996).

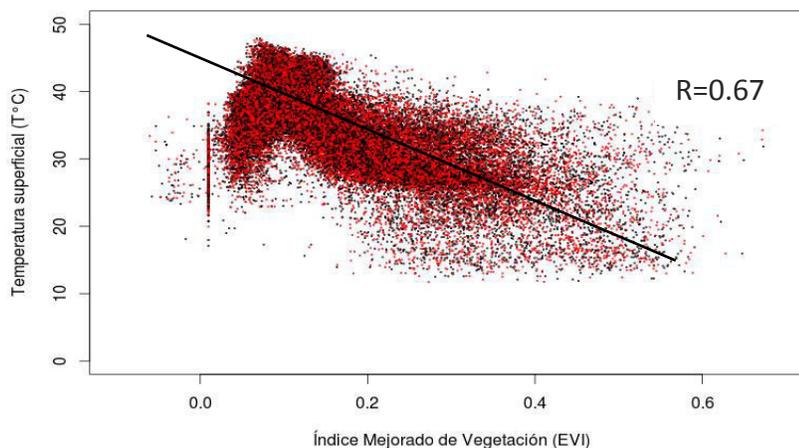


Figura 5-11. La relación entre el verdor de la vegetación y la temperatura superficial.

Este diagrama de dispersión de la temperatura superficial y el índice de vegetación a menudo resulta en una forma triangular⁷ (Moran et al., 1994) (Figura 5-12). El enfoque descrito por (Moran et al., 1994) representa superficies parcialmente con vegetación (**déficit de agua en relación con la evapotranspiración real y potencial de una superficie**).

Si bien es cierto, describir la relación triangular que hay entre la temperatura superficial y el índice EVI puede que sea parte del marco teórico, es necesario hacerlo en este capítulo para dar una explicación más detallada.

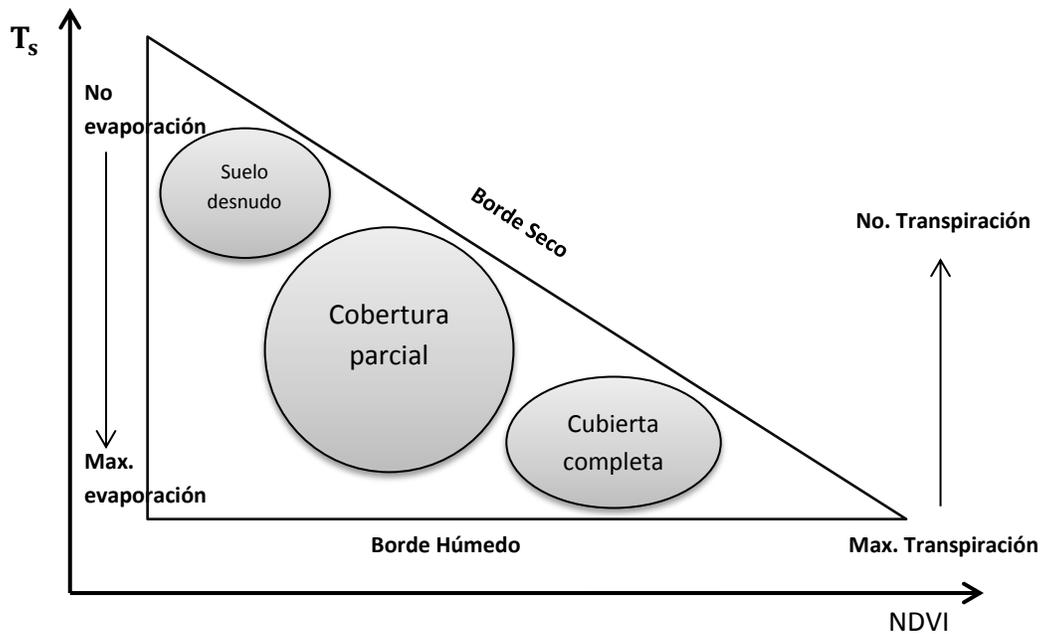
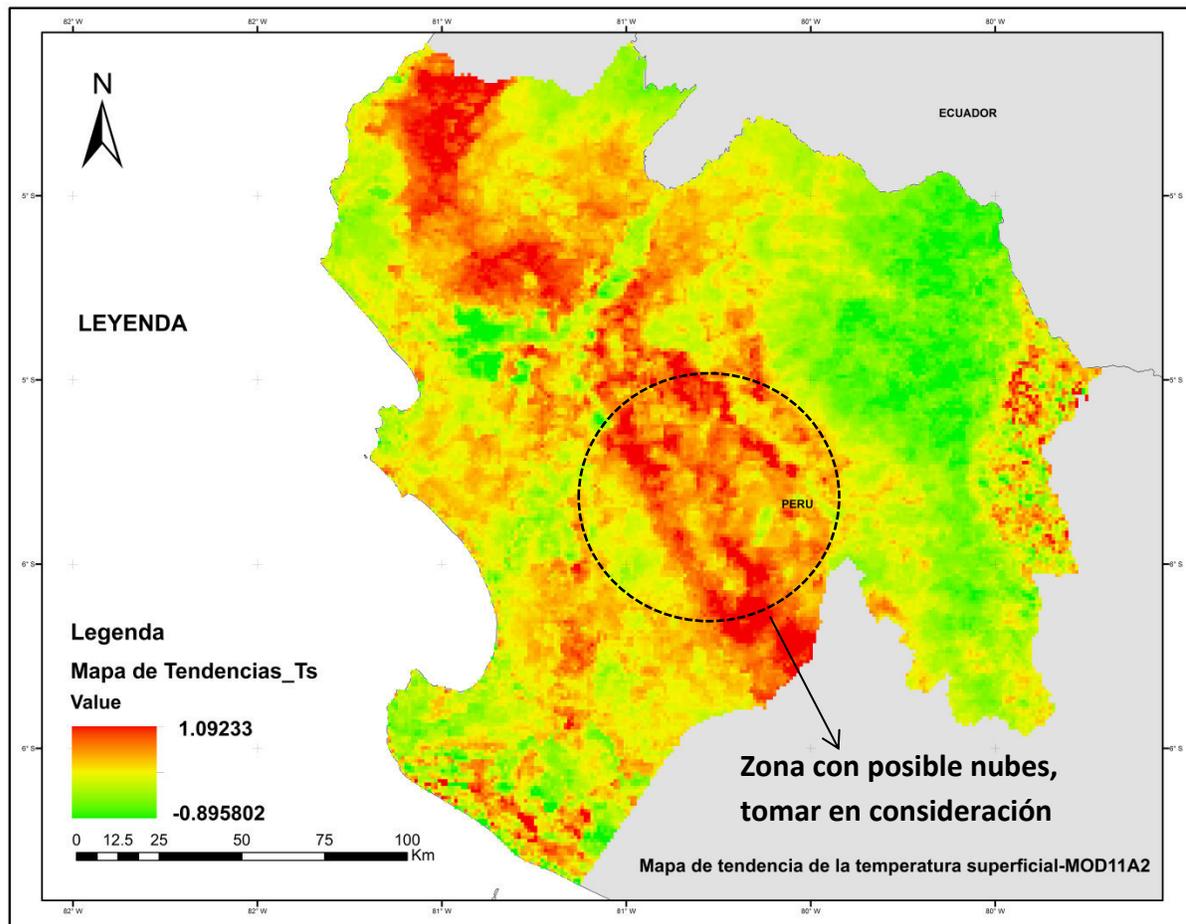


Figura 5-12. Simplificado T_s /NDVI adaptado de (Lambin & Ehrlich, 1996).

La Figura 5-12 muestra el concepto de T_s /EVI. El extremo izquierdo representa el suelo desnudo del rango de seco a húmedo y en extremo inferior derecho un suelo cubierto por mucha vegetación. Como la cantidad de vegetación verde aumenta a lo largo del eje x (NDVI), la temperatura máxima de la superficie disminuye. Para condiciones secas, la relación negativa se define por el borde superior, que es el límite superior de la T_s para un tipo de superficie dada.

⁷ Una variedad de tipos de vegetación se han estudiado bajo una variedad de condiciones climáticas y a escala de metros a global. Puede no extrañarse, por tanto, que las interpretaciones difieran ampliamente basados en la T_s y un índice

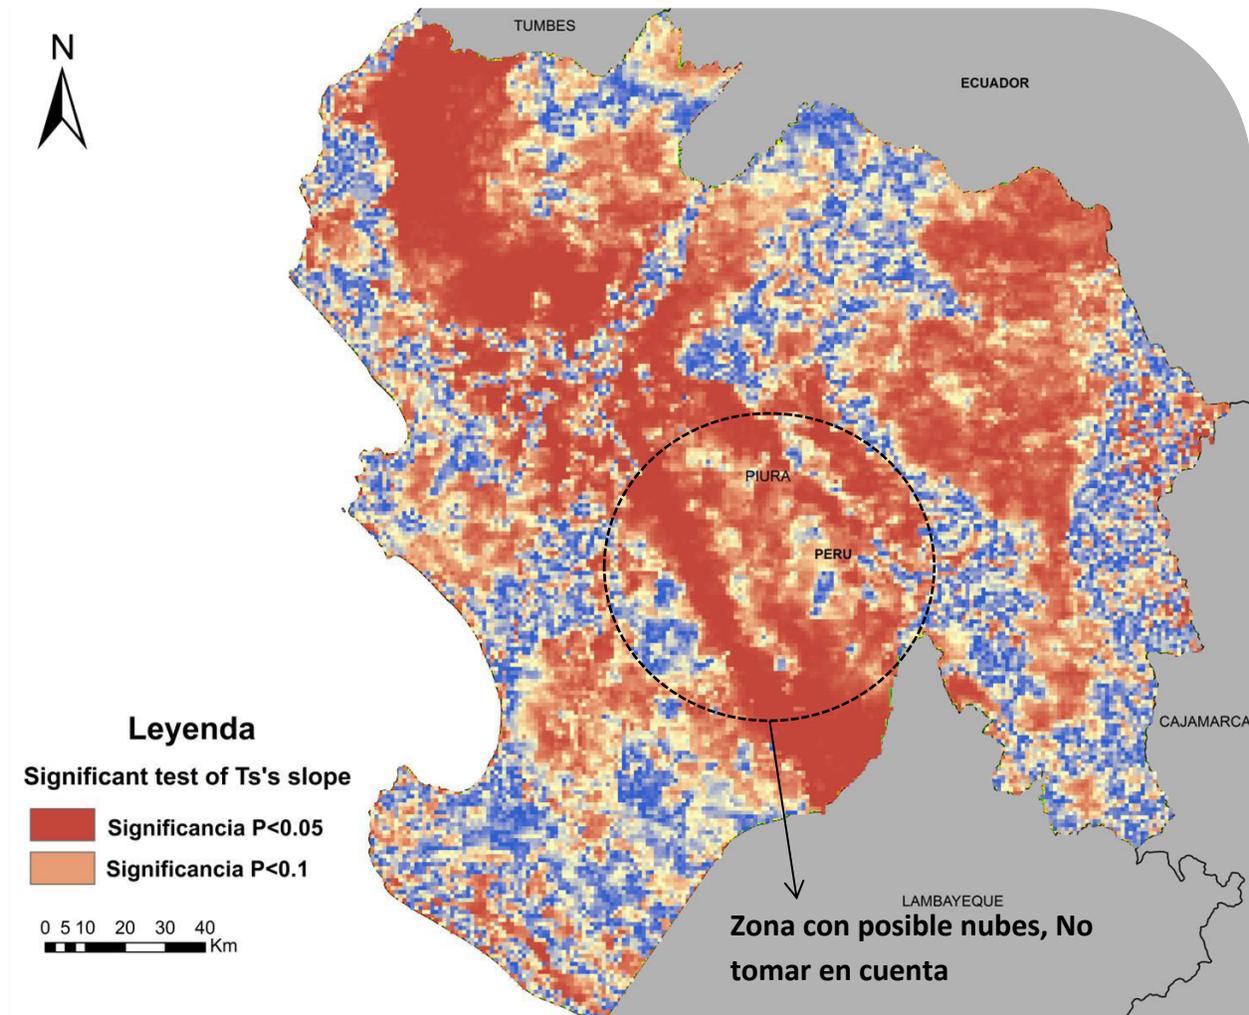


Mapa 5-7. Mapa de tendencias de la temperatura superficial obtenida de las pendientes de las regresiones lineales de los valores mínimos anuales del producto MOD11A2-Day a 1km de resolución espacial.

El mapa de tendencias de temperatura superficial (Mapa 5-7) tiene que necesariamente tener su nivel de significancia o nivel de confianza. Generalmente se hace un test al 95%, en otros casos a un 90% para tener la distribución espacial de una correlación óptima (Mapa 5-8). El nivel de confianza es un sinónimo de la correlación entre las variables, en este caso el tiempo y la temperatura superficial.

Las imágenes seleccionadas fueron en la época seca donde no hay mucha nubosidad, ni humedad relativa, por lo que los artefactos atmosféricos no están presentes en casi toda la región. La resolución del producto MOD11A2 de MODIS es de 1km, por lo que no ayuda mucho en el análisis de los cambios de temperatura dentro del valle, pero a grosso modo nos permite visualizar los comportamientos anómalos en las distintas coberturas del área de estudio, poniendo en especial

énfasis en aquellas zonas donde la tendencia de la degradación obtenidas con los índices EVI fue negativa.



Mapa 5-8. Mapa de tendencias de la temperatura superficial obtenida de las pendientes de las regresiones lineales de los valores mínimos anuales del producto MOD11A2-Day a 1km de resolución espacial.

Los resultados de la tendencia de la degradación, la tendencia de la temperatura superficial, el uso actual del suelo y la cobertura del bosque seco guardan una relación singular en el espacio y tiempo tal cual muestra la Figura 5-13. La línea longitudinal de color negro indica la franja de las áreas degradadas (Figura 5-13 A) y con un incremento en la temperatura de superficie (Figura 5-13 B). Estas áreas coinciden con la cobertura de bosque seco y la temperatura de superficie nos da idea que toda la zona (Figura 5-13 D) está en un estrés hídrico por lo que el verdor de la vegetación disminuye. Esta área con estrés hídrico tiene consecuencias que se comentarán líneas después.

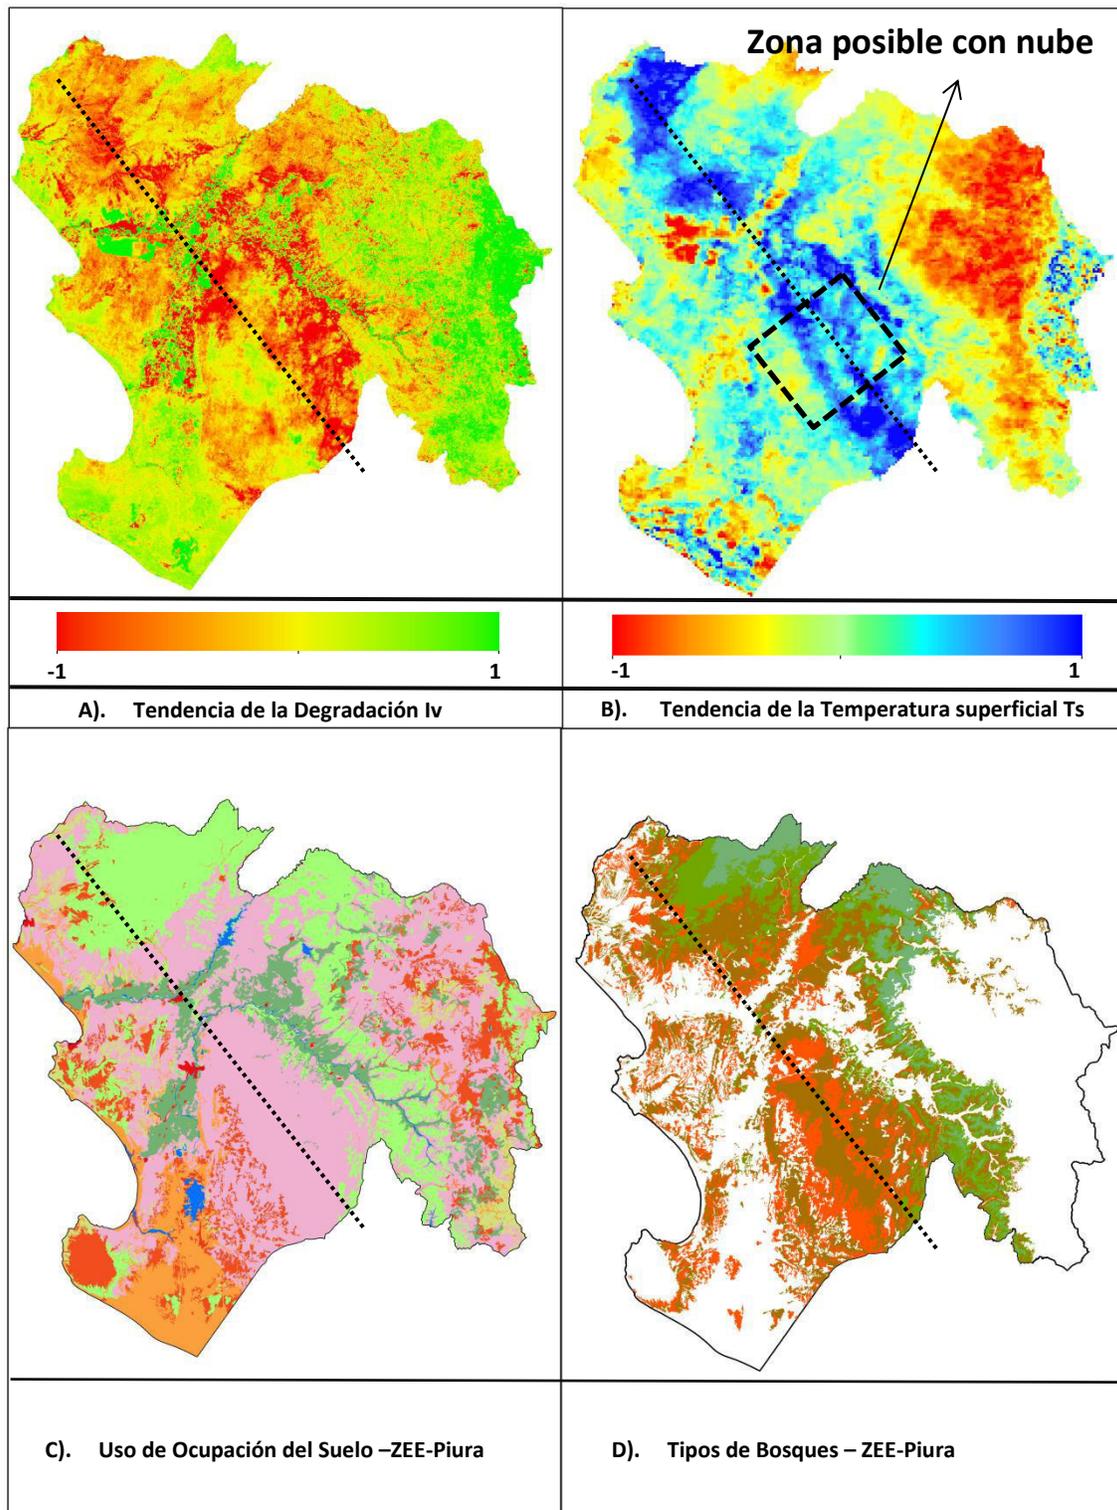


Figura 5-13. La relación entre la tendencia de la degradación y la tendencia de la temperatura guarda relación con el tipo de uso del suelo y sobre todo con los bosques secos. La tendencia positiva (Panel B), muestra zonas con estrés hídrico. Por lo tanto, el aumento de la temperatura superficial aumenta, mientras que el verdor del índice EVI disminuye según (Lambin & Erhlich, 1996).

Actualmente en las zonas donde el tipo de cobertura es un bosque seco y donde la tendencia de la degradación es negativa al igual que el aumento de la temperatura; hay problemas de floración y fructificación debido al incremento de la temperatura. Esto último -incremento de la temperatura- genera que los cultivos estén más expuestos a la incidencia de plagas relacionadas con el clima seco debido a un estrés hídrico tal cual muestra la (Mapa 5-7).

El incremento anual progresivo y la disminución estacional de la temperatura superficial alteran la fisiología y fenología de los árboles del bosque seco. Ello se expresa en una significativa disminución del verdor de la copa (Figura 5-14), disminución en la producción y además, en muchos casos ocurre la muerte de árboles, especialmente de los jóvenes.

Se encontró también que el problema antes descrito, especialmente en cuanto a la producción y muerte de árboles, se debió al daño realizado por hongos patógenos y plagas insectiles ambos favorecidos por el cambio climático (Ministerio de Agricultura y Riego, 2013). Asimismo se halló correlación o dependencia del daño realizado por estas plagas con el incremento de la temperatura (Mapa 5-7), la disminución de humedad relativa y probablemente algunos años de sequías⁸.



Figura 5-14. Comparación del bosque seco de un periodo a otro (Ministerio de Agricultura y Riego, 2013)

En la foto de la izquierda (setiembre de 2012), la planta luce verde y con bastante follaje, tiene un aspecto bueno; la misma planta, en la foto de la derecha (febrero de 2013), tiene menos follaje, algunas ramas secas y un aspecto regular. Se puede apreciar el cambio ocurrido tras cinco pocos meses (Ministerio de Agricultura y Riego, 2013).

Se ha realizado un gráfico de dispersión entre la tendencia de la degradación y el uso del suelo porque la degradación generalmente guarda mucha relación con el uso que se le da a la tierra, ya

⁸ La sequía es definida como la falta de lluvias durante un período prolongado de tiempo que produce sequedad en los campos y escasez de agua.

que el ambiente es un sistema equilibrado y si algún componente se deteriora entonces el sistema falla y el resultado es una lenta degradación debido al mal uso que se le da a la tierra.

Tabla 5-2. La relación entre el verdor de la vegetación y la temperatura superficial guarda una relación

Uso Actual del Suelo - Eje Y	Clase - Eje X
Agricultura Intensiva	1
Agricultura Semi Intensiva	2
Agricultura Temporal	3
Aguas Continentales	4
Aguas Marinas	5
Bosque Natural	6
Espacios con Vegetación Escasa	7
Pecuario Extensivo - Agricultura Temporal Fraccionado	8
Sin Uso	9
Sistemas Agroforestales	10
Sistemas Silvopecuario	11
Vegetación Arbustiva y/o Herbáceas Naturales	12
Zonas Húmedo Continentales	13
Zonas Urbanas	14

La Tabla 5-2 se puede agrupar en dos clases. Un grupo donde los usos del suelo tienen tendencia de degradación negativa y al mismo tiempo tendencia de la temperatura superficial positiva, y otro grupo donde la tendencia de la degradación no es muy significativa y la tendencia de la temperatura de superficie no es tan considerable. La Tabla 5-2 queda agrupada en la Tabla 5-3.

Tabla 5-3. Agrupación del uso del suelo en función a la tendencia de la degradación

Uso Actual del Suelo - Eje Y	Clase - Eje X
Clases donde se aprecia cambios significativos	
Agricultura Intensiva	1
Agricultura Semi Intensiva	2
Agricultura Temporal	3
Bosque Natural	6
Pecuario Extensivo - Agricultura Temporal Fraccionado	8
Sistemas Agroforestales	10
Vegetación Arbustiva y/o Herbáceas Naturales	12
Clases donde no se aprecia cambios significativos	
Aguas Continentales	4
Aguas Marinas	5
Espacios con Vegetación Escasa	7
Sin Uso	9
Sistemas Silvopecuario	11
Zonas Húmedo Continentales	13
Zonas Urbanas	14

El comportamiento del uso actual del suelo y de la cobertura del bosque seco en relación a la tendencia de la degradación y de la temperatura superficial, se muestra en la Figura 5-15.

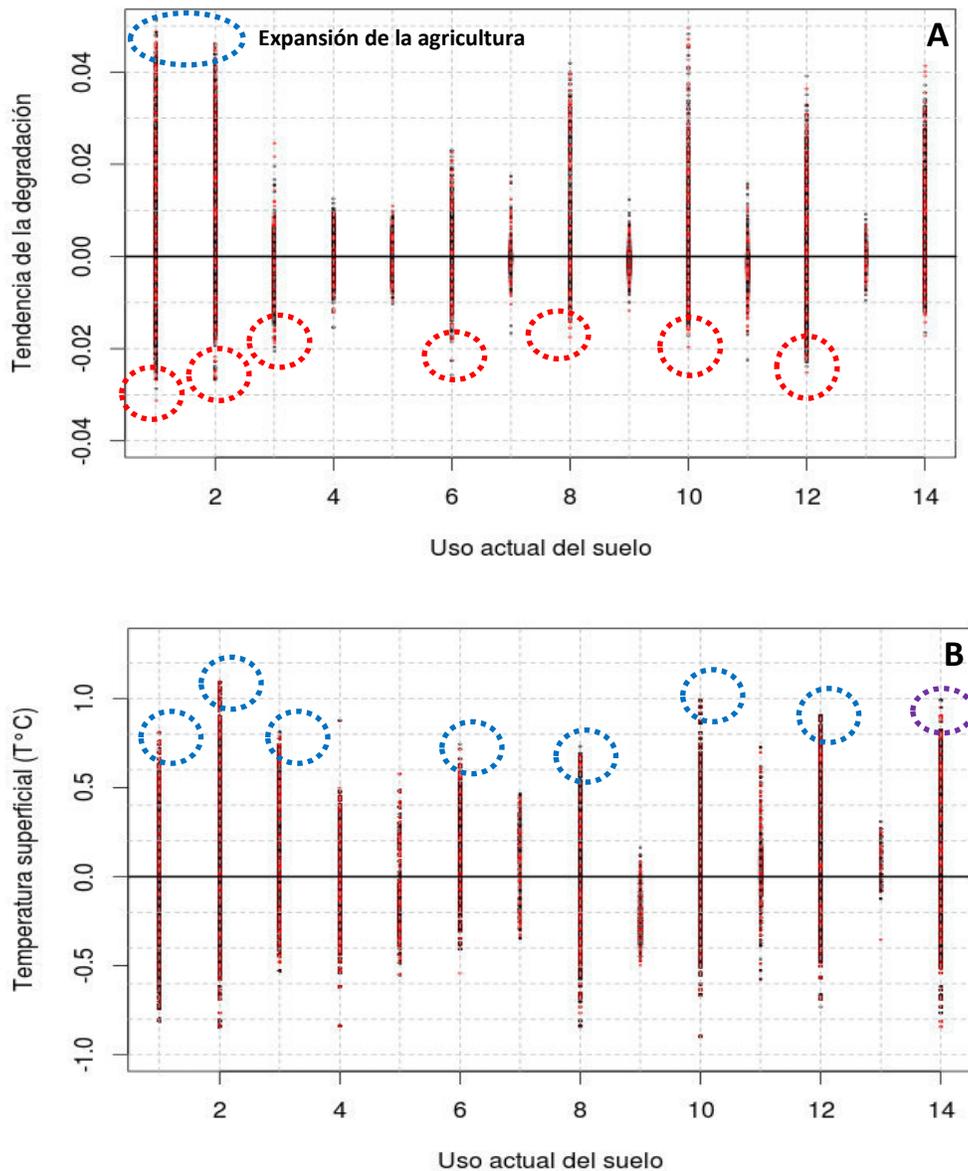


Figura 5-15. Gráfico de dispersión entre la tendencia de la degradación, tendencia de la temperatura y el uso actual del suelo.

El gráfico de dispersión (Figura 5-15), muestra la relación que hay entre la tendencia de la degradación con la tendencia de la temperatura superficial. Mientras las (clases = 1, 2, 3, 6, 8, 10, 12) disminuyen en la Figura 5-15 A, en la Figura 5-15 B aumentan su temperatura. Esto resulta muy interesante ya que la tendencia de la degradación negativa se da principalmente en la cobertura de bosque seco y a su vez esto es respaldado por un aumento leve de la temperatura de superficie (Mapa 5-7) en esta misma zona. Por otro lado, el valle agrícola denominado como uso agrícola según la Zonificación Ecológica Económica de la región Piura,

presenta una tendencia negativa en la disminución del índice EVI (Figura 5-15 A), esto debido principalmente a la salinización. Sin embargo, la salinización no es el único problema presenta, también la deforestación de los bosques, la deflación eólica originada en zona secas, áridas y semiáridas, dondequiera que la superficie del terreno este seca y recubierta de pequeñas partículas del suelo o la regolita (Stralher, 1994), también suma a la degradación. Una de las características de la región Piura es su clima árido y seco donde la superficie se encuentra expuesta a la deflación, ya que el suelo está al descubierto. Todas estas perturbaciones naturales y antrópicas juegan un papel muy importante en la degradación de la tierra y tiene que ser analizada a profundidad. Esta investigación no pretende profundizar en el análisis de cada una de ellas, sino que busca mostrar de manera general cómo el estudio y análisis empírico de la radiación captada en lo sensores remotos permite identificar y cuantificar zonas degradadas plasmadas en una disminución del valor del EVI.

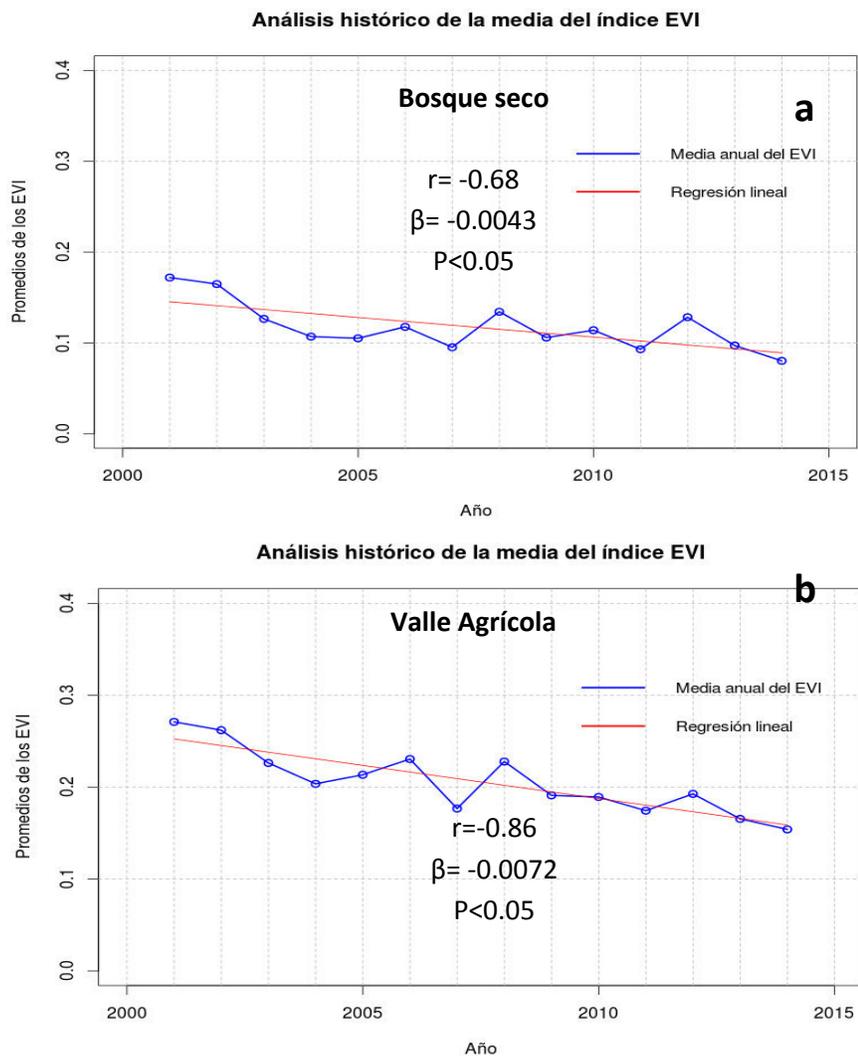


Figura 5-16. Análisis histórico de la degradación de la media del índice EVI 2001-2014. (a) Bosque seco y (b) Valle agrícola.

La Figura 5-16 corrobora lo que se ha expuesto como parte de los resultados. Y es que la media anual del índice EVI muestra una caída en la tendencia con significancia ($p < 0.05$) para el bosque seco. Lo mismo sucede dentro del valle pero esta degradación es más severa con una pendiente más pronunciada ($\beta = -0.0072$) y con el nivel de significancia ($p < 0.05$). Estos resultados muestra que los sensores van captando cada vez menos radiancia provenientes de estas coberturas, lo que indica que los factores antrópico y naturales pueden ser la causa.

El resumen, las áreas degradadas para los tipos de tierras secas en función del nivel de significancia se muestra en la Tabla 5-5, de donde se interpreta que la predicción de la gran parte de tierras en degradación se encuentra en zonas hiperáridas y zonas áridas. Por el otro extremo, las menores predicciones de tierras en degradación se encuentran en las zonas subhúmedo seco y no árido. Otro análisis que se extrae de la Tabla 5-5, tiene que ver con el nivel de significancia. Una disminución en el valor de p significa un aumento en la predicción de la degradación. En términos simples, mientras disminuimos cada vez más el valor de p , la certeza o la precisión de la predicción también disminuye. Es como si habláramos de la correlación, mientras más disminuimos el valor de p menor correlación tendremos y menor certeza de que los resultados sean buenos.

Tabla 5-4. Resumen del porcentaje de tierras degradadas en función el nivel de significancia..

	Hiperárido	Árido	Semiárido	Subhúmedo Seco	No árido	Total
P<0.05	633 423.40	299 156.97	26 590.15	5 407.43	9 193.55	
	65%	30%	3%	0.6%	1.4%	100%
P< 0.1	710 418.10	461 202.63	63 583.85	10 560.21	16 656.31	
	56%	37%	5%	0.8%	1.2%	100%

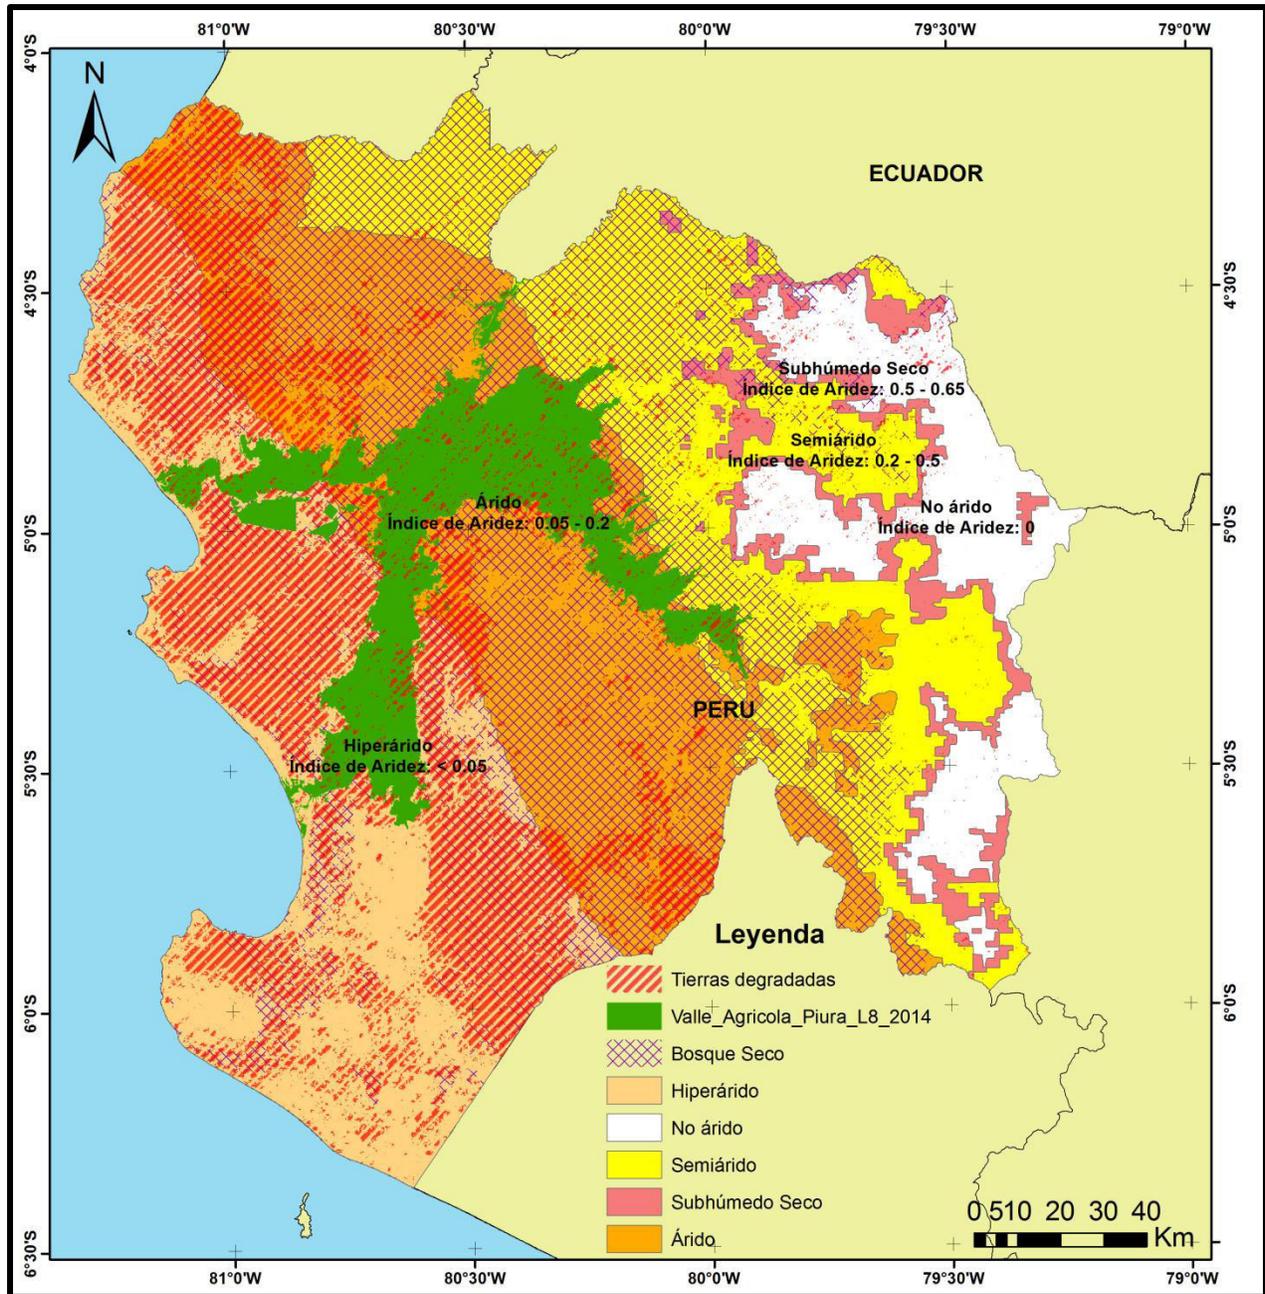
La Mapa 5-9 muestra, espacialmente, las tierras degradadas en función a las tierras secas. Las cifras estimadas por los estudiosos de este fenómeno se aproximan. Respecto de las causas, también hay consenso: la actividad agrícola, la deforestación, el cambio climático plasmado en un aumento de la temperatura superficial serían los principales agentes causantes de la desertificación, junto al sobrepastoreo. Hay discusión sobre el área de degradación según estudios de Morales (2013) (Ver anexo 2).

De la Figura 5-12 y la Mapa 5-10 se realizó un cuadro donde se muestra la pérdida de suelo degradado dentro del valle, versus cuánto se ganó por la expansión agrícola tal como muestra la Tabla 5-6. Antes de cuantificar el área perdida y ganada se filtraron las ciudades en máscaras para no cuantificarlas.

		Área (Ha)
Valle agrícola	Pérdida de suelo	28 000.00
	Ganancia de suelo	41 000.00

Tabla 5-5. Ganancia y pérdida de suelo por salinización.

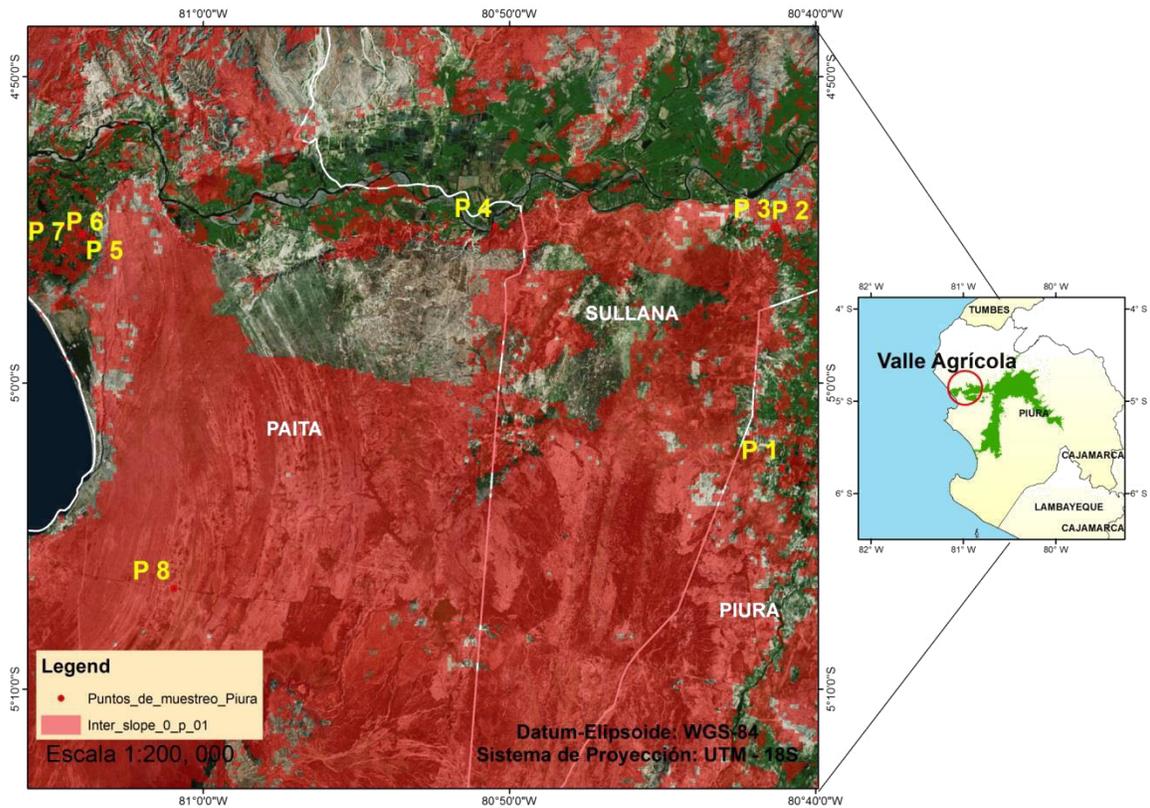
Predicción de Tierras Degradadas a Partir del Análisis de Series Temporales del Índice Mejorado de Vegetación y Temperatura de superficie de Suelo mediante Imágenes MODIS - Caso Estudio Piura



Mapa 5-9. Tierras degradadas al 95% de significancia.

5.5 Validación de los resultados (Porcentaje de acierto)

La veracidad del mapa de zonas potenciales en degradación fue validado con 7 puntos en campo tomados del mapa de degradación, luego de visitar cada uno de ellos y ser analizado en el laboratorio de la Universidad Nacional Pedro Ruiz Gallo, los cuatro de ellos resultados altamente salinos, mientras dos fueron neutro en zonas agrícolas sin problemas y un punto en los bosques secos. Los cuatro puntos salinos cayeron dentro del mapa de zonas potenciales en degradación (Figura 5-17).



ID_PUNTO	CE_1:5	CLASIFICACION	pH_1:5	CLASIFICACION
1	0.10	NO SALINO	7.38	NEUTRO
2	2.22	MUY SALINO	10.00	FUERTEMENTE ALCALINO
3	0.04	NO SALINO	7.75	MODERADAMENTE ALCALINO
4	1.62	MUY SALINO	7.87	MODERADAMENTE ALCALINO
5	5.83	MUY SALINO	7.42	MODERADAMENTE ALCALINO
6	8.78	MUY SALINO	8.99	FUERTEMENTE ALCALINO
7	0.04	NO SALINO	7.43	MODERADAMENTE ALCALINO

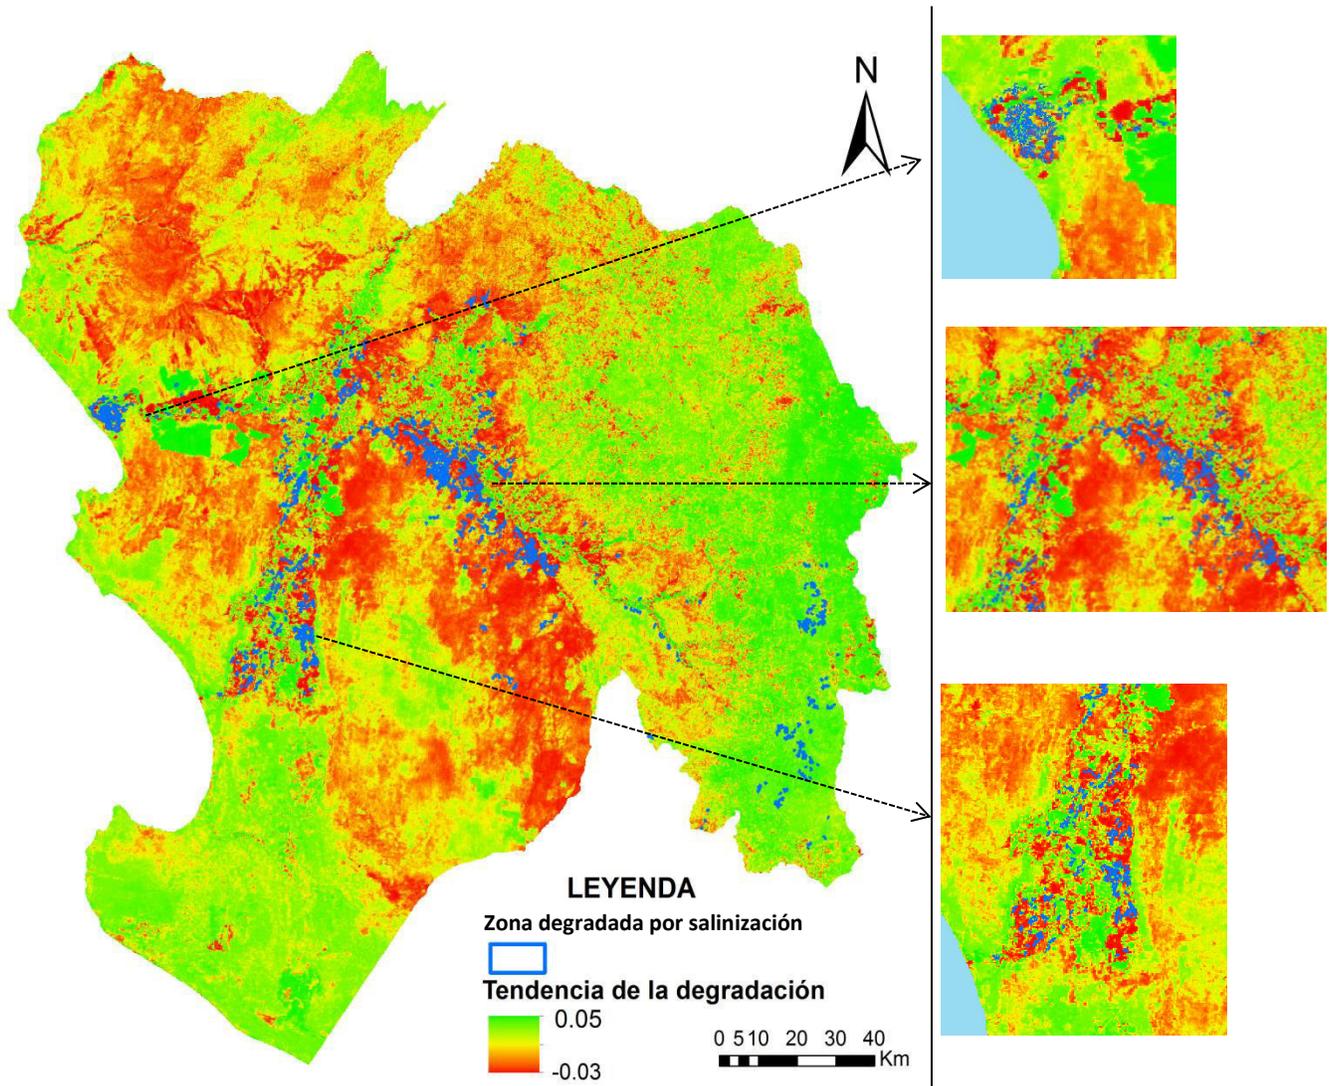
Figura 5-17. Puntos de muestreo en campo.

Además de la validación en campo, se cuenta con datos (Figura 4-11 **A**) de áreas degradadas generadas con imágenes de alta resolución como Landsat y Rapideye, a su vez estos datos obtenidos mediante imágenes de satélite fueron validados con visitas en campo. Estos datos fueron tomados en el valle agrícola y en sus alrededores (**Ver Anexo 1**). La comprobación de los resultados de la metodología presentada es bastante simple. La idea es encontrar cuánta área se superponen (intersección entre el mapa final de pendientes negativas y los datos disponibles (Figura 4-11 **A**), de manera que la intersección respecto al total (Figura 4-11 **A**), de áreas obtenidas con imágenes de alta resolución y medidos en campo, nos dará el porcentaje de acierto.

Tabla 5-6. Acierto de los datos obtenidos en campo con los resultados del mapa de pendiente.

	Datos adquiridos de degradación mediante imágenes de alta resolución y validados en campo (I)	Intersección de los datos de (I) con el mapa de pendientes con valor negativo (II)	Porcentaje de acierto II/I
Área (Ha)	20 063.16	16 891.58	84.50 %

La intersección entre el mapa de tendencias de degradación de la tierra y los vectores que representan áreas degradadas por salinización (Mapa 5-10) muestra como las áreas en tonalidad roja (áreas con probabilidad de degradación) coinciden apreciablemente con los vectores en color azul. Estos resultados visuales quedan plasmados numéricamente en la Tabla 5-6.



Mapa 5-10. Sobre-posición entre el mapa de tendencias de degradación de la tierra con los datos disponibles de zonas degradadas por salinización.

CAPITULO VI

DISCUSIÓN DE RESULTADOS

6. DISCUSIÓN DE RESULTADOS

6.1 El ruido en los datos MODIS

Hay muchas complicaciones, limitaciones y causas de error asociados a los datos de satélite, los errores de cuantificación digital (Viovy, 1992), condiciones atmosféricas (Tanre et al, 1992), la degradación orbital del sensor (Justice et al., 1985), incluida la resolución y calibración. El conjunto de datos EVI son bien documentados, las fuentes de datos de calidad son controladas y plasmadas en la banda de fiabilidad y de calidad. Al descargar los datos, el ruido está presente. Para ello, deben ser analizadas mediante serie de tiempo, filtros, suavizados e interpolaciones son necesarios. Este ruido presente en los datos se debe principalmente a la cobertura de nubes, agua, nieve y sombras, fuentes de errores que tienden a disminuir los valores EVI. Los falsos máximos, aunque muchos menos frecuentes, pueden producirse debido a errores de transmisión, tales como la línea de deserción (Viovy, 1992). Para minimizar el problema de los falsos máximos, los productos descargables generalmente se basan en observaciones de bajo ángulo siempre que sea posible. La mayoría de errores tienden a disminuir los valores del EVI. Por tanto, los valores altos de EVI (máximos compuestos anuales) son más confiables que los valores más bajos (Nathalie Pettorelli, 2005).

6.2 Interpolaciones de datos faltantes

El producto MOD13Q1 viene con una banda de fiabilidad y de calidad. Es necesario filtrar píxeles contaminados por artefactos atmosféricos con la finalidad de tener datos más confiables. Este filtro genera píxeles sin valor o "NA" que dificulta el proceso de análisis mediante cualquier algoritmo de series de tiempo, motivo por el cual es necesario interpolar o rellenar mediante algún método matemático los datos faltantes. Hay muchas metodologías que permiten interpolar datos faltantes como kriging, spline, idw, etc. Pero, todos estos métodos interpolan en la dimensión espacio (x,y) y no tienen en cuenta la dimensión tiempo (t). Se pensó utilizar kriging para interpolar imagen a imagen aquellos datos faltantes, pero, la incertidumbre de rellenar una cantidad grande píxeles condicionó el uso de estos algoritmos. Se pensó entonces, en un método que interpole en la dimensión tiempo. Dentro de las bondades que tiene R como lenguaje de programación se encuentra el paquete "forecast" que cuenta con el algoritmo "na.interp", esta función permite interpolar datos faltantes en la series de tiempo en base a la estacionalidad. Para corroborar la fiabilidad de la interpolación, se generó el mapa de tendencias con imágenes de la estación seca de todo Piura. En esta época la nubosidad es nula y ello permitió generar las tendencias. La diferencia de las tendencias con los datos interpolados con la tendencia con datos de imágenes MODIS en estación seca, solo discrepó en un 2.15% del total de este último. Haciendo un estudio más detallado se encontró que hubo comisión como omisión de las tendencias interpoladas respecto a lo real (Figura 6-2). Estos errores en las interpolaciones son debido a la cantidad de datos por rellenar en una serie de tiempo. Es distinto tener 3 o 4 datos a tener más de 5 (Figura 6-1). La bibliografía

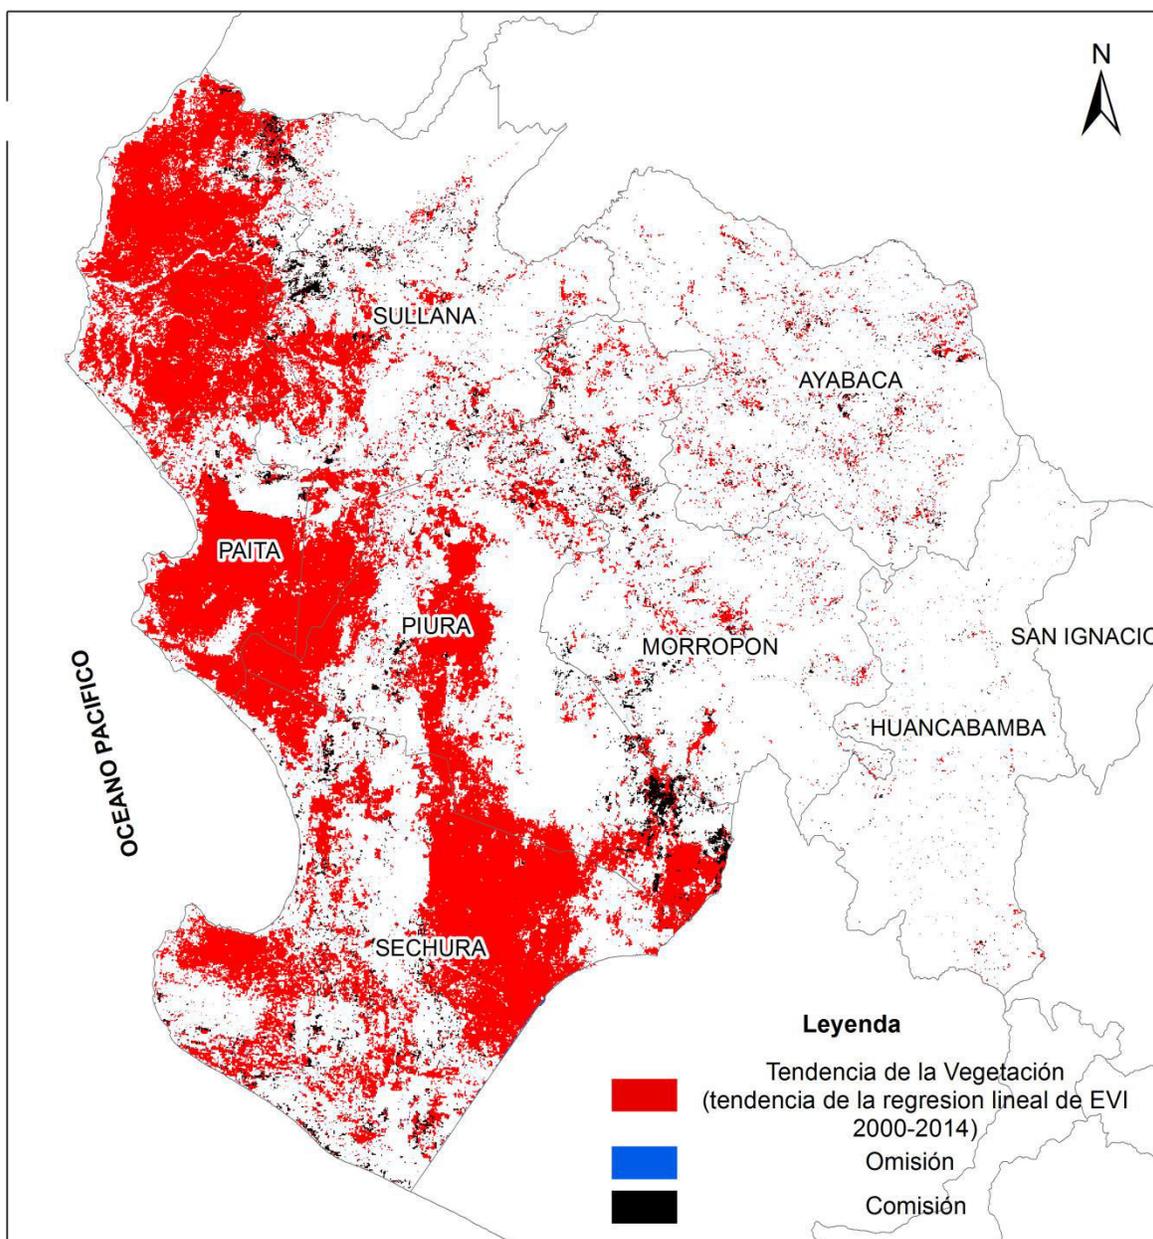
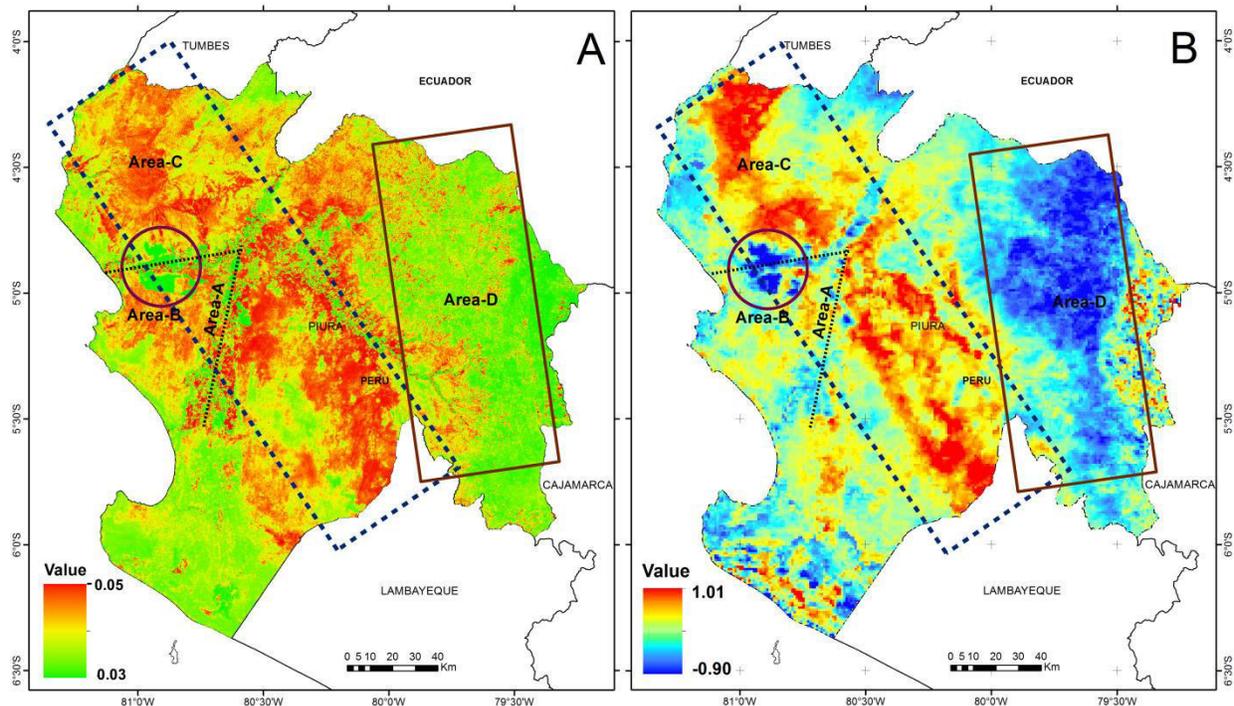


Figura 6-2. Los datos interpolados discreparon en un 2.15% de los datos reales, habiendo comisión y omisión; sobre todo comisión.

6.3 Tendencia de la degradación

El periodo de evaluación tiene una gran influencia en la detección de tendencias lineales. Esto nos alerta sobre el hecho que una evaluación en las tendencia solo es aplicable a un periodo determinado y que las tendencias monótonas pueden cambiar notablemente en la adición de años adicionales en la serie de tiempo (Wessels et al., 2012).

En casi todos los estudios, el inicio de la serie de tiempo es determinado por el inicio del registro de datos por satélite, en este estudio el año de inicio de los datos es 2001, sin embargo los datos MODIS están disponibles a partir del 2000. Se eligió comenzar a partir del 2001 porque los máximos anuales se dan durante los meses de diciembre a marzo y los datos MODIS están a partir de febrero de 2000, por lo que es preferible saltarse un año a tener un valor falso en los datos anuales. Los primeros años de las series de tiempo tienen una fuerte influencia en las evaluaciones de tendencia, sobre todo porque a menudo son tratados de manera implícita como un periodo de referencia (pre-degradación) (Veron, 2006). Si los primeros años coinciden con una sequía o un periodo inusualmente húmedo, o si la degradación ya ha ocurrido antes de esa fecha, la validez de la evaluación se ve comprometida (Wessels et al., 2012). El periodo exacto de la evaluación tiene una influencia grande, pero impredecible. Además, la disponibilidad de datos por satélite es un factor importante, porque una serie de tiempo más larga mejora el poder del análisis tendencial. Sin embargo, la longitud de la serie puede ser de poca utilidad si la degradación comienza temprano o tarde en la serie (Wessels et al., 2012). Por lo tanto, los resultados ponen de manifiesto las dificultades asociadas con el uso de un indicador que cambia rápidamente (EVI) para describir y detectar cambios en un proceso gradual como la degradación (Verstraete, 2009).



Mapa 6-1. En el panel A se muestra la tendencia del índice y las regiones con mayor importancia en la interpretación de los resultados. En el panel B se muestra la tendencia de la temperatura superficial del suelo.

La Mapa 5-9 muestra claramente las predicciones en degradación para las tierras secas, para la cobertura del bosque seco y para el valle agrícola. Para las zonas degradadas dentro del valle, se tuvieron que eliminar usos como ciudades antes de calcular el total de suelos perdidos. Además, algunas píxeles con posible degradación cayeron dentro de zonas de expansión agrícola, por lo que fue necesario eliminar estos píxeles también.

El área A de la Mapa 6-1 muestra zonas de agricultura con una tendencia negativa del índice de vegetación y una tendencia de la temperatura de superficie de suelo al lado izquierdo y derecho respectivamente. Las condiciones de aridez y topográficas del lugar, así como la elevación de la napa freática debido a prácticas continuas de riego en las partes media y altas, promueven la ocurrencia de degradación de suelos por salinización (Elisabeth, Bui., 2013).

El área B de la Mapa 6-1 representa la expansión agrícola. Mientras en la lado izquierdo de la Mapa 6-1 la tendencia del EVI fue positivo en tonalidad verde, al lado derecho de la Mapa 6-1 muestra tendencia negativa de la T_s . La explicación se centra en el intercambio de energía a través del calor sensible a calor latente de vaporización disminuyendo la temperatura del ambiente que lo contiene. Por cada gramo de agua evaporado, cerca de 600 calorías de calor sensible pasan en forma de calor latente (Stralher, 1994).

La cobertura del bosque seco que se encuentra dentro de las tierras secas hiperáridas y áridas; muestra tendencia negativa del EVI para el periodo 2001-2014; a su vez, por balance de radiación terrestre, esta disminución en la cobertura y fenología del bosque experimenta una tendencia en el aumento de la temperatura de superficie de suelo (Mapa 6-1 B). Por lo tanto, la variabilidad climática está afectando no solo al desarrollo fenológico y producción del algarrobo con el incremento leve de la temperatura, sino que está dando origen a la proliferación de plagas debido al estrés hídrico que sufren los bosques secos (MINAM, 2012). El área D de la Mapa 6-1 resalta tanto en la tendencia del índice como en la tendencia de la T_s que para el periodo 2001-2014 las condiciones de precipitación hicieron que la vigorosidad de la vegetación se mantenga estable con una leve mejora (Mapa 6-1 A).

6.4 Síndromes de la degradación en los usos del suelo.

Los síndromes de la degradación como la agricultura, la sobreexplotación y la variabilidad climática están acelerando la desertificación en Piura. Haciendo una estadística de qué porcentaje de los usos están siendo afectados por la degradación, se encontró que todos los usos de la Tabla 6-1 tiene zonas degradadas, pero los usos más preocupantes y que ameritan un estudio más detallado de las causas son: i) Vegetación arbustiva y/o herbácea con 37% y ii) bosque natural y pecuario extensivo con 22% y 21% respectivamente.

Tabla 6-1. Síndromes de la degradación en los usos actuales.

Uso actual	Área con p<95%	Área total del Uso	% Degradación
Agricultura Intensiva	21642.38	226025.92	10
Agricultura Semi-Intensiva	2007.90	44266.59	5
Agricultura Temporal	6433.99	67338.64	10
Bosque Natural	169951.43	775951.85	22
Pecuario Extensivo - Agricultura TF	343272.26	1615942.51	21
Sistemas Agroforestales	1285.26	18967.69	7
Vegetación Arbustiva y/o Herbáceas N	119761.31	324856.55	37

6.5 Detección del periodo de cambio

La detección de las rupturas en las series de tiempo mediante BFAST permitieron identificar los años de inicio de la expansión agrícola basadas en tendencias lineales a trozos (Jan Verbesselt A. Z., 2012). Es decir, BFAST no asume monótona las tendencias a lo largo de la serie temporal; sino que, utilizando la serie completa de EVI permite, además, la distinción de los componentes de una serie añadidos con mayor poder estadístico en la detección de cambios (Jong et al., 2011). Se pensó que este enfoque podría ser el más adecuado para la detección de los cambios fenológicos en segmentos específicos, sin embargo, la complejidad con que fue hecho el algoritmo imposibilita usarlo para extensas áreas debido a la sensibilidad del umbral en la detección de la degradación. Pero, si se considera analizar y detectar cambios abruptos como la expansión agrícola es posible automatizar y estudiar extensas áreas.

6.6 Validación de los resultados

La validación del mapa final de predicción de la degradación y los datos espaciales de degradación por salinización brindados por el Laboratorio de Teledetección-UNMSM coincidieron en un 85% aproximadamente (Tabla 4). Implícitamente el mapa generado de degradación de tierras tiene un nivel de confianza del 95%, es decir, que los resultados mostrados tienen una probabilidad alta de haber sufrido cambios negativos en la cobertura por causas diversas (Anyamba et al., 2005).

CAPITULO VII

CONCLUSIONES

7. CONCLUSIONES

Los algoritmos empleados para el análisis de series temporales permitió analizar y corregir la calidad de los datos de satélite, siendo indispensable los filtros y suavizados de series como pre-procesamiento antes de interpretar los valores históricos de los mismos.

La metodología establecida mediante el análisis matemático y estadístico de los datos, permitió predecir no solo tierras en degradación, sino que además; se pudo identificar el periodo de cambio de cobertura debido a la expansión agrícola en la Región.

Las reducciones del EVI en diversas magnitudes plasmadas en la representación lineal, muestran posibles manifestaciones de degradación de la tierra. En conclusión, las tendencias negativas significativas son identificadas mediante las regresiones lineales. La reducción del EVI plasmada en una tendencia negativa, fue más fuerte e intensa debido a causas como la salinización, erosión y deforestación tanto en los valles agrícolas como en los bosques secos.

La interpretación de las tendencias debidas al aumento o disminución probable en la precipitación (reflejadas en la temperatura superficial y el estrés hídrico), siguen siendo uno de los mayores desafíos a la hora de monitorear la degradación. Y es que analizar picos elevados en una serie de tiempo podrían ser reflejos de un aumento en la precipitación y por ende una disminución en la temperatura de superficie. Y por el contrario, los valores bajos podrían indicar una disminución en la precipitación (aumento en la temperatura superficial-estrés hídrico) o perturbaciones antrópicas como salinización, deforestación, erosión, etc.

La desertificación en las zonas secas ocurre porque estos ecosistemas son extremadamente vulnerables a la sobreexplotación y a los usos inadecuados. La pobreza, la deforestación, el sobre pastoreo y las prácticas inadecuadas de irrigación son las causas que socaven la productividad de la tierra. Los motores de la desertificación o degradación en tierras secas van desde motores climáticos, destacando la baja humedad del suelo, la elevada evaporación y las actividades humanas. El mapa final de degradación (Mapa 5-9) muestra la mayor concentración de pérdida de tierras en las zonas hiperáridas y áridas. La mayor explicación de estos resultados se centra en la variabilidad climática. Es decir, el incremento actual de la temperatura superficial y del aire está originando que las tierras secas se desertifiquen cada vez más, llegando incluso a convertirse en desiertos siendo este proceso irreversible.

La validación de este trabajo mediante los vectores de degradación por salinización proporcionados por LABTEL – UNMSM coincidieron en un 85% aproximadamente, esto indica que la metodología empleada para la predicción de la degradación de tierras puede ser reaplicada para monitorear otras regiones del Perú con las mismas condiciones climáticas. Por otro lado las muestras tomadas en campo y luego del análisis en el laboratorio, corroboraron el mapa de degradación resultando 5 puntos salino y muy salino, mientras otros tres puntos como neutro. Sin embargo el mapa generado de degradación de tierras tiene un nivel de confianza del 95%, es decir, que los resultados mostrados tienen una probabilidad alta de haber sufrido cambios negativos en la cobertura por causas diversas, ya que solo el 5% de todos los resultados importantes, son falsos negativos.

La teledetección por satélite siguen siendo el único medio asequible y no oneroso para el seguimiento de la dinámica de la vegetación a escala regional, pero la detección de niveles e intensidades de degradación de la tierra inducida por el hombre o por la variabilidad climática, requiere de metodologías, procedimientos analíticos y matemáticos sensibles al cambio, capaces de hacer frente a la variabilidad de las temperaturas interanuales. Por ello el análisis tendencial resulta hasta ahora un enfoque accesible y oportuno para el monitoreo de la degradación a escala regional o global.

8. RECOMENDACIONES

Si bien es cierto, solo un 2.15% del total de series interpoladas amerita una reconsideración de los resultados, es mejor no usar estos píxeles para la extracción de estadísticas finales.

En lo posible generar máximos compuestos anuales para las imágenes de temperatura de superficie de suelo (LST), esto para evitar posibles píxeles contaminados por artefactos atmosféricos que influyen en los resultados y la interpretación final de los datos.

Siendo la degradación de la tierra un proceso dinámico y complejo, se recomienda analizar y estudiar otras variables como la precipitación, índices de sequía y de alguna manera estudiar también la Productividad Primaria Neta aun cuando esta tenga una resolución gruesa, pero su análisis correlacionado con otras variables ayudaría de alguna manera a estimar mejor la degradación de la tierra.

Finalmente las decisiones políticas importantes y de gestión, no deben basarse en mapas de tendencias (pendientes) que no hayan sido suficientemente bien validados o evaluados en términos de su sensibilidad en la detección de cambio.

9. GLOSARIO

AVHRR: Signal de Advanced Very High Resolution Radiometer, sensor montado sobre la plataforma NOAA.

Banda: Intervalo de longitud de onda dentro del espectro electromagnético. Por extensión, se denomina banda a cada uno de los canales de adquisición de datos de un sistema sensor.

BRDF: Sigla de bidirectional reflectance distribution function, función de distribución de reflectancia bidireccional. Representa la proporción de radiación reflejada por una determinada superficie en cada dirección del rayo reflejado proyectada sobre el plano horizontal.

Degradación de la tierra: Pérdida en la capacidad de producir bienes y servicios debido a perturbaciones naturales y antrópicas.

Dispersión no selectiva: Dispersión de la radiación en el seno de la atmósfera producida por aerosoles, cuyo tamaño de coloides es suficientemente grande para afectar a todas las longitudes de onda. Es suma de efectos de reflexión, refracción y difracción.

Dispersión: Fenómeno por el cual la radiación electromagnética es desviada de su trayectoria original, como consecuencia de los choques entre los rayos luminosos y las partículas atmosféricas, ya sean éstas las moléculas de los gases que la constituyen o aerosoles en suspensión.

Escena: Área terrestre abarcada por una imagen adquirida por un sistema de teledetección.

Espectro electromagnético: Sucesión creciente de longitudes de onda de todas las radiaciones conocidas.

EVI: índice de vegetación de diferencia normalizada para analizar la vigorosidad de la vegetación.

Filtro: Operador local mediante el cual se obtiene una nueva imagen cuyos ND son función de los ND originales y de los de las celdas contiguas. Dependiendo del tipo, se utilizan para suavizar y eliminar ruido, o bien para realzar los rasgos lineales de una imagen.

FOV: Sigla de field of view, campo de visión de un instrumento sensor o ángulo de apertura. Es el ángulo bajo el cual se observa una línea completa de imagen desde la situación del sensor.

IFOV: Sigla de instantaneous field of view, campo de visión instantáneo. Es la sección recta del ángulo sólido sustentado por una celda de terreno, es decir, la superficie que el sensor es capaz de observar en un instante determinado, sin tener en cuenta la propia capacidad de barrido.

Ley de desplazamiento de Wien: Ecuación expresa la relación inversamente proporcional que existe entre la longitud de onda para la cual la radiación emitida desde un cuerpo es máxima y la

temperatura absoluta. Al ser inversa, esa longitud de onda de máxima radiación se desplaza hacia valores más pequeños a medida que crece la temperatura.

Longitud de onda: Distancia entre dos nodos o dos valles consecutivos de una onda. En el caso de la radiación electromagnética, es el recíproco de la frecuencia de dicha radiación multiplicada por la velocidad de la luz. De su longitud de onda derivan la mayor parte de las propiedades de la radiación electromagnética. La clasificación del espectro electromagnético en regiones espectrales consiste en la agrupación de aquellos intervalos de longitud de onda en los cuales la radiación tiene comportamientos electromagnéticos similares.

Mie: Tipo de dispersión atmosférica causado por partículas de tamaño similar a una determinada longitud de onda. Se asocia a la dispersión causada por los aerosoles atmosféricos.

NDVI: Sigla de Normalized Difference Vegetation Index, índice de vegetación de diferencia normalizada.

Píxel: Abreviatura de picture element, cada una de los elementos que componen una imagen dispuestos matricialmente en filas y columnas.

Puntos de control: Son una serie de puntos utilizados en la búsqueda de las funciones de transformación que permitan la corrección de las distorsiones de una imagen.

Radiancia: Es la cantidad de energía radiada desde un objeto en la unidad de tiempo por cada unidad de ángulo sólido y de unidad de superficie del objeto perpendicular a la dirección de propagación. Es el parámetro físico medible con un radiómetro.

Rayleigh: Tipo de dispersión atmosférica producida por partículas cuyo tamaño es pequeño en comparación con la longitud de onda de la radiación. Se asocia normalmente al tipo de radiación causada por las moléculas de los gases atmosféricos.

Reflectancia: Medida de la capacidad de una superficie para reflejar energía electromagnética en una determinada longitud de onda. Es la razón existente entre el flujo reflejado y el incidente sobre dicha superficie. Aplicado al espectro visible, suele hablarse de albedo.

Resolución: Capacidad de un sistema sensor para distinguir información de detalle en un objeto. En teledetección se habla de distintos tipos de resolución: espacial, espectral, radiométrica y temporal.

Ruido: Todos aquellos errores aleatorios introducidos en la imagen durante el proceso de adquisición, transmisión o grabación de la misma. Producen la alteración de los niveles digitales que corresponderían a la escena real. El proceso de análisis de la señal debe ser capaz de distinguir y separar las alteraciones que son consecuencia del ruido sin eliminar con ello información sustancial de la imagen.

Signatura o firma espectral: Forma característica del espectro de emisión/reflexión de una determinada superficie. Como cada material posee bandas de absorción diferentes de acuerdo a su composición química, la energía solar reflejada será la complementaria a la incidente más la virtualmente emitida por aquélla. En consecuencia, el espectro de un objeto será una señal prácticamente inequívoca de su composición del mismo. La única restricción que se impone a la identificación de superficies mediante la teledetección deriva de la propia resolución espectral del sensor, el cual no es capaz de proporcionar un espectro continuo de la superficie observada sino de un número finito de bandas, dentro de cuyos intervalos espectrales no puede hacer distinción alguna. La teledetección hiperespectral, que proporciona una gran cantidad de bandas para cada imagen, acerca el diagrama de signaturas obtenido a la verdadera signatura espectral de la superficie, y con ello facilita su identificación.

10. BIBLIOGRAFÍA

- Anyamba, A., & Tucker, C. J. (2005). Analysis of Sahelian vegetation dynamics using NOAA-AVHRR NDVI data from 1981–2003. *Journal of Arid Environments*, 63, 596–614.
- Azzali, S., & Menenti, M. (2000). Mapping vegetation-soil-climate complexes in southern Africa using temporal Fourier analysis of NOAA-AVHRR NDVI data. *International Journal of Remote Sensing*, 21, 973–996.
- Bai, Z. D. (2008). Proxy global assessment of land degradation. *Soil Use and Management*(24), 223-234.
- Bai, Z. D. (2008). Proxy global assessment of land degradation. *Soil Use Manage*, 24, 223–234.
- Bastin, G. N. (1995). Utility of AVHRR data for land degradation assessment: A case study. *International Journal of Remote Sensing*, 16, 651–672.
- Bayarjargal, Y., Karnieli, A., Bayasgalan, M., Khudulmur, S., Gandush, C., & Tucker, C. J. (2006). A comparative study of NOAA–AVHRR derived drought. *Remote Sensing of Environment*, 105, 9-22.
- Berry, J. O. (2003). *ASSESSING THE EXTENT, COST AND*. Commissioned by Global Mechanism.
- Beurs, K. M. (2005). A statistical framework for the analysis of long image time series. *International Journal of Remote Sensing*, 26, 1551–1573.
- Boegh, E., Soegaard, H., Hanan, N., Kabat, P., & Lesch, L. (1998). A remote sensing study of the NDVI–Ts relationship and the transpiration from sparse vegetation in the Sahel based on high resolution satellite data. *Remote Sensing of Environment*, 69 (3), 224-240.
- Boriah, S. (2010). *Time Series Change Detection: Algorithms for Land Cover Change*. USA: Universidad de Minnesota.
- Carcedo, J. M. (2000). *Introducción al Tratamiento de Series Temporales Mediante Filtros*. Madrid: Universidad Autónoma de Madrid.
- Cardille, J. A. (2003). Agricultural land-use change in Brazilian Amazoⁿia between 1980 and. *Remote Sensing of Environmen*, 551 – 562.
- Carlson, T. N., Gillies, R. R., & Perry, E. M. (1994). method to make use of thermal infrared temperature and NDVI measurements to infer surface soil water content and fractional vegetation cover. *Remote Sensing Reviews*, 9, 161-173.

- Carlson, T.N., Perry, E.M. & Schmugge, T.J. (1990). Remote estimation of soil moisture availability and fractional vegetation cover over patchy vegetation. *Agricultural and Forest Meteorology*, 52, 44-60.
- Cayuela, L. (s.f.). *Luis Cayuela*. Recuperado el 25 de Agosto de 2014, de Ecología : <http://luiscayuela.blogspot.com/2009/01/uso-de-imagenes-modis-para-estimar-el.html>
- César Morales, Guillermo Dascal, Zoraida Aranibar. (2013). *Estudio de los costos de la desertificación y degradación de las tierras en el departamento de Piura (Perú)*. Santiago de Chile: Impreso en Naciones Unidas 2013-903.
- Chuvieco, E. (1990). *FUNDAMENTOS DE LA TELEDETECCION ESPACIAL*. MADRID: EDICIONES RIALP, S.A.
- CLD, L. S. (2013). *El papel de los parlamentarios en el desempeño del proceso de la Convención de las Naciones Unidas de Lucha contra la Desertificación*. Bon Germany: Secretariat of the United Nations Convention to Combat Desertification.
- Coppin, P. J. (2004). Digital change detection methods in ecosystem monitoring: a review. *International Journal of Remote Sensing*, 25, 1565–1596.
- de Jong, R., de Bruin, S., de Wit, A., Schaepman, M. E., & Dent, D. L. (2011). Analysis of monotonic greening and browning trends from global NDVI time-series. *Remote Sensing of Environment*, 115, 692–702.
- Diouf, A., & Lambin, E. (2001). Monitoring land-cover changes in semi-arid regions: Remote sensing data and field observations in the Ferlo, Senegal. *Journal of Arid Environments*, 48, 129–148.
- Elisabeth, Bui. (2013). Soil salinity: A neglected factor in plant ecology and biogeography. *Journal of Arid Environments*, 92, 14-25.
- FAO. (2011). MEDIR LA DEGRADACION DEL BOSQUE. *Revista internacionalde silvicultura e industrias forestales*, 62, 238-300.
- Fensholt, R., Rasmussen, K., Nielsen, T. T., & Mbow, C. (2009). Evaluation of earth observation based long term vegetation trends—Intercomparing NDVI time series trend analysis consistency of Sahel from AVHRR GIMMS, Terra MODIS and SPOT VGT data. *Remote Sensing of Environment*, 113, 1886–1898.
- Fensholt, R., Sandholt, I., Rasmussen, M. S., Stisen, S., & Diouf, A. (2006). Evaluation of satellite based primary production modelling in the semi-arid Sahel. *Remote Sensing of Environment*, 105, 173–188.

- Fraser, R. H., Abuelgasim, A., & Latifovic, R. (2005). A method for detecting large-scale forest cover change using coarse. *Remote Sensing of Environment*, 95, 414–427.
- Gillies, R. R., Carlson, T. N., Gui, J., Kustas, W. P., & Humes, K. S. (1997). A verification of the 'triangle' method for obtaining surface soil water content and energy fluxes from remote measurements of the Normalized Difference Vegetation Index (NDVI) and surface radiant temperature. *International Journal of Remote Sensing*, 15, 3145–3166.
- Gobierno Regional de Piura. (2012). *LA ZONIFICACIÓN ECOLÓGICA ECONÓMICA (ZEE) DE LA REGIÓN PIURA*. Piura: Región de Piura.
- Goetz, S. J. (1997). Multisensor analysis of NDVI, surface temperature and biophysical variables at a mixed grassland site. *International Journal of Remote Sensing*, 18 (1), 71-94.
- Grainger, A. (1993). Controlling tropical deforestation. *Earthscan Publications Ltd*, 310.
- Holben, B. (1986). Characteristics of maximum-value composite images from temporal AVHRR data. *International Journal of Remote Sensing*, 7, 1417–1434.
- Huete, A., Didan, K., Miura, T., Rodriguez, E., Gao, X., Ferreira, L. (2002). Overview of the radiometric and biophysical performance. *ELSEVIER - Remote Sensing of Environment*, 195-213.
- Inge Sandholt, Kjeld Rasmussen. (2002). A simple interpretation of the surface temperature/vegetation index space for assessment of surface moisture status. *Remote Sensing of Environment*, 79, 213-224.
- Ingram, J. C. (2005). Inter-annual analysis of deforestation hotspots in Madagascar from high temporal resolution satellite observations. *International of Journal of Remote Sensing*, 26, 1447–1461.
- Jan Verbesselt, A. Z. (- de Agosto de 2012). Near Real-Time Disturbance Detection Using. (W. o. Science, Ed.) *ELSEVIER*, 98-108.
- Jan Verbesselt, R. H. (2010). Phenological Change Detection while Accounting. *Remote Sensing of Environment*, 2970–2980.
- Jeffrey A. Hicke, G. P. (2002). Trends in North American net primary productivity derived from. *GLOBAL BIOGEOCHEMICAL CYCLES*, 16, 1018-1029.
- John A. Richards, X. J. (2006). *Remote Sensing Digital* (4th Edition ed.). Germany: Springer.
- Justice, C.O. et al. (1985). Analysis of the phenology of global vegetation using meteorological satellite data. *International Journal of Remote Sensing*, 6, 1271-1318.

- Kamel Didan, A. H. (s.f.). NASA-USGS. Recuperado el 21 de Octubre de 2013, de https://lpdaac.usgs.gov/products/modis_products_table/mod13q1
- Kasperson, J.X., Kasperson, R.E., Turner II, B.L. (Eds.). (1995). *Regions at Risk: Comparisons of Threatened Environments*. United Nations University Press, Tokyo/NewYork/Paris.
- Lambin, E. F. (2006). Time series of remote sensing data for land change science. *IEEE Transactions on geoscience and remote sensing*, 1926-1928.
- Lambin, E. F., & Ehrlich, D. (1996). The surface temperature –vegetation index space for land cover and land-cover change analysis. *International Journal of Remote Sensing*, 17, 463– 487.
- Lleida, D. d. (1997). *Evaluación de los procesos de salinización de suelos bajo riego*. España: Universitat de Lleida.
- Mas, J.-F. (2011). *Aplicaciones del sensor MODIS para el monitoreo del territorio* (Primera edición ed.). Mexico D.F: Secretaría de Medio Ambiente y Recursos Naturales.
- Matthew C. Reevesa, L. S. (2014). A remote sensing protocol for identifying rangelands with degradedproductive capacity. *Ecological Indicators*, 43, 172–182.
- Mauricio Labrador García, J. A. (2012). *Satélites de Teledetección para la Gestión del Territorio*. Madrid: Consejería de Agricultura, Ganadería, Pesca y Aguas del Gobierno de Canarias.
- Michael A. White, R. R. (2006). Real-time monitoring and short-term forecasting. *ScienceDirect*, 43-49.
- MINAM. (2012). *Mapa de tierras secas del Perú* (Primera edición ed.). (M. d. Ambiente, Ed.) Lima: Giacomotti Comunicación Gráfica S.A.C.
- Ministerio de Agricultura y Riego, C. a. (2013). *Adaptación al cambio climático para la competitividad agraria* . Lima Perú: Dirección General de Competitividad Agraria.
- Mora, T. J. (2010). *EVALUACIÓN DE IMÁGENES DE BAJA RESOLUCIÓN ESPACIAL BAJO DIFERENTES METODOLOGÍAS PARA EL MONITOREO Y CARTOGRAFÍA DE LA COBERTURA DEL SUELO EN MÉXICO*. México: Universidad Nacional Autónoma de México.
- Morales, C. G. (2013). *Estudio de los costos de la desertificación y degradación de las tierras en el departamento de Piura (Perú)*. Santiago-Chile: Copyright © Naciones Unidas.
- Moran, M. S., Clarke, T. R., Inoue, Y., & Vidal, A. (1994). Estimating crop water deficit using the relation between surface-air temperature and spectral vegetation index. *Remote Sensing of Environment*, 49, 246– 263.

- Myneni, R. B. (1995). Optical remote sensing of vegetation: Modeling, caveats, and algorithms. *Remote Sensing of Environment*, 51, 169–188.
- Myneni, R. M. (1995). Optical remote sensing of vegetation: modelling, caveats and algorithms. *Remote Sensing of Environment*, 51, 169-188.
- Nachtergaele. (2010). *Land Degradation*. Italia: Beta Version.
- NASA. (s.f.). *MODIS Characterization Support Team*. Recuperado el 27 de Mayo de 2015, de National Aeronautics and Space Administration : <http://mcst.gsfc.nasa.gov/calibration/known-issues>
- Nathalie Pettorelli, J. O.-M. (2005). Using the satellite-derived NDVI to assess ecological responses to environmental change. *TRENDS in Ecology and Evolution*, 20(5), 503-510.
- Nemani, R., Pierce, L., Running, S., & Goward, S. (1993). Developing satellite-derived estimates of surface moisture status. *Journal of Applied*, 32, 548– 557.
- Nemani, R.R. & Running, S.W. (1989). Estimation of regional resistance to evapotranspiration from NDVI and Thermal-IR AVHRR data. *Journal of Applied Meteorology and Climatology*, 28, 276–284.
- Prince, S. D. (1991). A model of regional primary production for use with coarse resolution satellite data. *International Journal of Remote Sensing*, 12, 1313–1330.
- Ramon Solano, K. D. (2010). *MODIS Vegetation Index User's Guide*. Arizona: The University of Arizona.
- Reed, M. B.-S. (2011). Cross-scale monitoring and assessment of land degradation and sustainable land management: a methodological framework for knowledge management. *Land Degradation & Development*, 22, 261-271.
- Reeves, Matthew C. (2014). A remote sensing protocol for identifying rangelands with degraded productive capacity. *Ecological Indicators*, 43, 172-182.
- Roy, D.P., Borak, J.S., Devadiga, S., Wolfe, R.E., Zheng, M., Desloîtres, J. (2002). The MODIS Land product quality assessment approach. *Remote Sensing of Environment*, 83, 62-76.
- Safriel, U., & Adeel, Z. (2005). *Ecosystems and human well-being: Current state and trends* (Vol. 1). London: Island Press.
- Singh, A., & Harrison, A. (1985). Standardized principal components. *International Journal of Remote Sensing*, 6, 883–896.

- Smith, R. C. G., & Choudhury, B. J. (1991). Analysis of normalized difference and surface temperature observations over southeastern. *International Journal of Remote Sensing*, 12 (10), 2021–2044.
- Stralher, A. (1994). *Geografía Física*. Barcelona: Omega, S.A., Barcelona.
- Stralher, A. (1994). *Geografía Física*. Barcelona: Omega, S.A., Barcelona.
- Tanre et al. (1992). Atmospheric correction algorithm for NOAA–AVHRR products: theory and applications. *IEEE Transactions on Geoscience and Remote Sensing*, 30, 2231-2248.
- Tongway, D.J., Hindley, N. (2004). Landscape Function Analysis: Procedures for Monitoring and Assessing Landscapes. *CSIRO Publishing, Brisbane, AU*.
- Townshend, J. (1981). Information extraction from remotely sensed data. *International Journal of Remote Sensing*, 313-329.
- UNCCD. (2013). *Una CLD fortalecida para un mundo neutro frente a la degradación de la tierra*. Alemania: Secretaría de la Convención de las Naciones Unidas de Lucha contra la Desertificación.
- UNCCD, L. C. (2013). *El papel de los parlamentarios en el desempeño del proceso de la Convención de las Naciones Unidas de Lucha contra la Desertificación*. Germany: UNCCD.
- UNESCO. (s.f.). *Glosario*. Recuperado el 17 de Octubre de 2014, de <http://www.unesco.org/mab/doc/ekocd/spanish/glossary.html>
- Van Dijk, A. e. (1997). Smoothing vegetation index profiles: an alternative method for reducing radiometric disturbance in NOAA/AVHRR data. *Photogrammetric Engineering and Remote Sensing*, 53, 1059–1067.
- Vermote, E., El Saleous, N., & Justice, C. (2002). Atmospheric correction of the MODIS data in the visible to middle infrared: First results. *Remote Sensing of Environment*, 83, 97-111.
- Veron, S. R. (2006). Assessing desertification. *Journal of Arid Environments*, 66, 751-763.
- Verstraete, M. M. (2009). Climate and desertification: Looking at an old problem through newlenses. *Frontiers in Ecology and the Environment*, 7, 421-428.
- Viovy, N. et al. (1992). The best Index slope extraction (BISE): a method for reducing noise in NDVI time-series. *International Journal of Remote Sensing*, 12, 1585-1590.
- Viovy, N. et al. (1992). The best Index slope extraction (BISE): a method for reducing noise in NDVI time-series. *International Journal of Remote Sensing*, 12, 1585–1590.

- Volker Walter. (2004). Object-based classification of remote sensing data for change detection. *Photogrammetry & Remote Sensing*, 58, 225-238.
- Washington-Allen, R.A., West, N.E., Ramsey, R.D., Efroymson, R.A., 2006. (2006). A protocol for retrospective remote sensing-based ecological monitoring of rangelands. *Rangeland Ecology & Management*, 59, 19-29.
- Washington-Allen, R.A., West, N.E., Ramsey, R.D., Efroymson, R.A.,. (2006). A protocol for retrospective remote sensing-based ecological monitoring of rangelands. *Rangeland Ecology & Management*, 59, 19-29.
- Wessels K., F. v. (2012). Limits to detectability of land degradation by trend analysis of vegetation index data. *Remote Sensing of Environment*, 125, 10-22.
- Wessels, K. P. (2007). Relevance of rangelanddegradation in semiarid northeastern South Africa to the nonequilibrium theory. *Ecological Applications*, 17, 815-27.
- Wessels, K.J., van den Bergh, F., Scholes, R.J. (2012). Limits to detectability of land degradation by trend analysis of vegetation index data. *Remote Sensing of Environment*, 125, 10-22.
- Willems, B. L. (2014). *Servicio de consultoría para la elaboración de "Mapas de Desertificación por salinización para la Región de Piura"*. Lima, Lima.
- Woodcock, C. E., Macomber, S. A., Pax-Lenney, M., & Cohen, W. B. (2001). Monitoring large areas for forest change using Landsat: generalization across space, time and Landsat sensors. *Remote Sensing of Environment*, 78, 194–203.
- Zakri, A. (2005). *Ecosystems and Human Well-Being*. Washington DC: Millennium Ecosystem Assessment.
- Zeileis, C. K.-A. (2011). *Aplicaciones Económicas con R*. Baltimore-USA: Springer.
- Zhang, X. et al. (2003). Monitoring vegetation phenology using MODIS. *Environment of Remote Sensing*, 84, 471–475.

11. ANEXOS

Anexo 1.

La metodología empleada se basa en la predicción de áreas degradadas 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 se basa en lo observado durante los trabajos de campo, en los que se pudo constatar que 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.

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), se analizaron 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, en vista de que puede ser empleado como proxy para medir la producción neta primaria. 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. 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. De otro lado, Maxwell y colegas, emplearon $NDVI_{Max}$, obtenidos de 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.

El periodo de estudio comprendió un total de 15 años (2000-2014) y los trabajos estuvieron orientados a detectar áreas valores del $NDVI_{Max}$ menores a un valor crítico (que finalmente se estableció entre 0.3 Y 0.45 para el caso de las imágenes LANDSAT), ya sea de manera permanente o que hayan evolucionado por debajo de éste. La detección de las potenciales áreas degradadas involucró los siguientes pasos:

1. Adquisición de las imágenes productos NDVI (MOD 13) del sensor MODIS y OLI a bordo del 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 $NDVI_{Max}$. 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 generados a partir del procesamiento de imágenes 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. A partir de los píxeles con valores de NDVI entre 0.3 y 0.45 del paso anterior se generaron 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.

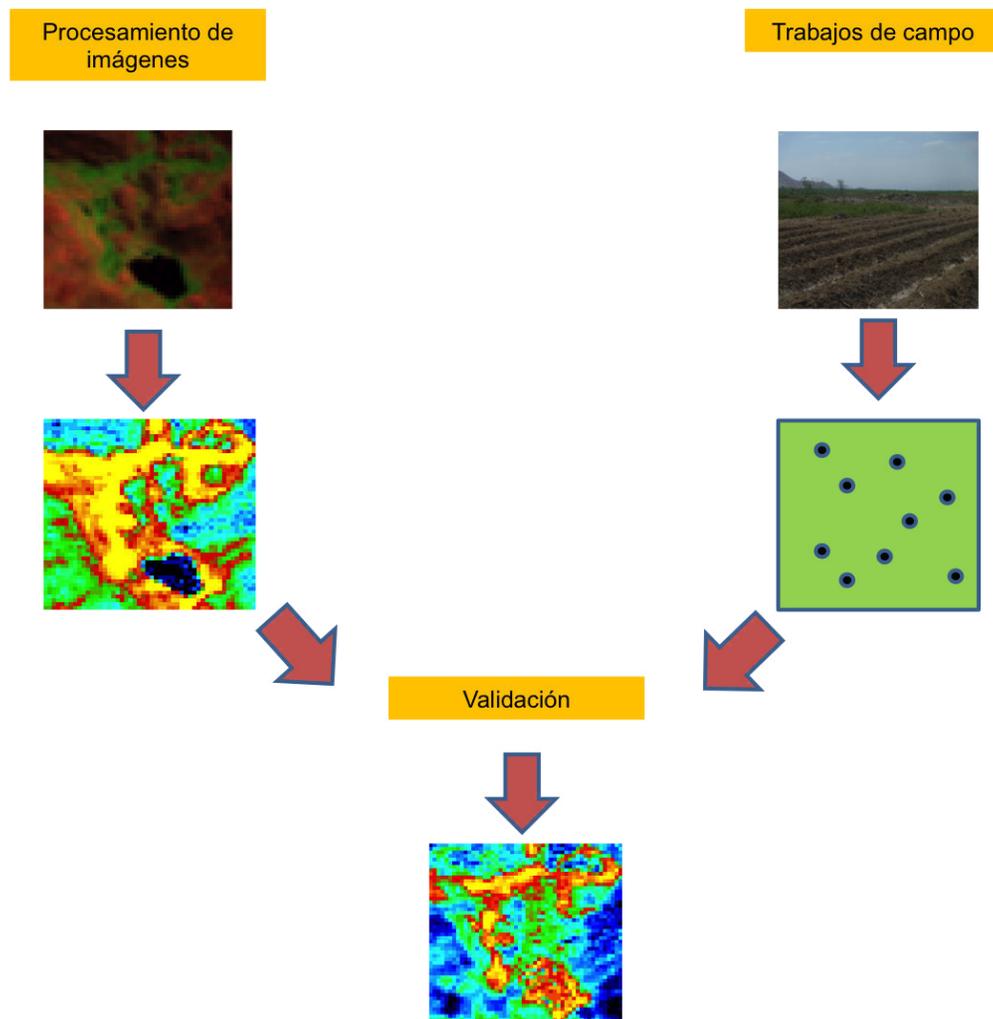
Tabla : Criterio de selección de áreas de probable degradación a partir del análisis de series temporales del producto NDVI de MODIS (MOD 13) e imágenes OLI.

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

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 (1-2 años por imagen), 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.

La validación de los resultados se complementó con información recabada durante las observaciones de campo y talleres/reuniones realizados con agricultores, representantes de las juntas de usuarios y funcionarios del Gobierno Regional. Asimismo, se analizaron un total de 134 muestras de suelos, de los que se obtuvieron los valores de 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.



Representación esquemática del proceso de elaboración del mapa de predicción de degradación de suelos.

Muestreo_Participativo_Comision_La_Union_Piura Julio 2014

X_WGS84	Y_WGS84	CE_1_5	CLASE_SALI	pH_1_5
530114	9394695	0.25	No Salino	8.15
530144	9393832	0.35	No Salino	8.42
530202	9393828	0.08	No Salino	7.45
530924	9394091	1.08	Salino	7.02
530871	9394057	0.37	Ligeramente Salino	8.69
526614	9392263	0.54	Ligeramente Salino	7.71
526588	9392227	0.29	No Salino	8.73
530531	9403125	0.16	No Salino	7.18
530872	9403026	0.54	Ligeramente Salino	7.56
531250	9402938	0.96	Salino	7.51
522547	9388411	0.11	No Salino	7.72
523093	9388390	0.10	No Salino	7.60
523112	9388432	0.08	No Salino	7.75
524517	9391134	0.20	No Salino	7.75
524511	9391164	0.19	No Salino	7.76
527907	9403364	0.38	Ligeramente Salino	7.53
527926	9403414	0.16	No Salino	7.19
527977	9403493	0.15	No Salino	7.39
527879	9403569	0.57	Ligeramente Salino	8.26
527837	9403519	0.37	Ligeramente Salino	9.29
527734	9403401	0.20	No Salino	8.20
527614	9403399	0.22	No Salino	8.85
527849	9403261	0.15	No Salino	8.25
521212	9387767	0.08	No Salino	7.52
521378	9387870	0.39	Ligeramente Salino	8.47
521554	9387716	0.89	Salino	7.70
521709	9387860	2.71	Muy Salino	7.30
521765	9387816	0.47	Ligeramente Salino	8.80
521816	9387817	0.18	No Salino	7.91
521740	9387774	0.56	Ligeramente Salino	8.79
521638	9387728	0.07	No Salino	8.24
521520	9388088	1.14	Salino	8.40
521360	9387943	0.88	Salino	7.69
521381	9387997	1.25	Muy Salino	8.08
527306	9404927	0.04	No Salino	8.29
527011	9404933	0.07	No Salino	7.63

Predicción de Tierras Degradadas a Partir del Análisis de Series Temporales del Índice Mejorado de Vegetación y Temperatura de superficie de Suelo mediante Imágenes MODIS - Caso Estudio Piura

527502	9406276	0.12	No Salino	7.84
527430	9406216	0.18	No Salino	7.13
527793	9406454	0.35	No Salino	7.59
530108	9407742	0.10	No Salino	7.72
530072	9407651	0.13	No Salino	7.74
530368	9408186	0.40	Ligeramente Salino	8.10
531325	9407811	0.07	No Salino	8.50
531266	9407882	0.17	No Salino	7.59
531266	9405266	0.78	Salino	7.24
531188	9405226	0.80	Salino	7.36
531350	9405407	0.20	No Salino	8.73
532381	9405127	0.23	No Salino	7.46
532521	9405088	0.27	No Salino	7.47
532278	9405146	0.24	No Salino	7.75
532465	9404877	0.40	Ligeramente Salino	7.41
532325	9404910	0.43	Ligeramente Salino	7.50
532229	9404937	0.12	No Salino	7.41

Muestreo_Participativo_Comision_Yusca_Piura – Julio 2014

X_WGS84	Y_WGS84	CE_1_5	CLASE_SALI
574159	9471421	0.33	NO SALINA
574240	9471304	0.09	NO SALINA
574188	9470470	0.24	NO SALINA
574333	9470414	0.15	NO SALINA
574438	9470613	0.01	NO SALINA
574443	9470753	0.14	NO SALINA
585011	9483409	0.11	NO SALINA
585017	9483369	0.03	NO SALINA
584970	9483691	0.12	NO SALINA
584946	9483582	0.07	NO SALINA
585021	9483534	0.09	NO SALINA
584920	9483896	0.10	NO SALINA
584865	9483738	0.14	NO SALINA
585066	9483764	0.09	NO SALINA
585106	9483715	0.05	NO SALINA
585158	9483644	0.09	NO SALINA
585781	9483534	0.04	NO SALINA
585801	9483599	0.04	NO SALINA
584792	9483456	0.08	NO SALINA
584740	9483698	0.14	NO SALINA
584793	9483559	0.10	NO SALINA
583913	9483388	0.17	NO SALINA
583935	9483282	0.16	NO SALINA
584037	9483240	0.10	NO SALINA
583619	9483319	0.09	NO SALINA
583540	9481278	0.15	NO SALINA
583397	9481357	0.05	NO SALINA
583617	9481343	0.08	NO SALINA
582567	9481824	0.12	NO SALINA
582629	9481842	0.07	NO SALINA
582545	9481557	0.42	LIGERAMENTE SALINO
583038	9481618	1.15	SALINO
582814	9481738	0.20	NO SALINA
582297	9481820	0.07	NO SALINA
582242	9481905	0.09	NO SALINA
582112	9481838	0.21	NO SALINA
582158	9481764	0.09	NO SALINA

Predicción de Tierras Degradadas a Partir del Análisis de Series Temporales del Índice Mejorado de Vegetación y Temperatura de superficie de Suelo mediante Imágenes MODIS - Caso Estudio Piura

581921	9481810	0.31	NO SALINA
580624	9478501	1.73	MUY SALINO
580542	9478436	3.44	MUY SALINO
579489	9478808	0.60	LIGERAMENTE SALINO
580024	9478723	0.09	NO SALINA
579976	9478405	2.06	MUY SALINO
579560	9478217	0.28	NO SALINA
579512	9478195	1.54	MUY SALINO
579483	9478138	1.13	SALINO
580266	9478210	0.12	NO SALINA
580111	9478274	0.59	LIGERAMENTE SALINO
580117	9478067	0.54	LIGERAMENTE SALINO
580331	9477924	0.08	NO SALINA
580506	9477913	0.07	NO SALINA
580366	9477791	0.13	NO SALINA
580230	9477891	0.08	NO SALINA
580326	9477755	0.10	NO SALINA
580230	9477560	0.13	NO SALINA
580328	9477370	0.07	NO SALINA
582904	9481497	1.06	SALINO
582823	9481008	0.03	NO SALINA
583427	9481249	0.09	NO SALINA
583048	9481485	0.10	NO SALINA
582943	9481350	0.18	NO SALINA
582738	9481223	0.11	NO SALINA
583006	9481151	0.82	SALINO
582858	9480860	0.17	NO SALINA
582519	9481039	0.12	NO SALINA
582469	9481324	0.17	NO SALINA
582161	9481039	0.07	NO SALINA
579102	9478159	0.12	NO SALINA
579004	9478037	0.27	NO SALINA
578902	9478102	0.32	NO SALINA
579151	9477068	0.15	NO SALINA
579067	9477053	0.08	NO SALINA
579247	9477010	0.20	NO SALINA
578949	9477286	0.13	NO SALINA
579029	9477243	0.32	NO SALINA
579057	9477192	1.66	MUY SALINO

575498	9477001	0.08	NO SALINA
575480	9477260	0.08	NO SALINA
575551	9477412	0.06	NO SALINA
579784	9476598	0.60	LIGERAMENTE SALINO
579826	9476507	0.18	NO SALINA

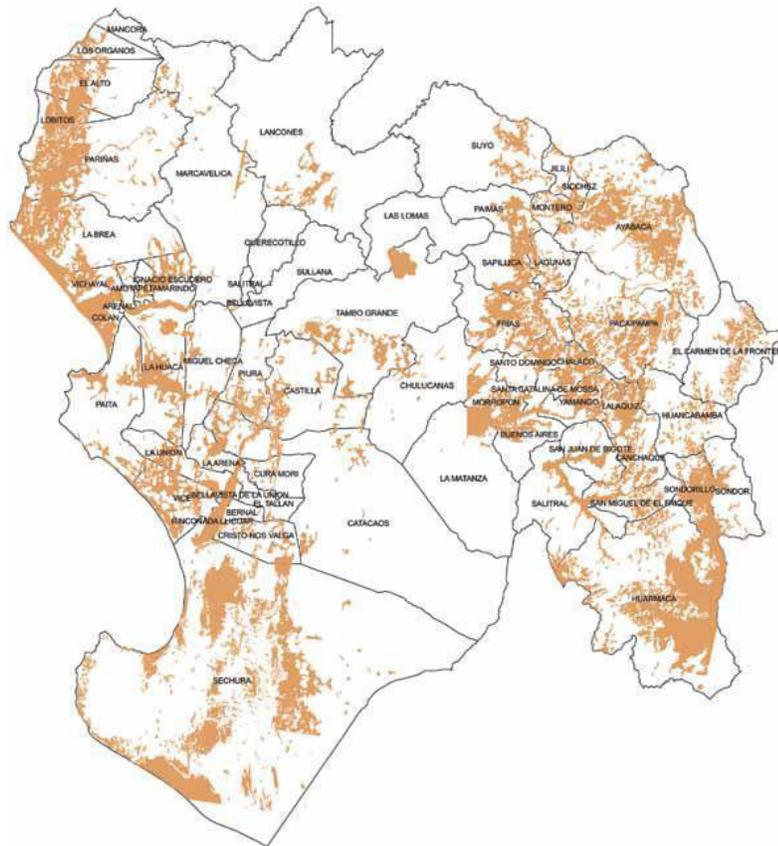
Anexo 2.

Estudios de degradación de la tierra por el CEPAL.

Siendo la superficie total de la Región Piura 3.589.250 ha de acuerdo al estudio, el área afectada por desertificación y deforestación alcanza los 19,97% (véase el mapa 2). En cuanto al nivel nacional, la Cuarta Comunicación Nacional del Perú a la Convención de las Naciones Unidas de Lucha contra la Desertificación, publicada en 2011, señala que “cerca de la tercera parte de la superficie del Perú se halla en algún estado de desertificación, ya sea como zona desertificada (3,01%: 3.862.786 ha) o en proceso de desertificación (23,75%: 30.522.010 ha)” (Morales, 2013).

Por otra parte, la Cuarta Comunicación considera que Piura es una de las zonas más afectadas: “En el caso de la Región Natural Costa, la degradación de la tierra se debe fundamentalmente a la salinización, que afecta al 40% de la superficie cultivada. Dentro de esta región, una parte importante de la desertificación se encuentra en la costa norte (Piura-Lambayeque), la cual es un área importante de producción agrícola para agroexportación”. Al respecto, si se considera que para el Perú la superficie afectada alcanza la tercera parte del país, es razonable preguntarse si la cifra considerada para la Región Piura, 18,79% de su superficie, pueda ser conservadora (Morales, 2013).

Predicción de Tierras Degradadas a Partir del Análisis de Series Temporales del Índice Mejorado de Vegetación y Temperatura de superficie de Suelo mediante Imágenes MODIS - Caso Estudio Piura



Fuente: Mapa de desertificación y deforestación elaborado por el Gobierno Regional de Piura, en el marco de la Zonificación Ecológica y Económica (2012).

Anexo 3. Fotos y trabajo de campo realizado en los valles y bosque seco de Piura.

Valle Piura- Paita. Tomando muestras de suelo para analizar la salinización.

Anexo 3



Foto1. Tomando muestras de suelo en el valle de Paita-Piura



Foto 2. Tomando muestras-Piura



Foto 3. Valle agrícola sin problemas de salinización- Piura



Foto 4. Suelos salinizados-Piura