Universidad Nacional Mayor de San Marcos
Universidad del Perú. Decana de América

Dirección General de Estudios de Posgrado
Facultad de Ciencias Físicas
Unidad de Posgrado

Estimación del índice de vegetación procedente del sensor AVHRR transportado por la serie de satélites NOAA (1981-2012) y su aplicación como un indicador de la desertificación en el Perú

TESIS

Para optar el Grado Académico de Magíster en Física con mención en Geofísica

AUTOR

Han XU

ASESOR

Dr. Joel ROJAS ACUÑA

Lima, Perú

2024

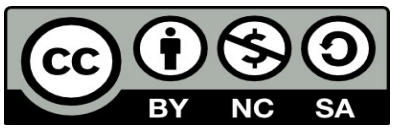

Reconocimiento - No Comercial - Compartir Igual - Sin restricciones adicionales

https://creativecommons.org/licenses/by-nc-sa/4.0/

Usted puede distribuir, remezclar, retocar, y crear a partir del documento original de modo no comercial, siempre y cuando se dé crédito al autor del documento y se licencien las nuevas creaciones bajo las mismas condiciones. No se permite aplicar términos legales o medidas tecnológicas que restrinjan legalmente a otros a hacer cualquier cosa que permita esta licencia.

Referencia bibliográfica

Xu, H. (2024). *Estimación del índice de vegetación procedente del sensor AVHRR transportado por la serie de satélites NOAA (1981-2012) y su aplicación como un indicador de la desertificación en el Perú*. [Tesis de doctorado, Universidad Nacional Mayor de San Marcos, Facultad de Ciencias Físicas, Unidad de Posgrado]. Repositorio institucional Cybertesis UNMSM.

Metadatos complementarios

Datos de autor	
Nombres y apellidos	Han Xu
Tipo de documento de identidad	Carné de extranjería emitido en Perú
Número de documento de identidad	000320024
URL de ORCID	https://orcid.org/0000-0001-7263-9645
Datos de asesor	
Nombres y apellidos	Joel Rojas Acuña
Tipo de documento de identidad	DNI
Número de documento de identidad	08647737
URL de ORCID	https://orcid.org/0000-0001-9722-7890
Datos del jurado	
Presidente del jurado	
Nombres y apellidos	Cesar Omar Jimenez Tintaya
Tipo de documento	DNI
Número de documento de identidad	08677351
Miembro del jurado 1	
Nombres y apellidos	Jaime Aguilar Lome
Tipo de documento	DNI
Número de documento de identidad	42645927
Miembro del jurado 2	
Nombres y apellidos	Julio Tomas Aquije Chacaltana
Tipo de documento	Cédula de identidad
Número de documento de identidad	BR / 1.764.115 - ES
Miembro del jurado 3	
Nombres y apellidos	-
Tipo de documento	-

Número de documento de identidad	-
Datos de investigación	
Línea de investigación	A.2.3.2. Teledetección de la Desertificación y Sequías debido al Cambio Climático
Grupo de investigación	No aplica.
Agencia de financiamiento	Perú. Consejo Nacional de Ciencia, Tecnología e Innovación Tecnológica. Fondo Nacional de Desarrollo Científico y Tecnológico. Proyecto Cátedra "Teledetección en Desertificación y Sequía". Resolución de Presidencia N° 045-2013-CONCYTEC-P.
Ubicación geográfica de la investigación	Lugar: Laboratorio de Teledetección, Facultad de Ciencias Físicas, Universidad Nacional Mayor de San Marcos País: Perú Departamento: Lima Provincia: Lima Distrito: Cercado de Lima Latitud: -12.059769° Longitud: -77.081787°
Año o rango de años en que se realizó la investigación	2020 - 2023
URL de disciplinas OCDE	Ciencias de la Tierra, Ciencias ambientales Geofísica https://purl.org/pe-repo/ocde/ford#1.05.04 Ciencias del medio ambiente https://purl.org/pe-repo/ocde/ford#1.05.08 Ingeniería ambiental Sensores remotos https://purl.org/pe-repo/ocde/ford#2.07.04

UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS
Universidad del Perú. Decana de América
FACULTAD DE CIENCIAS FÍSICAS
UNIDAD DE POSGRADO

ACTA DE SUSTENTACIÓN DE TESIS EN LA MODALIDAD PRESENCIAL PARA OPTAR EL GRADO ACADÉMICO DE MAGÍSTER EN FÍSICA CON MENCIÓN EN GEOFÍSICA

Siendo las 5:00 pm del 19 de enero de 2024, en el salón 304 de la Unidad de Posgrado de la Facultad de Ciencias Físicas de la Universidad Nacional Mayor de San Marcos, se reunieron los siguientes miembros del Jurado Examinador:

Dr. Cesar Omar Jimenez Tintaya	(Presidente)
Dr. Jaime Aguilar Lome	(Miembro interno)
Dr. Julio Aquije Tomás Chacaltana	(Miembro externo)
Dr. Joel Rojas Acuña	(Asesor)

Para la sustentación oral y pública de la tesis para optar el Grado Académico de Magíster en Física con mención en Geofísica, del Bach. Han Xu, con código de matrícula N° 12137011.

Después de darse lectura al expediente de Grado, en el que consta haberse cumplido con todas las disposiciones reglamentarias, los señores miembros del Jurado Examinador, atendieron a la exposición de la tesis titulada:

"Estimación del índice de vegetación procedente del sensor AVHRR transportado por la serie de satélites NOAA (1981- 2012) y su aplicación como un indicador de la desertificación en el Perú"

Concluida la exposición del candidato y luego de las preguntas de rigor por parte del Jurado Examinador, los asistentes y el tesista se retiraron del salón 304, para que el presidente y los miembros del Jurado Examinador puedan deliberar y calificar.

Al término de la deliberación, el Dr. Cesar Omar Jimenez Tintaya invitó al tesista y a los asistentes a pasar al salón 304 para dar lectura a la evaluación de la sustentación. Obteniendo como resultado la calificación de:

18	Dieciocho	Muy bueno
(NÚMERO)	(LETRAS)	(ESCALA)

A continuación, el presidente del Jurado Examinador entrega el Acta de Sustentación de Tesis a la Unidad de Posgrado, para continuar el trámite correspondiente para obtener el Grado Académico de Magíster en Física con mención en Geofísica, del Bach. Han Xu.

Siendo las 18:30 pm, se levantó la sesión.

UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS
Universidad del Perú. Decana de América
FACULTAD DE CIENCIAS FÍSICAS
UNIDAD DE POSGRADO

Los miembros del Jurado Examinador suscriben el Acta de sustentación de tesis en la Ciudad de Lima, el 19 de enero de 2024.

Acta de Sustentación de Tesis del Bach. Han Xu.

Dr. Cesar Omar Jimenez Tintaya
Presidente

Dr. Jaime Aguilar Lome
Miembro interno

Dr. Julio Tomás Aquije Chacaltana
Miembro externo

Dr. Joel Rojas Acuña
Asesor

CALIFICACIÓN OBTENIDA: Dieciocho (18) Muy bueno

Universidad Nacional Mayor de San Marcos

Universidad del Perú. Decana de América

Facultad de Ciencias Físicas

UNIDAD DE POSGRADO

CERTIFICADO DE SIMILITUD

Yo **Joel Rojas Acuña** en mi condición de asesor acreditado con el Dictamen N° **012-UPG- FCF-2013** de la tesis de investigación, cuyo título es "**Estimación del índice de vegetación procedente del sensor AVHRR transportado por la serie de satélites NOAA (1981-2012) y su aplicación como un indicador de la desertificación en el Perú**", presentado por el bachiller **Han Xu** para optar el grado de **Maestría en Física con mención en Geofisica**.

CERTIFICO que se ha cumplido con lo establecido en la Directiva de Originalidad y de Similitud de Trabajos Académicos, de Investigación y Producción Intelectual. Según la revisión, análisis y evaluación mediante el software de similitud textual, el documento evaluado cuenta con el porcentaje de **5**% de similitud, nivel PERMITIDO para continuar con los trámites correspondientes y para su **publicación en el repositorio institucional**.

Se emite el presente certificado en cumplimiento de lo establecido en las normas vigentes, como uno de los requisitos para la obtención del grado correspondiente.

Lima, 16 de enero de 2024.

UNMSM Firmado digitalmente por ROJAS ACUÑA Joel FAU 20148092282 soft
Motivo: Soy el autor del documento
Fecha: 16.01.2024 21:08:31 -05:00

Firma del asesor _____

D.N.I. Nº: **08647737**

Nombres y apellidos del asesor: **Joel Rojas Acuña**

DEDICATORIA

A mi madre por su incondicional apoyo.

AGRADECIMIENTOS

A mi profesor Dr. Joel Rojas Acuña, por su paciencia, predisposición y tiempo brindado en el desarrollo de este trabajo de investigación.

ACRÓNIMOS

6SV	Second Simulation of a Satellite Signal in the Solar Spectrum -Vector
AE	Aproximaciones Empíricas
APOLLO	AVHRR Processing Over Land cLoud and Ocean
ARS	Archive Retrieval System
AVHRR	Advanced Very High Resolution Radiometer
C3AR	Channel-3 Albedo Restoral
C3AT	Channel-3 Albedo Test
CIRT	Four-Minus-Five Restoral
CLAVR	Clouds from AVHRR
CMG	Climate Modeling Grid
CVM	Compuesto de Valores Máximos
DN	Digital Number
ENVI	ENvironment for Visualizing Images
FDSE	Fondo de Desarrollo de Servicios Estratégicos
FLAASH	Fast Line-of-Sight Atmospheric Analysis of Spectral Hypercubes
FMFT	Four-Minus-Five Test
GCTE	Global Change and Terrestrial Ecosystems
GESDISC	Goddard Earth Sciences Data and Information Services Center
GPS	Global Positioning System
HDF	Hierarchy Data Format
IGAC	International Global Atmospheric Chemistry Project
IGBP	International Geosphere-Biosphere Programme
IMARPE	Instituto del Mar del Perú
ISCCP-FD	International Satellite Cloud Climatology Project-Flux Data
LabTel	Laboratorio de Teledetección
LAC	Local Area Coverage
LST	Land Surface Temperature
LWIR	Long Wavelength Infrared
MAE	Mean Absolute Error
MK	Mann-Kendall
MODIS	MODerate-resolution Imaging Spectroradiometer
MODTRAN	MODerate resolution atmospheric TRANsmission

MWIR	Medium Wavelength Infrared
NASA	National Aeronautics and Space Administration
NDVI	Normalized Difference Vegetation Index
NIR	Near Infrared
NOAA	National Oceanic and Atmospheric Administration
PRTs	Platinum Resistance Thermometers
QUAC	Quick Atmospheric Correction
RGCT	Reflectance Gross Cloud Test
RMS	Root Mean Square
RMSE	Root Mean Square Error
RRCT	Reflectance Ratio Cloud Test
RSI	Research System Inc
RUT	Reflectance Uniformity Test
RVI	Ratio Vegetation Index
SMAC	Simplified Model for Atmospheric Correction
SMACC	Sequential Maximum Angle Convex Cone
SWIR	Short Wavelength Infrared
TGCR	Thermal Gross Cloud Restoral
TGCT	Thermal Gross Cloud Test
TOA	Top Of Atmosphere
TR	Transferencia Radiactiva
TRMM	Tropical Rainfall Measuring Mission
TUR	Thermal Uniformity Restoral
TUT	Thermal Uniformity Test
UNMSM	Universidad Nacional Mayor de San Marcos
ULST	Uniform Low Stratus Test
VCI	Vegetation Condition Index
VIS	Visible
WI	Wallop Island

RESUMEN

El objetivo del presente trabajo de tesis es estimar el índice de vegetación NDVI usando los datos de la serie de satélites NOAA y proponerlo como un indicador de la desertificación en el Perú para el periodo de 1982 a 2012. Los datos son adquiridos del portal de CLASS/NOAA, de nivel 1b, de resolución espacial de 1 km y temporal de 12 horas. Los datos originales están almacenados en números digitales binarios de 10 bits en archivos de formato LAC. Se procesaron un total de 15988 imágenes de los sensores AVHRR/2 y /3 de la serie de satélites NOAA para el área de estudio que abarca entre las latitudes de 0º a 19º S y las longitudes de 82º a 68.5º W.

Se desarrolló un algoritmo en lenguaje de programación IDL que automatiza el procesamiento de las imágenes que incluye las correcciones atmosférica y geométrica, el filtrado de nubes y redimensionado de los datos de cada imagen diaria. Al comparar con los resultados obtenidos usando el software ENVI, se obtuvieron los mismos valores de la reflectancia de los canales 1, 2 y 3a, y una mínima diferencia de valor de temperatura para los canales 3b, 4 y 5. Se discutió la consistencia de la base de datos de la serie de satélites NOAA y la eficiencia de la técnica de filtrado de nubes CLAVR. Se calculó los índices de NDVI y VCI diarios a partir de la reflectancia estimada, y los datos mensuales usando el compuesto de valores máximos para el periodo de enero de 1982 a abril de 2019 (448 meses). Se compararon los ciclos anuales del NDVI de AVHRR de distintos periodos con el de MODIS para encontrar una climatología más adecuada, con la cual se calculó la anomalía mensual de los índices. Se analizó los mapas anuales, estacionales del NDVI y de su anomalía, también de la desviación estándar y los diagramas de Hovmoller. Se obtuvo las series de los índices y sus tendencias por regiones y departamentos. Se identificó siete posibles zonas de desertificación mediante mapas de tendencias del NDVI y VCI.

De acuerdo de los resultados obtenidos, el NDVI tuvo un valor inferior a 0.2 en la región costera, un rango de 0.2 a 0.5 en la sierra, se registró mayor intensidad (> 0.5) y anomalías positivas en la selva durante el periodo de 1985 a 2019. La tendencia decadal fue positiva en todas las regiones, donde, la intensidad fue mayor en la selva (+0.14 por década) y menor en la costa (+0.05 por década), mientras que, se observó regiones pequeñas de tendencias negativas del NDVI (hasta -0.2 por década) y del VCI (hasta -0.11 por década), éstas son consideradas

como posibles zonas desertificadas, se propusieron dos posibles causas de la desertificación, entre ellas, cinco zonas de la región de costa (Piura, Chiclayo, Chicama, Pisco y Majes) fueron calificadas como consecuencia de la agricultura intensiva mientras que, la desertificación de Pucallpa y de Huepetuhe fue considerada como producto de la expansión urbana. El proceso de desertificación de las zonas costeras fue observado en el periodo de 1997 a 2006, donde, la mayor decrecimiento fue registrado en las zonas de Piura, Chiclayo y Chicama con tendencias de -0.29, -0.36 y -0.27 por década respectivamente, durante el periodo de 2007 a 2018, se ocurrió un proceso de recuperación registrándose tendencias positivas en dichas zonas mientras que, se observó tendencias negativas en las dos zonas de la selva alcanzando un valor de -0.25 por década en Huepetuhe.

Palabras Claves: base de datos del AVHRR nivel 1b, NDVI, VCI, climatología, tendencia, desertificación.

ABSTRACT

The objective of this thesis work is to estimate the NDVI vegetation index using data from the NOAA satellite series and propose it as an indicator of desertification in Peru for the period from 1982 to 2012. The data are acquired from the CLASS/NOAA portal, level 1b, spatial resolution of 1 km and temporal resolution of 12 hours. The original data are stored in 10-bit binary digital numbers in LAC format files. A total of 15988 images from the AVHRR/2 and /3 sensors of the NOAA satellite series were processed for the study area spanning between latitudes 0º to 19º S and longitudes 82º to 68.5º W approximately.

An algorithm was developed in IDL programming language that automates image processing, including atmospheric and geometric corrections, cloud filtering and resizing of the data for each daily image. When compared with the results obtained using ENVI software, the same reflectance values were obtained for channels 1, 2 and 3a, and a minimal difference in temperature value for channels 3b, 4 and 5. The consistency of the NOAA satellite series database and the efficiency of the CLAVR cloud filtering technique were discussed. Daily NDVI and VCI indices were calculated from estimated reflectance, and monthly data using the composite of maximum values for the period January 1982 to April 2019 (448 months). The annual cycles of the AVHRR NDVI of different periods were compared with that of MODIS to find a best-fit climatology, with which the monthly anomaly of the indices was calculated. The annual and seasonal maps of NDVI and its anomaly were analyzed, as well as the standard deviation and the Hovmoller diagrams. The series of indices and their trends by regions and departments were obtained. Seven possible desertification zones were identified by means of NDVI and VCI trend maps.

According to the results obtained, NDVI had a value lower than 0.2 in the coastal region, a range of 0.2 to 0.5 in the highlands, higher intensity (> 0.5) and positive anomalies were recorded in the rainforest during the period from 1985 to 2019. The decadal trend was positive in all regions, where, the intensity was higher in the jungle (+0.14 per decade) and lower in the coast (+0.05 per decade), while, small regions of negative trends of NDVI (up to -0.2 per decade) and VCI (up to -0. 11 per decade), these are considered as possible desertified areas, two possible causes of desertification were proposed, among them, five areas of the coastal region (Piura, Chiclayo, Chicama, Pisco and Majes) were qualified as a consequence of

intensive agriculture while, the desertification of Pucallpa and Huepetuhe was considered as a product of urban expansion. The desertification process in coastal areas was observed in the period from 1997 to 2006, where the greatest decrease was recorded in the areas of Piura, Chiclayo and Chicama with trends of -0.29, -0.36 and -0.27 per decade respectively. During the period from 2007 to 2018, there was a recovery process with positive trends in these areas, while negative trends were observed in the two jungle areas, reaching a value of -0.25 per decade in Huepetuhe.

Key words: AVHRR level 1b database, NDVI, VCI, climatology, trend, desertification.

ÍNDICE

Capítulo 1 - Introducción

1.1 Generalidades 1
1.2 Antecedentes 2
1.3 Objetivo general 4
1.4 Objetivos específicos 4
1.5 Hipótesis 5

Capítulo 2 - Fundamento Teórico

2.1 Calibración radiométrica 6
2.2 Corrección atmosférica 9
2.3 Corrección geométrica 12
2.4 Detección de nubes 19
2.5 Índices de Vegetación 21
2.6 Prueba de tendencia de Mann-Kendall 24

Capítulo 3 - Datos Utilizados

3.1 Área de estudio 26
3.2 Imágenes diarias en formato LAC/AVHRR 26
3.3 Imagenes mensuales en formato HDF NDVI/MODIS-AQUA 30
3.4 Precipitación mensual del TRMM 31

Capítulo 4 - Metodología

4.1 Extracción de Números Digitales 34
4.2 Calibración radiométrica 35
4.3 Corrección atmosférica 36
4.4 Corrección geométrica 38
4.5 Redimensionado 39
4.6 Detección de nubes 40

4.7 Estimación del NDVI/AVHRR mensual y su anomalía 41
4.8 Análisis comparativo del NDVI 41

Capítulo 5 - Resultados

5.1 Serie del NDVI/AVHRR por mes 42
5.2 NDVI/AVHRR promedio anual 44
5.3 NDVI/AVHRR promedio estacional 45
5.4 Climatología mensual del NDVI/AVHRR 45
5.5 Promedio de la anomalía del NDVI/AVHRR mensual 46
5.6 Promedio de la anomalía del NDVI/AVHRR anual 48
5.7 Promedio de la anomalía del NDVI/AVHRR estacional 49
5.8 Promedio del NDVI/AVHRR (1986-2018) 50
5.9 Hovmoller del NDVI/AVHRR 51
5.10 Hovmoller de la anomalía del NDVI/AVHRR 52
5.11 Serie de tendencia del VCI/AVHRR por departamentos 53
5.12 Mapa de tendencia del NDVI AVHRR 54
5.13 Mapa de tendencia del VCI AVHRR 55
5.14 Serie de tendencia del NDVI AVHRR 56
5.15 Serie de tendencia del VCI AVHRR 57

CAPITULO 6 - DISCUSIONES

6.1 Sobre la base de datos 60
6.2 Sobre el filtrado de nubes 60
6.3 Sobre el periodo para la climatología 61
6.4 Comparación con el producto del NDVI/MODIS 61
6.5 Comparación con la precipitación TRMM 62
6.6 Evaluación de la técnica de tendencia 65
6.7 Sobre las tendencias por departamentos 65
6.8 Sobre las posibles zonas desertificadas 65

CAPITULO 7 - CONCLUSIONES Y RECOMENDACIONES

7.1 Conclusiones 69
7.2 Recomendaciones 71

Referencias

Anexos

A-I. Derivación de la ecuación de excentricidad 86
A-II. Código IDL para generar las series y tendencias con prueba de Mann-Kendall 91
A-III. Código IDL para el preprocesamiento AVHRR 95
A-IV. Código IDL para el redimensionado 101

Lista de Figuras

Figura 1.1.	Clasificación climática del Perú (SENAMHI, 2021).	4
Figura 2.1.	Secuencia de calibración en la órbita de los canales térmicos del AVHRR (adaptado de NOAA, 2014).	9
Figura 2.2.	Los tres caminos de la radiación del Sol (adaptado de Bernstein et al., 2012).	11
Figura 2.3.	Esquema de algunos elementos orbitales (adaptado de Jerry et al., 2000).	15
Figura 2.4.	Esquema del movimiento del satélite en la órbita (adaptado de Rosborough et al., 1994).	16
Figura 2.5.	Firma espectral de la reflectancia del suelo en estados seco y húmedo, y de pasto de biomasa seca de 530 m^{-2} (adaptado de Tucker and Miller, 1977).	22
Figura 2.6.	Gráfico de dispersión de los valores de las reflectancias RefNIR y RefRED para las vegetaciones densa y dispersa, y suelos brillantes y oscuros con las isolíneas del NDVI (adaptado de Njomo, 2008).	23
Figura 2.7.	Tabla de probabilidad para la prueba de Mann-Kendall (Gilbert, 1987).	25
Figura 3.1.	Área de estudio: Perú-América Sur. La imagen muestra el modelo de elevación digital del Perú con sus	27

	alturas, costas, andinas y amazonia empleando el modelo Etopo 2022 de 15° de arco de resolución espacial. (Fuente: https://www.ncei.noaa.gov/maps/grid-extract/)	
Figura 3.2.	Número de imágenes procesadas, clasificado por año y por satélite.	27
Figura 3.3.	Los dos escenas adquiridos para el día 28 de enero del 2000 (trazo naranja: área de solicitud y rectángulo azul: área de barrido del satélite).	28
Figura 3.4.	Estructura de un archivo LAC del sensor AVHRR/3 (Xu, 2014).	30
Figura 3.5.	Promedio mensual de NDVI/MODIS para el mes de febrero del 2000.	31
Figura 3.6.	Promedio mensual de la precipitación del TRMM para el mes de enero del 1998.	32
Figura 4.1.	Secuencia del procesamiento del sensor AVHRR.	33
Figura 4.2.	Imágenes de falso color para el área de estudio.	34
Figura 4.3.	Diagrama de dispersión de LA temperatura estimada por IDL y ENVI.	37
Figura 4.4.	Comparación del histograma entre (a) la reflectancia en la superficie y (b) en TOA.	38
Figura 4.5.	Imágenes georreferenciadas de las horas (a) 15:28 y (b) 16:58 horas.	39
Figura 4.6.	(a) Área del estudio en imagen georreferenciada; (b) redimensionado	40

	de la imagen eliminando áreas en norte, sur y oeste, y completando a la zona este con un matriz vacío.	
Figura 4.7.	(a) Imagen de ejemplo y de (b) canal 1 donde los pixeles de nubes son ceros.	41
Figura 5.1.	Serie de tiempo del NDVI/AVHRR mensual para todo el periodo de estudio.	43
Figura 5.2.	Promedio del NDVI/AVHRR por año.	44
Figura 5.3.	Promedio del NDVI/AVHRR estacional.	45
Figura 5.4.	Climatología mensual del NDVI/AVHRR (1992-1999).	47
Figura 5.5.	Promedio de la anomalía del NDVI/AVHRR mensual.	48
Figura 5.6.	Promedio de la anomalía del NDVI/AVHRR anual.	49
Figura 5.7.	Promedio estacional de la anomalía del NDVI/AVHRR.	50
Figura 5.8.	(a) NDVI/AVHRR promedio, (b) desviación estándar del NDVI/AVHRR para el periodo 1986-2018, (c) ecorregiones propuestas por Brack (MINAM, 2010). (Fuente de vectores de regiones naturales y ecorregiones: https://www.geogpsperu.com)	51
Figura 5.9.	Diagrama de Hovmoller del NDVI/AVHRR mensual en las regiones de la (a) costa, (b) sierra, (c) selva para el periodo de estudio.	52
Figura 5.10.	Diagrama de Hovmoller de la anomalía del NDVI/AVHRR mensual	53

	en las regiones de la (a) costa, (b) sierra, (c) selva.	
Figura 5.11.	Serie de tendencias del VCI de las regiones del Perú.	54
Figura 5.12.	Mapa de tendencia del NDVI (Dec^{-1}).	55
Figura 5.13.	Mapa de tendencia del VCI (Dec^{-1}).	56
Figura 5.14.	Serie de tendencia del NDVI de las posibles zonas desertificadas para el periodo del ene-1986 al abr-2019.	57
Figura 5.15.	Serie de tendencia del VCI de las posibles zonas desertificadas para el periodo del ene-1986 al abr-2019.	58
Figura 6.1.	Ciclos anuales del NDVI del sensor (a) MODIS de periodo 2002-2019, del AVHRR para los periodos de (b) 1992-1999, (c) 1992-2018, (d) 2000-2006 y (e) 2007-2018.	62
Figura 6.2.	Comparación de la distribución del NDVI de ambos sensor para el periodo común (2000-2019).	63
Figura 6.3.	Serie mensual del NDVI de los sensores AVHRR y MODIS de la región de costa norte del Perú.	63
Figura 6.4.	Diagrama de dispersión del NDVI de los sensores AVHRR y MODIS.	64
Figura 6.5.	Histograma del NDVI de AVHRR y de precipitación TRMM (línea azul) en la costa norte del Perú para el periodo 1998-2019, el color amarillo representa los meses con NDVI > 0.4, y el verde son para el NDVI < 0.4.	64
Figura 6.6.	Comparación del NDVI/AVHRR promedio anual con precipitación	64

anual (a) logarítmico en base 10 y (b) su anomalía en costa norte del Perú durante el periodo 1998-2018.

Figura 6.7. Mapa de tendencia del NDVI/AVHRR por departamentos. 67

Figura 6.8. Serie de tendencia del NDVI de las posibles zonas desertificadas por periodos. 68

Lista de Tablas

Tabla 2.1.	Longitud de onda espectral de AVHRR (Kalluri et al., 2020).	6
Tabla 2.2.	Características de los elementos orbitales (Jerry et al., 2000).	16
Tabla 2.3.	Umbrales utilizados para las pruebas (adaptado de Stowe et al., 1999).	21
Tabla 4.1.	Ejemplo del cálculo de un mismo pixel para cada canal espectral.	36
Tabla 4.2.	Valor máximo, mínimo, promedio y desviación estándar de la reflectancia superficial y TOA de cada canal.	36
Tabla 4.3.	Umbrales modificados.	40
Tabla 5.1.	Tendencia, error y p-valor del NDVI y su anomalía por zonas.	43
Tabla 5.2.	Valores máximo, mínimo, promedio y desviación del NDVI.	46
Tabla 5.3.	Área, tendencia, error y p-valor de los índices de NDVI y VCI para las zonas identificadas como posibles zonas de desertificación.	59

Capítulo 1

Introducción

1.1 Generalidades

En general, se define la desertificación como la degradación del suelo causado por las variaciones climáticas y actividades humanas en zonas áridas, semiáridas y subhúmedas secas, en las cuales, el suelo pierde su capacidad regenerativa. En sentido estricto, se refiere al proceso de cambio ambiental de regiones no desérticas a desérticas debido a actividades antropológicas cuando se trata de ecosistemas frágiles (MINAM, 2011), es decir, se trata fundamentalmente de un problema antropogénico que tiene su origen en una presión excesiva sobre el suelo y no en la expansión gradual del desierto (Naciones Unidas, 1977). Entonces, el periodo del proceso de desertificación está relacionado con las actividades humanas y no se considera que la formación y la expansión geológica natural de los desiertos como desertificación, no se incluyen los tipos de formación por razones naturales puras como la formación del desierto de Sahara, el Gran Gobi, los desiertos salinos nativos, el paisaje de Jadán eólico y las zonas alpinas de congelación y descongelación. Por otro lado, la lucha contra la desertificación es un proceso de armonización de la relación entre el hombre y la naturaleza, mejoramiento del medio ambiente, recuperación de la productividad de la tierra y desarrollo económico sostenible, en las cuales, es necesario el monitoreo dinámico y la cuantificación permanente de estado del suelo en regiones desertificadas.

Los métodos como encuestas estadísticas y modelos de simulación fueron utilizados con mayor frecuencia para la vigilancia temprana de la desertificación antes de la década de 70 del siglo 20 (Paylore and McGinnies, 1969). Desde el decenio de 1970, la desertificación ha sido

monitoreada mediante técnica de sensoramiento remoto (Zhang et al., 2018). En la década de 1980, se ha reconocido el índice de vegetación NDVI (Normalized Difference Vegetation Index) como un parámetro biofísico importante que representa el estado de la vegetación y se ha convertido en el principal indicador para determinar la dinámica de la desertificación (Ormsby et al., 1987; Tucker et al., 1991; Hutchison, 2004). Los datos del sensor AVHRR (Advanced Very High Resolution Radiometer) de la serie de satélites NOAA (National Oceanic and Atmospheric Administration) ha demostrado que es capaz de monitorear la dinámica del cambio de cubertura vegetal a escala global (Defries and Townshend, 1994). Los grandes proyectos internacionales tales como IGBP (International Geosphere-Biosphere Programme), IGAC (International Global Atmospheric Chemistry Project) y GCTE (Global Change and Terrestrial Ecosystems) utilizan las imágenes de AVHRR como la principal fuente de datos.

1.2 Antecedentes

En nivel global, en el año 1997, IGBP completó la primera colección de los datos del NDVI de 1 km de resolución espacial a nivel global (Ehrlich et al., 1994). Asimismo, en otros países han construido la información histórica del NDVI del AVHRR/NOAA para su territorio nacional correspondiente (Chen et al., 1999; Fontana et al., 2012). Gaitán indicó que el NDVI es el mejor predictor de los atributos del ecosistema a través de un análisis estadístico de los índices de vegetación en la región Patagonia (Gaitán et al., 2013).

En el Perú, desde el 2000, se viene preparando la base de datos del NDVI (1980-2001) a través de la calibración radiométrica usando los datos de nivel crudo y de nivel 1b del sensor AVHRR para detectar la distribución de vegetación en el territorio peruano (Rojas et al., 2000), en la cual, los datos fueron obtenidos de distintas fuentes como IMARPE (Instituto del Mar del Perú), ABTEMA (Asociación Boliviana de Teledetección y Medio Ambiente), INPE (Instituto Nacional de Pesquisas Espaciais) y SAA (Satellite Active Archive) de la NOAA. Con los datos mensuales del NDVI y los índices ENOS (El Niño Oscilación Sur), se propuso un modelo de predicción del inicio de la sequía en la costa norte del Perú a través de la técnica de regresión múltiple (Rojas et al., 2009).

En 2012, Badaracco correlacionó el NDVI estimado por la serie de satélites Landsat con los datos in situ de la conductividad eléctrica mediante el análisis de regresión lineal múltiple y logró generar mapas temáticos de la distribución espacial de la conductividad eléctrica del suelo

con valores altos de coeficientes de correlación para la costa norte del Perú (Badaracco, 2012). Dicho trabajo formó parte del proyecto de "Sistema de detección temprana de la sequía en la costa norte de Perú financiado por el FDSE (Fondo de Desarrollo de Servicios Estratégicos) ejecutado por LabTel (Laboratorio de Teledetección) de la Facultad de Ciencias Físicas de UNMSM (Universidad Nacional Mayor de San Marcos).

En 2014, Xu estimó el NDVI del sensor AVHRR/3 a través del modelo de la corrección atmosférica SMAC (Simplified Model for Atmospheric Correction) para todo el territorio peruano (Xu, 2014).

En 2015, Soca identificó suelos degradados por salinidad empleando NDVI estimado de las imágenes Landsat mediante SMAC para zonas de cultivo de caña de azúcar en Pomalca de la región Lambayeque (Soca, 2015). Así mismo, Aguilar utilizó los datos de LST (Land Surface Temperature) del sensor MODIS (Moderate-Resolution Imaging Spectroradiometer) de los satélites TERRA y AQUA para determinar la variabilidad espacio-temporal de LST del territorio peruano con el fin de reducir los efectos negativos frente a los eventos que ocurre por el cambio climático (Aguilar, 2015).

En 2017, Carbajal calculó el VCI (Vegetation Condition Index) a partir de los datos productos de NDVI del MODIS y correlacionó con otros índices de sequía para las regiones Piura, Lambayeque y Cajamarca (Carbajal, 2017). Los trabajos mencionados son presentados por parte del proyecto "Teledetección en Desertificación y Sequía" ejecutado por Labtel/UNMSM.

En el 2021, SENAMHI ha actualizado su mapa de clasificación climática del Perú (SENAMHI, 2021), en la cual, se identificaron treinta y ocho tipos de climas (Fig. 1.1).

En este trabajo, se construirá una base de datos del NDVI estimado por el sensor AVHRR de la serie de NOAA (1982-2019) usando algoritmo de preprocesamiento automatizado, realizarán los análisis de serie de tiempo y tendencias de los índices generados e identificarán posibles zonas desertificadas usando mapas temáticos de tendencias del NDVI mensual a partir de los datos diarios.

1.3 Objetivo general

Estimación del NDVI en el Perú usando datos imágenes del sensor AVHRR/NOAA para proponerlo como un indicador de la desertificación en el periodo 1982-2012.

Color	Simbología	Descripción	Área (Km²)	Porcentaje área nacional (%)
	A (r) A'	Muy lluvioso con humedad abundante todas las estaciones del año. Cálido	338 099	26
	A (r) B'	Muy lluvioso con humedad abundante todas las estaciones del año. Templado	28 244	2
	A (r) C'	Muy lluvioso con humedad abundante todas las estaciones del año. Frío	12 567	1
	A (r) D'	Muy lluvioso con humedad abundante todas las estaciones del año. Semifrigido	2353	0.18
	B (i) B'	Lluvioso con invierno seco. Templado	25136	2
	B (i) C'	Lluvioso con invierno seco. Frío	6396	0.50
	B (i) D'	Lluvioso con invierno seco. Semifrigido	3140	0.24
	B (i) E'	Lluvioso con invierno seco. Frígido	66	0.01
	B (o , i) B'	Lluvioso con otoño e invierno secos. Templado	16005	1
	B (o , i) C'	Lluvioso con otoño e invierno secos. Frío	133384	10
	B (o , i) D'	Lluvioso con otoño e invierno secos. Semifrigido	1848	0.14
	B (r) A'	Lluvioso con humedad abundante todas las estaciones del año. Cálido	262835	20
	B (r) B'	Lluvioso con humedad abundante todas las estaciones del año. Templado	110961	9
	B (r) C'	Lluvioso con humedad abundante todas las estaciones del año. Frío	2971	0.23
	B (r) D'	Lluvioso con humedad abundante todas las estaciones del año. Semifrigido	15391	1
	C (i , p) A'	Semiseco con invierno y primavera secos. Cálido	57	0.004
	C (i , p) B'	Semiseco con invierno y primavera secos. Templado	304	0.02
	C (i) A'	Semiseco con invierno seco. Cálido	2967	0.23
	C (i) B'	Semiseco con invierno seco. Templado	17712	1
	C (i) C'	Semiseco con invierno seco. Frío	34483	3
	C (i) D'	Semiseco con invierno seco. Semifrigido	13928	1
	C (i) E'	Semiseco con invierno seco. Frigido	419	0.03
	C (o , i) B'	Semiseco con otoño e invierno secos. Templado	3857	0.30
	C (o , i) C'	Semiseco con otoño e invierno secos. Frío	18972	1
	C (o , i) D'	Semiseco con otoño e invierno secos. Semifrigido	310	0.02
	C (o , i) E'	Semiseco con otoño e invierno secos. Frígido	537	0.04
	C (r) A'	Semiseco con humedad abundante todas las estaciones del año. Cálido	7587	1
	C (r) B'	Semiseco con humedad abundante todas las estaciones del año. Templado	39968	3
	D (i , p) A'	Semiárido con invierno y primavera secos. Cálido	5996	0.47
	D (i , p) B'	Semiárido con invierno y primavera secos. Templado	4067	0.32
	D (i , p) C'	Semiárido con invierno y primavera secos. Frío	8532	1
	D (i) A'	Semiárido con invierno seco. Cálido	422	0.03
	D (i) B'	Semiárido con invierno seco. Templado	12698	1
	D (i) C'	Semiárido con invierno seco. Frío	6420	0.50
	D (i) D'	Semiárido con invierno seco. Semifrigido	82	0.01
	E (d) A'	Árido con deficiencia de humedad en todas las estaciones del año. Cálido	30945	2
	E (d) B'	Árido con deficiencia de humedad en todas las estaciones del año. Templado	115033	9
	Glaciar	Hielo perenne	1292	0.10

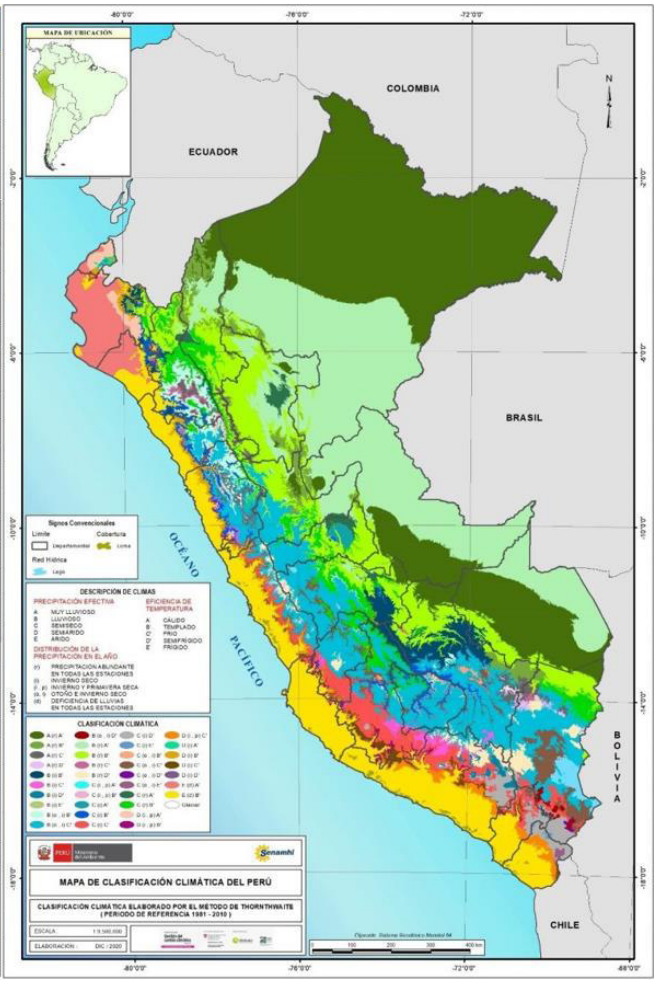

Figura 1.1. Clasificación climática del Perú (SENAMHI, 2021).

1.4 Objetivos específicos

- Lograr la lectura de los datos (número digital) de los archivos de nivel 1b en formato LAC.
- Lograr la calibración radiométrica de los datos de número digital.
- Lograr la corrección atmosférica de los datos de la radiancia.
- Lograr la corrección geométrica de las imágenes de la reflectancia.
- Lograr el filtrado de nubes para las imágenes de la reflectancia.
- Lograr la estimación del NDVI a partir de la reflectancia.

- Lograr el cálculo de compuesto de valores máximos mensuales del NDVI.
- Lograr realizar los principales estadísticos del conjunto del producto NDVI.
- Lograr el análisis de serie de tiempo del NDVI para el periodo de estudio (serie anual, mensual, trimestral).
- Lograr el cálculo de la tendencia para cada pixel de la imagen.
- Lograr detectar posibles zonas de desertificación con mapa de tendencia.
- Lograr analizar las series de tendencias de las posibles zonas desertificadas.

1.5 Hipótesis

Usando los datos de satélites NOAA (de 1km de resolución espacial) podemos generar climatología de periodo de mayor alcance (37 años), y mediante mapas temáticos de tendencia de los índices de vegetación, es posible identificar zonas de desertificación que tendrán tendencias negativas para el periodo de estudio. Se espera que el NDVI sea un indicador de la desertificación.

Capítulo 2

Fundamento Teórico

En este capítulo se describe el fundamente teórico del procesamiento utilizado en el presente trabajo de tesis, que incluyan la calibración radiométrica, la corrección atmosférica y geométrica, la detección de nubes, la estimación de los índices de vegetación NDVI y VCI, y la prueba de Mann-Kendall para validar el cálculo de la tendencia.

2.1 Calibración radiométrica

Un archivo imagen del sensor AVHRR contiene cinco imágenes en diferentes intervalos espectrales más otros datos (ver Tabla 2.1), en donde los canales 3a y 3b trabajan alternadamente (3a en el día y 3b en la noche). La calibración radiométrica de los canales VIS (Visible), NIR (Near Infrared) y SWIR (Short Wavelength Infrared) es distinta a la de los canales MWIR (Medium Wavelength Infrared) y LWIR (Long Wavelength Infrared) como se describen en los siguientes párrafos.

Tabla 2.1 Longitud de onda espectral del AVHRR (Kalluri et al., 2020).

Canal	**Longitud de Onda (µm)**		
	TIROS-N, NOAA-6, -8, -10	**NOAA-7, -9, -11, -12, -13, -14**	**NOAA-15, -16, -17, -18, -19, MetOp-A, -B, -C**
1 (VIS)	0.580 - 0.680	0.580 - 0.680	0.580 - 0.680
2 (NIR)	0.725 - 1.000	0.725 - 1.000	0.725 - 1.000
3a (SWIR)	-	-	1.580 - 1.640
3b (MWIR)	3.550 - 3.930	3.550 - 3.930	3.550 - 3.930
4 (LWIR)	10.300 - 11.300	10.300 - 11.300	10.300 - 11.300
5 (LWIR)	Repetido del 4	11.500 - 12.500	11.500 - 12.500

Canales 1, 2 y 3a

Se realizan calibración radiométrica del sensor AVHRR en laboratorio antes del lanzamiento de un satélite NOAA, la fuente de luz que recibe el sensor proviene de fuentes de luminosidad instaladas dentro de una esfera de integración. El nivel de iluminación varía en veinticinco pasos para el canal 1, dieciséis pasos para el canal 2 y once pasos para el canal 3a. En cada nivel se registran la media y la desviación estándar de la señal emitida por AVHRR (3600 mediciones) y se convierten en conteos digitales en una escala de 10 bits (NOAA, 2014). Cuando el sensor AVHRR recibe la radiación emitida por la fuente de luminosidad, la radiancia filtrada I ($Wm^{-2}sr^{-1}$) registrada por el sensor está dada por la ec. (2.1):

$$I = \int_{\lambda_1}^{\lambda_2} S_\lambda \tau_\lambda d\lambda \quad , \tag{2.1}$$

donde, S_λ es la radiancia de la fuente de luminosidad en una determinada longitud de onda λ; τ_λ es la función de respuesta normalizada del canal dado para λ, λ_1 y λ_2 son los límites inferior y superior del canal espectral (Goodrum et al., 2001). De manera similar, la irradiancia del Sol extraterrestre filtrada está dada por la ec. (2.2):

$$F = \int_{\lambda_1}^{\lambda_2} F_{o\lambda} \tau_\lambda d\lambda \quad , \tag{2.2}$$

donde, $F_{o\lambda}$ es la irradiancia espectral del Sol extraterrestre en la longitud de onda λ (Goodrum et al., 2001). Otras cantidades de interés son la longitud de onda media expresada por la ec. (2.3):

$$\bar{\lambda} = \frac{\int_{\lambda_1}^{\lambda_2} \lambda F_{o\lambda} \tau_\lambda d\lambda}{F} \quad , \tag{2.3}$$

y la anchura equivalente del canal se expresa por la ec. (2.4):

$$w = \int_{\lambda_1}^{\lambda_2} \tau_\lambda d\lambda \quad . \tag{2.4}$$

Se define A como la radiancia escalada registrada por el sensor y se expresa por la ec. (2.5):

$$A = \frac{\pi I}{F} \quad , \tag{2.5}$$

donde, el valor de A representa la razón (en porcentaje) entre la irradiancia de un campo de radiación isotrópica con radiancia I y la irradiancia filtrada del Sol F. El objetivo de la calibración antes del lanzamiento consiste en establecer la relación lineal entre A y la señal digital C del sensor AVHRR para los niveles de iluminación como se expresa en la ec. (2.6):

$$A = a + b\,C \ , \tag{2.6}$$

donde, la señal digital está representada por número de cuentas, por lo tanto, la pendiente b está en porcentaje por cuentas y el intercepto a está en unidad de porcentaje.

Durante el vuelo, la calibración de los canales 1, 2 y 3a se realiza a través de unos objetos terrestres que son radiométricamente estables, y mediciones de aeronaves y satélites de trayectoria congruentes para monitorear la calibración de los instrumentos en función del tiempo (NOAA, 2014).

Canales 3b, 4 y 5

Antes del lanzamiento, la calibración de los canales de 3b, 4 y 5 se llevó a cabo en un ambiente vacío térmico para simular condiciones en el espacio. El radiómetro va registrando de manera secuencial la radiación que proviene de tres objetos negros: un cuerpo de baja temperatura de 95 grados Kelvin que simula el espacio frío, un cuerpo negro instalado en laboratorio externo que simula el Planeta Tierra y un cuerpo negro caliente instalado en interior del laboratorio (Fig. 2.1). Las temperaturas internas y externas del cuerpo negro se miden por PRTs (Platinum Resistance Thermometers), a partir de estas temperaturas, se calculan la radiancia para cada canal térmico y lo convierte a valor digital de conteo de 10 bits (0-1023).

Durante el vuelo, en cada línea de barrido, la calibración se realiza a través de los siguientes objetos (Fig. 2.1): primero, el sensor realiza diez mediciones para el espacio frío, luego una sola medición para cada pixel por línea de barrido (2048 pixeles en total), y finalmente diez mediciones para el cuerpo negro interno. Las mediciones indican una relación no lineal entre la radiancia y el conteo gráfico, la cual se expresa por la ec. (2.7)

$$N_E = a_0 + a_1 C_E + a_2 C_E^2 \ , \tag{2.7}$$

donde, N_E es la radiancia de la imagen de tierra cuya unidad es $mW/(m^2\text{-}sr\text{-}cm^{-1})$, C_E es cuentas de la imagen de tierra en 10 bits. a_0, a_1 y a_2 son coeficientes de calibración de cada canal térmico. La temperatura del cuerpo negro equivalente T_E está dada por la ec. (2.8):

$$T_E = \frac{\frac{c_2 \upsilon_c}{\ln\left[1 + \frac{c_1 \upsilon_c^3}{N_E}\right]} - A}{B} \quad , \tag{2.8}$$

donde, c_1 y c_2 son las constantes, $c_1 = 1.191 \times 10^{-5}$ mW/(m^2 sr cm^{-4}) y $c_2 = 1.439$ cm K, ν_c es el número de ondas, A y B son los coeficientes de corrección de la ec. (2.8) para cada canal (Mittaz and Harris, 2009).

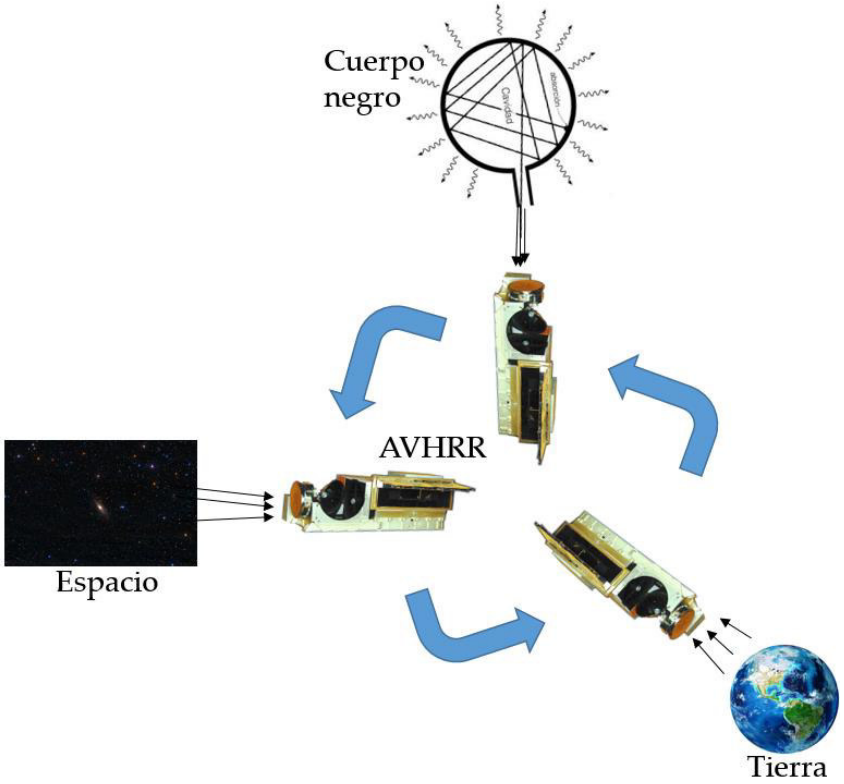

Figura 2.1. Secuencia de calibración en la órbita de los canales térmicos del AVHRR (adaptado de NOAA, 2014).

2.2 Corrección atmosférica

La radiación del Sol antes de ser registrada por el sensor del satélite, interactúa con los aerosoles suspendidos y las moléculas de los gases en la atmósfera generando efectos de absorción y scattering que alteran la información real del objeto en la superficie. Por consiguiente, se debe realizar la corrección atmosférica con el fin de eliminar la interferencia atmosférica, de esta manera, restaurar la reflectancia espectral real del objeto (Vermote et al., 2006).

En general, se utilizan los modelos basados en la teoría de Transferencia Radiactiva (TR) y scattering de orden sucesivo (Vermote et al., 2006; Adler-Golden et al., 1999; Matthew et al., 2003; Rahman and Dedieu, 1994) tales como 6SV (Second Simulation of a Satellite Signal in the Solar Spectrum – Vector), MODTRAN (MODerate resolution atmospheric TRANsmission), FLAASH (Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes), SMAC (Simplified Model for Atmospheric Correction). En los modelos de transferencia radiativa, trata de la simulación de la transmisión de la radiación del Sol en la atmósfera y la determinación de los coeficientes de atenuación por absorción y scattering usando los parámetros como aerosoles y moléculas de los gases registrados en tiempos cercanos al barrido del satélite con el fin de optimizar la estimación de la reflectancia espectral, sin embargo, los modelos pueden estar restringidos por falta de información de los parámetros atmosféricos (Jiménez-Muñoz et al., 2010).

Otros algoritmos de corrección atmosférica se basan en los modelos de AE (Aproximaciones Empíricas) como el método lineal empírico, en la cual, se suponen que existe una relación lineal entre el Digital Number (DN) y la reflectancia, y se calculan la pendiente y el intercepto de la regresión lineal ingresando datos de DN y la reflectancia (Concha and Schott, 2014; Ariza et al., 2018; Melgarejo et al., 2018). La ventaja de un algoritmo AE con respecto a TR es que, el AE tiene un tiempo de procesamiento muy reducido ya que no se requieren operaciones de los parámetros atmosféricos, sino, la reflectancia in situ. Por lo mismo, los modelos AE están limitados por falta de los datos de la reflectancia *in situ* en tiempo cercano a la hora de barrido de la imagen. Además, la precisión de las mediciones in situ depende mucho de las condiciones atmosféricas.

En 2005, Bernstein y otros introdujeron un modelo semi-empírico de corrección atmosférica llamado QUAC (QUick Atmospheric Correction) que solo se requiere una especificación aproximada de la longitud de onda espectral y los datos calibrados radiométricamente (Bernstein et al., 2005). Se ha demostrado que la precisión absoluta de la estimación por QUAC es de ±15% con respecto a la del FLAASH, y la velocidad computacional del QUAC es significativamente rápida (Bernstein et al., 2008). Según Bernstein, el modelo QUAC se basa en la ecuación de radiancia estándar que se expresa por la ec. (2.9):

$$\rho_{TOA}(\lambda) = A(\lambda) + \frac{B(\lambda)}{1 - S(\lambda) \cdot M_{\rho}(\lambda)} \cdot \rho(\lambda) + \frac{C(\lambda)}{1 - S(\lambda) \cdot M_{\rho}(\lambda)} \cdot M_{\rho}(\lambda) \quad , \qquad (2.9)$$

donde, ρ_{TOA} es la reflectancia espectral (radiancia normalizada por la componente normal de la superficie del flujo del Sol) registrada por el sensor; ρ es la reflectancia del objeto en la superficie; M_ρ es el valor promedio de la reflectancia de los objetos vecinos; S es el albedo planetario de la atmósfera de la Tierra; los términos $A(\lambda)$, $B(\lambda)$ y $C(\lambda)$ representan los caminos de viaje de la radiación en la atmósfera (Bernstein et al., 2005) como se muestra en la Figura 2.2, donde $A(\lambda)$ representa la cantidad de radiación que no fue reflejada por el objeto sin embargo es registrada por el sensor debido a los efectos de scattering y absorción en la atmósfera; $B(\lambda)$, la radiación del Sol reflejada por objeto en la superficie y registrada por sensor, que contiene la información verdadera del objeto; $C(\lambda)$, la cantidad de radiación reflejada por los objetos vecinos y registrada por sensor (Bernstein et al., 2012).

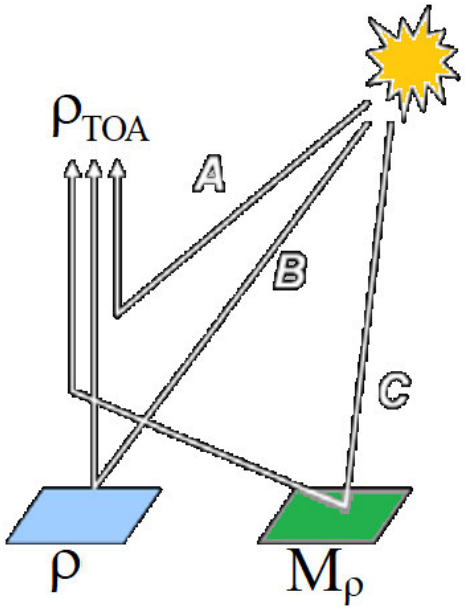

Figura 2.2. Los tres caminos de la radiación del Sol (adaptado de Bernstein et al., 2012).

Tal como menciona Bernstein, para los objetos oscuros en la superficie de la Tierra (vegetación, agua o suelo oscuro), el $S(\lambda)$ es muy pequeño, y cuando los objetos de la imagen están intercalados de manera bastante uniforme, el valor M_ρ es constante (Bernstein et al., 2005), bajo esta condición, cuando la visibilidad es alta, la ec. (2.9) se reduce a la ec. (2.10):

$$\rho_{TOA}(\lambda) = A(\lambda) + B(\lambda)\cdot\rho(\lambda) + C(\lambda)\cdot M_\rho(\lambda) \quad , \qquad (2.10)$$

donde, el valor de 1/B es considerado como la pendiente y $A(\lambda) + C(\lambda)\cdot M_\rho(\lambda)$, como el intercepto. El modelo QUAC no emplean los datos de la reflectancia in situ ρ sino determina los parámetros de compensación atmosférica directamente desde la información contenida dentro de la imagen mediante el método lineal empírico, bajo los siguientes supuestos (Bernstein et al., 2005):

1. Existe más que 10 tipos de objetos en la superficie dentro de la imagen.

2. Para el conjunto de objetos de la misma característica espectral, cuya desviación estándar espectral debe ser una constante, que es independiente de la longitud de onda.

3. Existe suficiente pixeles oscuros ($\rho \approx 0$) para permitir una buena estimación de contribución de línea de base casi invariable espacialmente, donde, la suma de $\rho_b = A(\lambda) + C(\lambda) \cdot M\rho(\lambda)$ será el valor mínimo en cada canal espectral.

Bajo los supuestos anteriores, para un conjunto de pixeles de característica espectral distinta, la desviación estándar espectral, $\sigma\rho_{TOA}$ se expresa por (2.11):

$$\sigma\rho_{TOA}(\lambda) = B(\lambda) \cdot \sigma\rho(\lambda) \quad . \tag{2.11}$$

El intercepto $A(\lambda) + C(\lambda) \cdot M\rho$ no contribuye a la desviación estándar por ser una constante, de lo contrario, el algoritmo dividirá la imagen en partes más pequeñas hasta que los pixeles agrupados cumplen los supuestos. En el módulo QUAC del software ENVI (ENvironment for Visualizing Images), $1/B(\lambda)$ está dado por la ec. (2.12):

$$\frac{1}{B} = \frac{< \rho_{end} >_{lib}}{< (\rho_{TOA} - C(\lambda)\rho_{promedio})_{end} >} \quad , \tag{2.12}$$

donde, $<\rho_{end}>_{lib}$ representa el promedio de la reflectancia espectral de los objetos cuyos subpíxeles son de la misma característica espectral que han sido registrados en la librería espectral del modelo, $<(\rho_{TOA}\text{-}C(\lambda)\rho_{promedio})_{end}>$ representa el promedio de la reflectancia de los subpíxeles observado por el sensor. Los subpíxeles son llamados como endmembers, en el modelo se utiliza el algoritmo SMACC (Sequential Maximum Angle Convex Cone) para detectarlos. De esta manera, se obtienen los valores de pendiente e intercepto para cada canal espectral (Gruninger et al., 2003).

2.3 Corrección geométrica

Durante la navegación de un satélite, los únicos datos conocidos del satélite son el tiempo registrado por los relojes del satélite y la órbita programada del satélite. Se debería conocer la posición y la velocidad del satélite en momento del barrido para hallar las coordenadas de los pixeles en la Tierra en un sistema de referencia adecuada con una precisión aceptable, para las imágenes del AVHRR/NOAA, los errores no deben superar a un pixel (Xu, 2007).

La metodología para calcular la órbita y las coordenadas geográficas de los pixeles de barrido se basa en las leyes de Newton y Kepler:

Las tres leyes de Newton:

Primera ley de Newton (ley de inercia): todo cuerpo continúa en su estado de reposo o movimiento uniforme en línea recta, no muy lejos de las fuerzas impresas a cambiar su posición.

Segunda ley de Newton (ley fundamental de la dinámica): el cambio de movimiento es directamente proporcional a la fuerza motriz impresa y ocurre según la línea recta a lo largo de la cual aquella fuerza se imprime.

Tercera ley de Newton (principio de acción y reacción): con toda acción ocurre siempre una reacción igual y contraria: quiere decir que las acciones mutuas de dos cuerpos siempre son iguales y dirigidas en sentido opuesto.

Las tres leyes de Kepler:

Primera ley de Kepler: todos los planetas se desplazan alrededor del Sol describiendo órbitas elípticas. El Sol se encuentra en uno de los focos de la elipse.

Segunda ley de Kepler: el radio vector que une un planeta y el Sol recorre áreas iguales en tiempos iguales.

Tercera ley de Kepler: para cualquier planeta, el cuadrado de su período orbital es directamente proporcional al cubo de la longitud del semieje mayor de su órbita elíptica.

Consideré el problema de dos cuerpos (el satélite y la Tierra), resolviendo la ecuación de movimiento del satélite usando las leyes de Newton y de Kepler (Curtis, 2005) se obtiene la ec. (2.13):

$$\ddot{\vec{r}} = -\frac{\mu}{r^3}\,\vec{r} \quad \text{con} \quad \mu = G(m_T + m_S) \quad , \tag{2.13}$$

donde, r es la distancia entre el satélite y el centro de masa de Tierra, $\vec{r} = X\hat{I} + Y\hat{J} + Z\hat{K}$ es el vector de posición del satélite en un sistema cartesiano considerando la Tierra como referencia (Fig. 2.3), $\ddot{\vec{r}}$ es el vector de aceleración del satélite, m_T y m_S son masa de la Tierra y del satélite respectivamente, G es la constante de gravitación universal cuyo valor es (6.6743 ±

0.00015)x10^{-11} $m^3kg^{-1}s^{-2}$. En un determinado momento, el vector de estado del satélite comprende su vector de velocidad $\vec{v} = \dot{\vec{r}} = v_X\hat{I} + v_Y\hat{J} + v_Z\hat{K}$ y aceleración $\vec{a} = \ddot{\vec{r}}$, este vector de estado puede ser determinado por los elementos de la órbita (Fig. 2.3), cuyas descripciones se muestran en la Tabla 2.2. En general se utilizan seis elementos de la órbita reportados en los boletines de la órbita, el cálculo de cada elemento se muestra en ANEXO I.

Como es bien sabido, no se disponen los datos de telemetría continua sobre los vectores de la posición ni de la velocidad, sino, se los calculan de manera inversa, a partir de los elementos orbitales para construir la órbita del satélite. Como describe Curtis en 2005, en una órbita elíptica, la anomalía media M_e se expresa por la ec. (2.14):

$$M_e = nt \quad , \tag{2.14}$$

donde, $n = \frac{2\pi}{T}$ es la velocidad angular media en una elipse. Y la anomalía excéntrica E se expresa por la ec. (2.15):

$$E = 2\tan^{-1}\left(\sqrt{\frac{1-e}{1+e}} \cdot \tan\left(\frac{\nu}{2}\right)\right) \quad , \tag{2.15}$$

donde, v es la anomalía verdadera. La ecuación de Kepler está dado por la ec. (2.16):

$$M_e = E - e\sin E \quad . \tag{2.16}$$

En general, se emplea el método de Newton para resolver la ec. (2.16) usando los datos proporcionados por satélites GPS, boletines de la órbita de las estaciones terrestres (Curtis, 2005; Kloster, 1989; Marsouin and Brunel, 1991), en el método de Newton, la función f(E) y su derivada se expresa por la ec. (2.17):

$$\begin{aligned} f(E) &= E - e\sin E - M_e \quad , \\ f'(E) &= 1 - e\cos E \quad . \end{aligned} \tag{2.17}$$

La solución se expresa por la ec. (2.18):

$$E_{i+1} = E_i - \frac{E_i - e\sin E_i - M_e}{1 - e\cos E_i} \quad , \tag{2.18}$$

donde, se asigna un factor de tolerancia para comparar con la razón $\frac{E_i - e\sin E_i - M_e}{1 - e\cos E_i}$, hasta que la razón tenga un valor inferior al valor de tolerancia (Curtis, 2005). El cálculo de los elementos de la órbita considera los tipos de la navegación (directo e indirecto). En una navegación directa,

se conoce la posición del pixel escaneado en la superficie de la Tierra en un determinado momento, por lo que, se debe conocer la posición del satélite con respecto a la Tierra y el ángulo de barrido en cada momento, y la navegación indirecta es un proceso que proyecta el punto geográfico en la superficie de la Tierra al campo de visión del satélite que realizó el barrido, en la cual, se específica los parámetros (instante de tiempo de escaneo, tamaño, proyección geográfica y resolución espacial) para determinar la ubicación geográfica de cada píxel de la imagen (Rosborough et al., 1994). Rojas recomendó que la navegación indirecta es más adecuada para las imágenes de AVHRR (Rojas et al., 2001). Este método contiene cinco pasos como describe Rosborough en 1994:

1. Calcular el vector posición del satélite hacia la superficie de la Tierra $\vec{d}(t)$ en un instante de tiempo. Como se ilustra en la Figura 2.4, para un tiempo t dado, el vector de posición del pixel la superficie y del satélite están representados por $\vec{R}$ y $\vec{r}(t)$ respectivamente, entonces, $\vec{d}(t) = \vec{R} - \vec{r}(t)$.

2. Determinar el vector $\vec{d}(t)$ en el sistema coordenado fijo al satélite incluyendo la matriz de rotación de actitud (si se encuentra disponible) mediante principalmente dos transformaciones del sistema de referencia como se describen en las siguientes subsecciones:

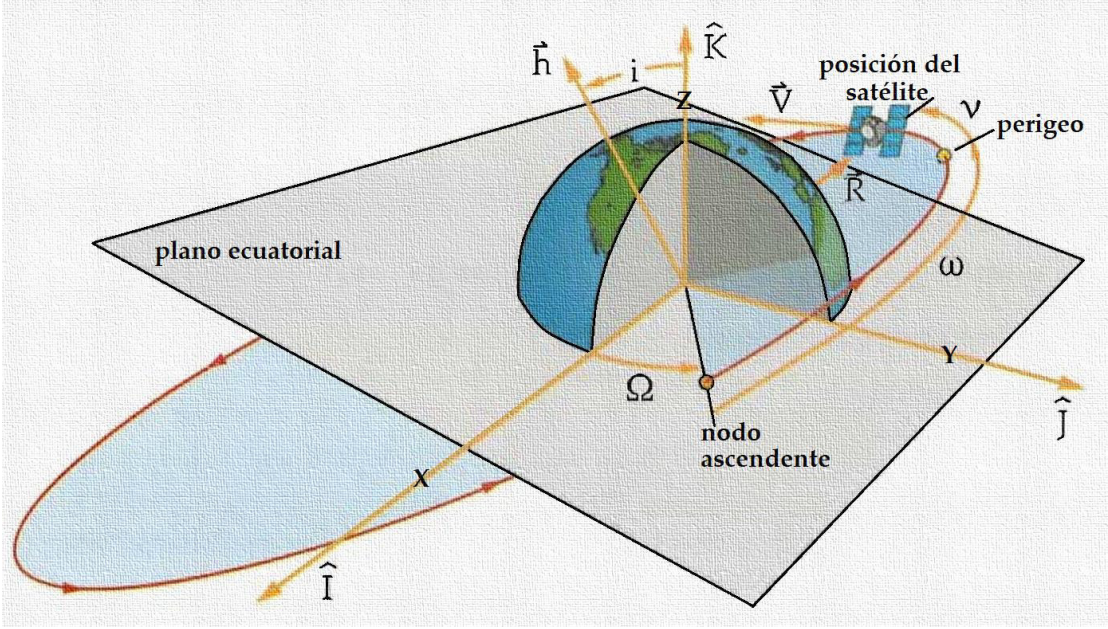

Figura 2.3. Esquema de algunos elementos orbitales (adaptado de Jerry et al., 2000).

Tabla 2.2 Características de los elementos orbitales (Jerry et al., 2000).

Símbolo	Parámetro	Descripción	Rango de valores
a	Semieje mayor	Tamaño de la órbita	
e	Excentricidad	Forma de la órbita	e = 0: Circulo 0 < e < 1: Elipse e = 1: Parábola e > 1: Hipérbola
i	Inclinación	Inclinación de la órbita	i = 0° o i =80°: Órbita ecuatorial i = 90°: Órbita polar 0° ≤ i < 90°: Satélite viaja en la dirección de la rotación de la Tierra. 90° < i ≤ 180°: Satélite viaja en contra la dirección de la rotación de la Tierra.
Ω	Longitud del nodo ascendente	Giro, ángulo desde el equinoccio de primavera hasta el nodo ascendente	0° ≤ Ω < 360°
ω	Argumento del perigeo	Ángulo desde el nodo ascendente hasta el perigeo	0° ≤ ω < 360°
ν	Anomalía verdadera	Ángulo desde el perigeo hasta la posición del satélite	0° ≤ ν < 360°

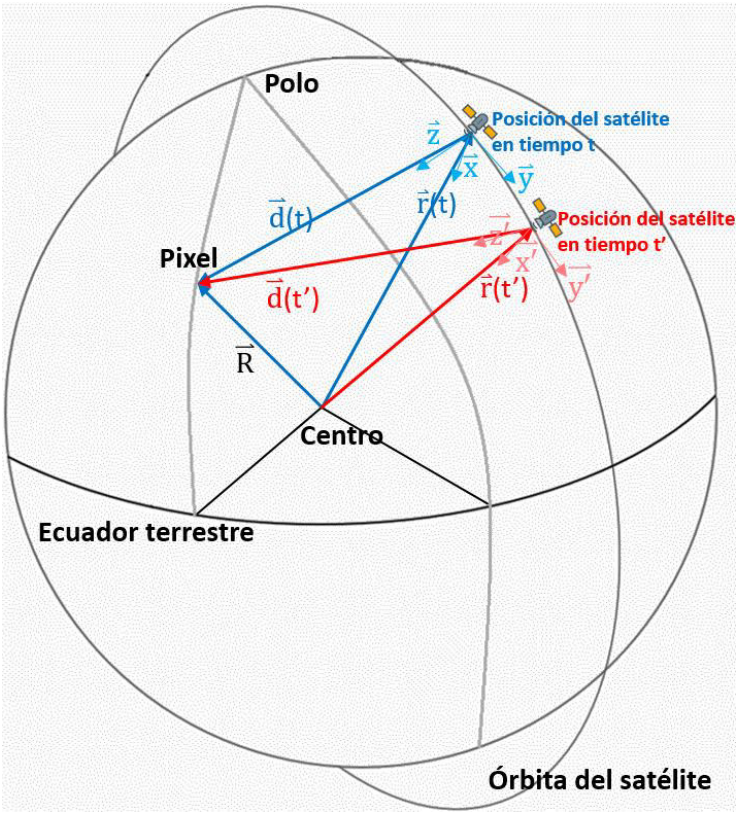

Figura 2.4. Esquema del movimiento del satélite en la órbita (adaptado de Rosborough et al., 1994).

Del sistema coordenado fijo a la Tierra al satélite geodésico

Si denotemos los vectores unitarios del sistema coordenado fijo a la Tierra (X, Y, Z) como $\vec{u}_x$,$\vec{u}_y$, $\vec{u}_z$, y los vectores del sistema coordenado geodésico del satélite (Xg, Yg, Zg) como $\vec{w}_x$,$\vec{w}_y$, $\vec{w}_z$, el vector $\vec{d}$ en el sistema geodésico $\vec{d}_g$ se expresa por la ec. (2.19):

$$\vec{d}_g = T\vec{d}$$

$$\text{con} \quad T = \begin{vmatrix} \vec{w}_x^T \\ \vec{w}_y^T \\ \vec{w}_z^T \end{vmatrix} \quad , \tag{2.19}$$

donde, $\vec{w}_x$ se expresa por los términos del sistema fijo a la Tierra en la ec. (2.20):

$$\vec{w}_x = -\cos\phi_s^* \cos\lambda_s \vec{u}_x - \cos\phi_s^* \sin\lambda_s \vec{u}_y - \sin\phi_s^* \vec{u}_z \quad , \tag{2.20}$$

donde, ϕ_s^* y λ_s son latitud y longitud geodésica del sensor, el vector unitario $\vec{w}_z$ se expresar por la ec. (2.21):

$$\vec{w}_z = \frac{\dot{\vec{r}}_s \times \vec{w}_x}{\left| \dot{\vec{r}}_s \times \vec{w}_x \right|} \quad , \tag{2.21}$$

donde, $\dot{\vec{r}}_s$ es el vector de velocidad de inercia del satélite se expresa por la ec. (2.22):

$$\dot{\vec{r}}_s = \dot{x}_s \vec{u}_x + \dot{y}_s \vec{u}_y + \dot{z}_s \vec{u}_z \quad , \tag{2.22}$$

finalmente, $\vec{w}_y$ se expresa por la ec. (2.23):

$$\vec{w}_y = \vec{w}_z \times \vec{w}_x \quad . \tag{2.23}$$

Del sistema geodésico del sensor al sistema coordenado fijo al satélite

En el sistema coordenado fijo al satélite se consideran efecto de rotación alrededor de los ejes de dirección (yaw), elevación (pitch) y alabeo (roll). El vector $\vec{d}$ en el sistema fijo al satélite $\vec{d}_b$ se expresa por la ec. (2.24):

$$\vec{d}_b = A\vec{d}_g \quad , \tag{2.24}$$

donde, A es la matriz de rotación de la actitud se expresa por la ec. (2.25):

$$A = \begin{vmatrix} \cos\xi_p \cos\xi_r & \cos\xi_p \sin\xi_r \sin\xi_y + \sin\xi_p \cos\xi_y & -\cos\xi_p \sin\xi_r \cos\xi_y + \sin\xi_p \sin\xi_y \\ -\sin\xi_p \cos\xi_r & -\sin\xi_p \sin\xi_r \sin\xi_y + \cos\xi_p \cos\xi_y & \sin\xi_p \sin\xi_r \cos\xi_y + \cos\xi_p \sin\xi_y \\ \sin\xi_r & -\cos\xi_r \sin\xi_y & \cos\xi_r \cos\xi_y \end{vmatrix} \quad . \tag{2.25}$$

donde, ξ_y, ξ_r y ξ_p son los ángulos de yaw, roll y pitch respectivamente.

3. Calcular la posición del vector $\vec{d}_b$ en el plano de escaneo. Dejamos que el vector $\vec{d}_b$ se expresa por la ec. (2.26):

$$\vec{d}_b = d_x \vec{v}_x + d_z \vec{v}_z + d_z \vec{v}_z \quad , \tag{2.26}$$

donde, $\vec{v}_x$, $\vec{v}_y$ y $\vec{v}_z$ son vectores unitarios del sistema coordenado fijo al satélite, el ángulo que forma $\vec{d}_b$ proyectado sobre plano X_b-Y_b con eje X_b positivo se expresa por la ec. (2.27):

$$\beta = \tan^{-1} \frac{d_y}{d_x} \quad , \tag{2.27}$$

4. Determinar cuánto debe avanzar o retrasarse el satélite a lo largo de la órbita para encajar el vector $\vec{d}_b$ en el plano de escaneo (β es cero). La corrección de anomalía verdadera que hace este ángulo hacia cero se expresa por la ec. (2.28):

$$\Delta\nu = \tan^{-1} \frac{d_{xy} \text{sen}\beta}{r_s - d_{xy} \cos\beta} \quad , \tag{2.28}$$

donde, d_{xy} es la proyección del vector $\vec{d}_b$ en el plano X_b-Y_b, r_s es la distancia geocéntrica al satélite.

5. Vuelven a calcular la posición y la velocidad del satélite en nuevo instante, y repetir este proceso hasta que el ángulo β igual a 0°.

En el cálculo de la posición del satélite, se consideran los errores en efemérides de la órbita y de actitud del satélite (Rosborough et al., 1994) debido a las perturbaciones en la órbita generadas por diversos factores tales como el viento solar, la gravedad del Sol y de la Tierra, la curvatura y rotación de la Tierra (Ho and Asem, 1986; Emery et al., 1989). Estas fuerzas extras no solo ejercen sobre el satélite objeto, también afectan la precisión de registro de posición de los satélites GPS (Global Positioning System). Para corregir los errores en las efemérides de la

órbita, Zhang recomienda uniformizar la distribución de las estaciones de recepción terrestre (Zhang et al., 2011) y Yu propone la importancia de uso de la cadena de los satélites GPS (Yu et al., 2019). Los errores de actitud ocurren cuando el satélite no está perfectamente alineado con su orientación de apuntamiento de referencia geodésica, la estimación de los errores puede obtener mediante la determinación de la diferencia (número de pixeles) entre pixel navegado y el punto de referencia conocida (Rosborough et al., 1994).

2.4 Detección de nubes

Se estimó un 66% de cubertura nubosa en la plantea Tierra (Zhang et al., 2004) empleando los datos del ISCCP-FD (International Satellite Cloud Climatology Project-Flux Data). Los efectos de brillo por las nubes y de oscurecimiento por las sombras de las nubes influyen significativamente en la reflectancia espectral real de la superficie de la Tierra (Zhu and Woodcock, 2014; Vera, 2005). Por otro lado, el ángulo cenit del Sol y de la visión, y la cubertura nubosa varía con el tiempo durante el barrido del satélite que afectará la calidad de los datos. Se consideraron la técnica de detección de nubes como un componente importante en el procesamiento para el ISCCP (Schiffer and Rossow, 1983).

El método de detección más común es utilizar los umbrales basado en características espectrales de los objetos, en la cual, se usan gradualmente, de los umbrales simples (Kegelmeyer, 1994) a los más complejos, como umbrales agrupados (Baum and Trepte, 1999), umbrales obtenidos por razón de canales (Irish, 2000) y umbrales dinámicos (Jedlovec et al., 2008). Estos métodos mencionados no consideran la relación entre los píxeles vecinos, para ello, se han propuesto los métodos estadísticos (Wang et al., 2017; Deng et al., 2018) que utiliza datos de muestra para construir la fórmula de simulación que permite estimar la reflectancia y temperatura de brillo para la detección del pixel contaminado por las nubes (Molnar and Coakley, 1985), así mismo, se han desarrollado el método del análisis de textura (Dong et al., 2019) que trata de explotar la similitud de las propiedades de un objeto y la discontinuidad de los límites entre los objetos (Christodoulou et al., 2003).

Por otro lado, se han desarrollado los algoritmos de aprendizaje automático, tales como, el bayesiano (Pearson et al., 2014), los vectores de soporte automático (Ishida et al., 2018), redes neuronales probabilísticas (Bankert, 1994) y Deep-learning (Ma et al., 2021) para evitar la

configuración manual de los umbrales y de las condiciones espectrales (Visa et al., 1991; Liu et al., 2021).

Es poco probable que exista un solo algoritmo aplicable para todos tipos de sensor, hasta que con el mismo sensor, se producirá distintos efectos por la variación diurna. Los algoritmos más usados a escala global son , CLAVR (Clouds from AVHRR) y APOLLO (AVHRR Processing Over Land cLoud and Ocean). El ISCCP asume que la variabilidad espacial de la radiancia espectral es menor en condiciones despejadas, en una región pequeña, se calcula la diferencia entre valor máximo y valor del pixel, en la cual, se considera el pixel nuboso cuando esta diferencia supera al valor umbral (Rossow and Garder, 1994; Kotarba, 2015). El algoritmo CLAVR usa una matriz de 2 x 2 pixeles como una unidad para determinar si este conjunto de pixeles son nubes, despejados o mixtos, a los pixeles mixtos, vuelve a pasar algunas pruebas más específicos como control de calidad (Stowe et al., 1991). En el algoritmo APOLLO un pixel es determinado como pixel limpio siempre cuando falla en todas las pruebas (Saunders et al., 1988). En este trabajo se utilizó el algoritmo CLAVR adaptado para condiciones locales. Según Stowe, el CLAVR se basa en el siguiente fundamento:

En el espectro solar (0.3~3 mm), la cantidad de la radiación del Sol reflejada está en función de la composición física y química de la superficie de la Tierra y de la atmósfera. Esta composición es la que distingue los objetos en la superficie y los componentes atmosféricos. Las diferencias de composición suelen hacer que algunos componentes sean altamente reflectantes (nubes, nieve y hielo), otros moderadamente reflectantes (desiertos, tierras estériles) y el resto poco reflectantes (océano, vegetación). Esta propiedad es mencionada por Davis en 1984 (Davis et al., 1984) y puede utilizarse para la detección de la presencia de algunos de estos componentes tierra-atmósfera por diferencias en la reflectancia que se denominan como firmas espectrales.

En el infrarrojo térmico (3~20 mm), los competentes pueden discriminarse por los tres tipos de firmas mencionadas, sin embargo, son el resultado de un proceso de la absorción y reemisión en lugar de la reflexión y scatering. La radiación infrarroja es proporcional a la temperatura de la imagen, por lo que las firmas de contraste son las que separan las superficies frías de las calientes. Por otro lado, existen firmas espaciales debido a las diferencias de escala entre las inhomogeneidades espaciales de las nubes y la superficie subyacente (Coakley and Bretherton, 1982).

El algoritmo CLAVR realiza las pruebas para condición diurna y nocturna de forma separada, y se especifican valor de los umbrales por dos tipos de superficie: suelo y océano (Tabla 2.3).

Tabla 2.3 Umbrales utilizados para las pruebas (adaptado de Stowe et al., 1999).

		Suelo		**Mar**	
	Prueba	**Canal**	**Umbral**	**Canal**	**Umbral**
Diurna	Prueba de nubes/mixtos				
	RGCT (Reflectance Gross Cloud Test)	1	>44%	2	>30%
	RUT (Reflectance Uniformity Test)	1	>9%	2	>0.3%
	RRCT (Reflectance Ratio Cloud Test)	2/1	0.9<R<1.1	2/1	0.9<R<1.1
	C3AT (Channel-3 Albedo Test)	3, 4, 5	>6%	3, 4, 5	>3%
	TUT (Termal Uniformity Test)	4	>3 K	4	>0.5 K
	FMFT (Four-Minus-Five Test)	4, 5	>fcn T_4	4, 5	>fcn T_4
	TGCT (Thermal Gross Cloud Test)	4	<249 K	4	<271 K
	Prueba de pixeles restaurados				
	C3AR (Channel-3 Albedo Restoral)	3	<3%	3	<3%
	TUR (Thermal Uniformity Restoral)	4	<1 K	4	<0.5 K
	TGCR (Thermal Gross Cloud Restoral)	4	>293 K		
Nocturna	Prueba de nubes/mixtos				
	TGCT (Thermal Gross Cloud Test)	4	<249 K	4	<271 K
	TUT	4	>3 K	4	>0.5 K
	ULST (Uniform Low Stratus Test)	3, 5	<fcn T_4	3, 5	<fcn T_4
	FMFT (Four-Minus-Five Restoral)	4, 5	>fcn T_4	4, 5	>fcn T_4
	CIRT (Cirrus Test)	3, 5	>fcn T_4	3, 5	>fcn T_4
	Prueba de pixeles restaurados				
	FMFR (Four-Minus-Five Restoral)	4, 5	<fcn T_4	4, 5	<fcn T_4

2.5 Índices de Vegetación

NDVI

La firma espectral de la vegetación es bastante diferente a la del suelo (Fig 2.5) para la longitud de onda $\lambda = 0.35$ μm, la refletancia de los suelos y del pasto es alrededor de valor de 0.05, para los suelos seco y húmedo, la reflectancia crece linealmente con el aumento de la longitud de onda, para $\lambda = 1.00$ μm, la reflectancia del suelo seco y húmedo se aproxima a 0.27 y 0.2 respectivamente, en cambio, para la firma del pasto, se observó un valle (reflectancia ≈ 0.07) para 0.60 μm < λ < 0.68 μm, y una región de valor máximo (reflectancia ≈ 0.3) para 0.73 μm < λ < 1.00 μm. Basando en esta característica espectral de la vegetación, Pearson y Miller

propusieron el Índice RVI (Ratio Vegetation Index) con el fin de estimar el estado de crecimiento de la vegetación (Pearson and Miller, 1972) y se expresa por la ec. (2.29):

$$\mathrm{RVI} = \frac{\mathrm{Ref}_{\mathrm{NIR}}}{\mathrm{Ref}_{\mathrm{RED}}} \quad , \tag{2.29}$$

donde, y $\mathrm{Ref}_{\mathrm{NIR}}$ y $\mathrm{Ref}_{\mathrm{RED}}$ son las reflectancias correspondientes a los canales 2 y 1 respectivamente para el sensor AVHRR. Para la vegetación verde densa, a medida que la $\mathrm{Ref}_{\mathrm{RED}}$ se aproxima a cero, el valor de RVI aumenta sin límite. Por lo tanto, el RVI es sumamente sensible al cambio de vegetación durante la época de máximo crecimiento y no es sensible cuando la cobertura vegetal es dispersa (Jackson and Huete, 1991). En el 1974, Rouse propuso una fórmula para normalizar el RVI que denomina el NDVI (Rouse, 1974) expresada por la ec. (2.30):

$$\mathrm{NDVI} = \frac{\mathrm{RVI}-1}{\mathrm{RVI}+1} = \frac{\mathrm{Ref}_{\mathrm{NIR}}-\mathrm{Ref}_{\mathrm{RED}}}{\mathrm{Ref}_{\mathrm{NIR}}+\mathrm{Ref}_{\mathrm{RED}}} \quad . \tag{2.30}$$

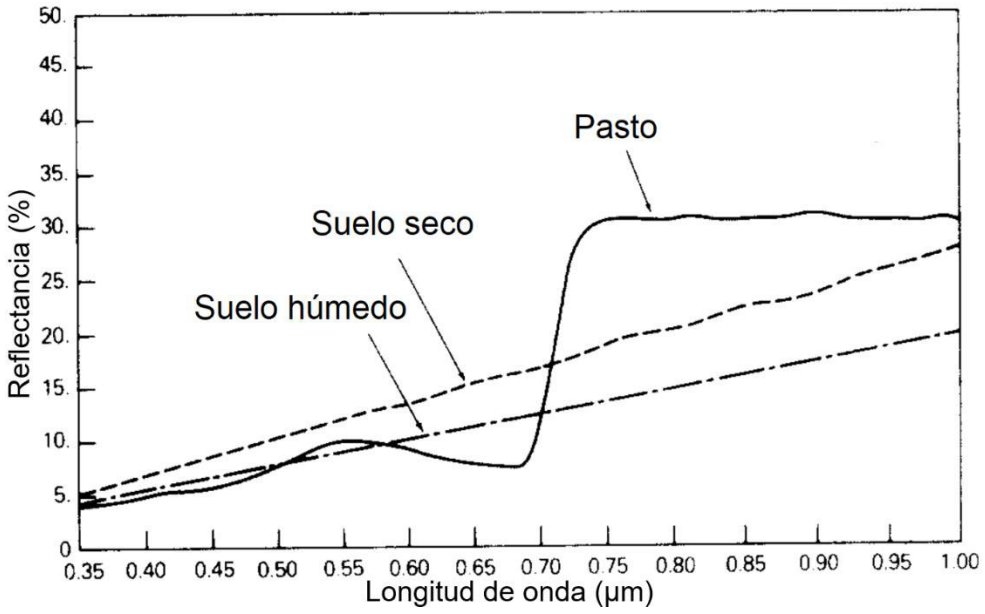

Figura 2.5. Firma espectral de la reflectancia del suelo en estados seco y húmedo, y de pasto de biomasa seca de 530 g m^{-2} (adaptado de Tucker and Miller, 1977).

La Figura 2.6 muestra la gráfica de dispersión de las reflectancias de cuatro tipos de objeto, vegetaciones densa y dispersa, suelos brillante y oscuro, con las isolineas del NDVI en la región de cuenca del Congo (Njomo, 2008). Se puede observar que la vegetación densa se encuentra entre NDVI de 0.4 al 0.6, y la proporción entre la reflectancia $\mathrm{Ref}_{\mathrm{NIR}}$ y $\mathrm{Ref}_{\mathrm{RED}}$ es casi 3 a 1, mientras que, para la vegetación dispersa, los suelos brillantes y oscuros se centran en el mismo rango del NDVI de 0 al 0.2, y se aproximan los valores de $\mathrm{Ref}_{\mathrm{NIR}}$ y $\mathrm{Ref}_{\mathrm{RED}}$. Donde, el suelo

brillante tiene mayor reflectancia (> 0.3) mientras que los valores de la reflectancia son similares para la vegetación dispersa y suelo oscuro que se encuentran en el rango de 0.2 al 0.3 aproximadamente.

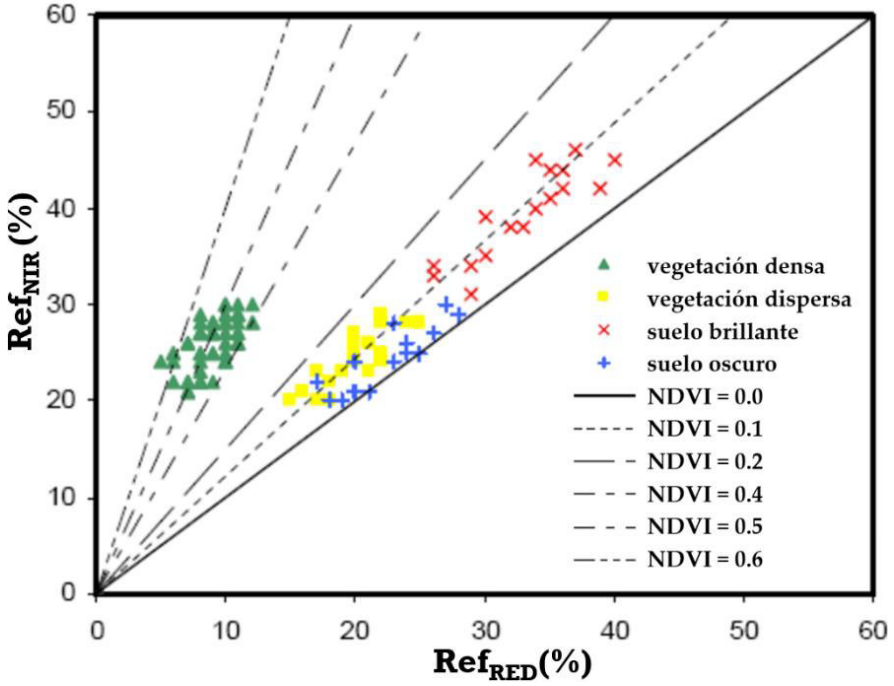

Figura 2.6. Gráfico de dispersión de los valores de las reflectancias Ref_{NIR} y Ref_{RED} para las vegetaciones densa y dispersa, y suelos brillantes y oscuros con las isolíneas del NDVI (adaptado de Njomo, 2008).

VCI

El VCI propuesto por Kogan permite cuantificar el estado de saludo de la vegetación (Kogan, 1995), normalizando el NDVI del i-ésimo mes en la serie histórica del mismo mes como se expresa en ec. (2.31):

$$VCI_{i,j} = \frac{NDVI_{i,j} - NDVI_{i,min}}{NDVI_{i,max} + NDVI_{i,min}} \quad , \tag{2.31}$$

donde, $VCI_{i,j}$ y $NDVI_{i,j}$ representan el valor del i-ésimo mes y j-ésimo año del VCI y NDVI respectivamente, $NDVI_{i,min}$ y $NDVI_{i,max}$ representan el valor mínimo y máximo del i-ésimo mes para el periodo de estudio. El VCI basado en los datos de AHVRR ha sido ampliamente aceptado por su idoneidad para evaluar una serie de parámetros de estimación de índices de vegetación (Dutta et al., 2015).

2.6 Prueba de tendencia de Mann-Kendall

La prueba no paramétrica de MK (Mann y Kendall) permite determinar si había una tendencia positiva o negativa del NDVI a largo plazo con su significación estadística (Gocic and Trajkovic, 2013). A diferencia de un método paramétrico, la prueba de MK no requiere la distribución normal de los datos sino, solo que sean independientes. El estadístico S de prueba de MK (Mann, 1945; Kendall, 1970) está dado por la ec. (2.32):

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^{n} f(NDVI_j - NDVI_i) \quad , \tag{2.32}$$

donde, n es el número de meses del NDVI, es decir, para cada píxel de la imagen, se ordenan los valores del NDVI con respecto al tiempo: NDVI = {$NDVI_1$, $NDVI_2$, …, $NDVI_n$}, donde, $NDVI_j$ y $NDVI_i$ son el i-ésimo y el j-ésimo valor de la serie (j > i) respectivamente, la función de signo f($NDVI_j$ - $NDVI_i$) está dado por la ec. (2.33):

$$f(NDVI_j - NDVI_i) = \begin{cases} +1, & si \quad NDVI_j - NDVI_i > 0 \\ 0, & si \quad NDVI_j - NDVI_i = 0 \\ -1, & si \quad NDVI_j - NDVI_i < 0 \end{cases} . \tag{2.33}$$

Para una serie de n meses, se debe determinar un total de $\frac{n(n-1)}{2}$ valores de f($NDVI_j$-$NDVI_i$), si en n<=10, el valor de S se encuentra en la tabla de probabilidad para MK (Fig. 2.7) y cuya relación con el estadístico Z se expresa por la ec. (2.34):

$$z = \frac{S}{\frac{n(n-1)}{2}} \quad . \tag{2.34}$$

En caso general (n>10), se calcula la varianza de S con la ec. (2.35):

$$Var(S) = \frac{1}{18} \left[n(n-1)(2n+5) - \sum_{i=1}^{m} t_i (t_i - 1)(2t_i + 5) \right] \quad , \tag{2.35}$$

donde, m es el número de grupos con valores idénticos, t_i es número de valores iguales en el i-ésimo grupo. En caso de que los valores nunca se repite, entonces, los $t_i = 1$ y la varianza Var(S) se simplifica a $\frac{n(n-1)(2n+5)}{18}$. El estadístico Z_S de la prueba normal estándar está dado por la ec. (2.36):

$$Z_S = \begin{cases} \dfrac{S-1}{\sqrt{Var(S)}}, & si \;\; S > 0 \\ 0 \quad , & si \;\; S = 0 \\ \dfrac{S-1}{\sqrt{Var(S)}}, & si \;\; S < 0 \end{cases} . \tag{2.36}$$

Los valores positivos de Z_S indican las tendencias positivas, mientras los valores negativos muestran las tendencias negativas. En una prueba bilateral, dando un nivel de significancia α, cuando $|Z_S| > Z_{1-\alpha/2}$, se rechaza la hipótesis nula, esto significa que los datos tienen una tendencia estadísticamente. El algoritmo para generar la matriz de p-valor de la prueba se muestra en el ANEXO II, donde, la función de MK fue elaborado por los doctores Paola Arias de Georgia Tech y Juarez de la universidad Tulane.

Table A18 Probabilities for the Mann-Kendall Nonparametric Test for Trend

S	Values of n				S	Values of n		
	4	5	8	9		6	7	10
0	0.625	0.592	0.548	0.540	1	0.500	0.500	0.500
2	0.375	0.408	0.452	0.460	3	0.360	0.386	0.431
4	0.167	0.242	0.360	0.381	5	0.235	0.281	0.364
6	0.042	0.117	0.274	0.306	7	0.136	0.191	0.300
8		0.042	0.199	0.238	9	0.068	0.119	0.242
10		0.0^283	0.138	0.179	11	0.028	0.068	0.190
12			0.089	0.130	13	0.0^283	0.035	0.146
14			0.054	0.090	15	0.0^214	0.015	0.108
16			0.031	0.060	17		0.0^254	0.078
18			0.016	0.038	19		0.0^214	0.054
20			0.0^271	0.022	21		0.0^320	0.036
22			0.0^228	0.012	23			0.023
24			0.0^387	0.0^263	25			0.014
26			0.0^319	0.0^229	27			0.0^283
28			0.0^425	0.0^212	29			0.0^246
30				0.0^343	31			0.0^223
32				0.0^312	33			0.0^211
34				0.0^425	35			0.0^347
36				0.0^528	37			0.0^318
					39			0.0^458
					41			0.0^415
					43			0.0^528
					45			0.0^628

Figura 2.7. Tabla de probabilidad para la prueba de Mann-Kendall (Gilbert, 1987).

Capítulo 3

Datos Utilizados

En este capítulo, se describe el área de estudio y los tres conjuntos de datos utilizados en el trabajo de tesis, que son los datos de AVHRR, los productos del NDVI mensual del sensor MODIS y los productos de precipitación mensual del TRMM (Tropical Rainfall Measuring Mission).

3.1 Área de estudio

El área de estudio comprende todo el territorio peruano (-81.5 a -68 longitud y -3.2 a -18.5 latitud), que se encuentran el punto extremo norte en la vaguada del río Putumayo en Güepi (00°01'48''S y 75°10'29''O); el punto extremo sur en el punto de la Concordia (18°21'08''S y 70°22'39''O); el punto extremo este en la confluencia del río Heath con el río Madre de Dios (12°30'11''S y 68° 39'27''O); el punto extremo oeste en la punta Pariñas (04°40'45''S y 81°19'35''O). La cordillera central atraviesa el Perú de sur a norte con una altitud mayor a 4000 m que divide el Perú en dos regiones de baja altitud (< 500 m): costa y selva (Fig. 3.1).

3.2 Imágenes diarias en formato LAC/AVHRR

Para el periodo de estudio, se procesaron 15988 imágenes de los sensores AVHRR/2 y /3 a bordo de la serie de satélites NOAA (Fig. 3.2). Los datos son de nivel 1b, tienen una resolución espacial de 1 km, temporal de 12 horas y están almacenados en números digitales binarios de 10 bits en archivo en formato LAC (Local Area Coverage). Los datos son disponibles al público en el portal CLASS de la NOAA. (Fuente: https://www.avl.class.noaa.gov/).

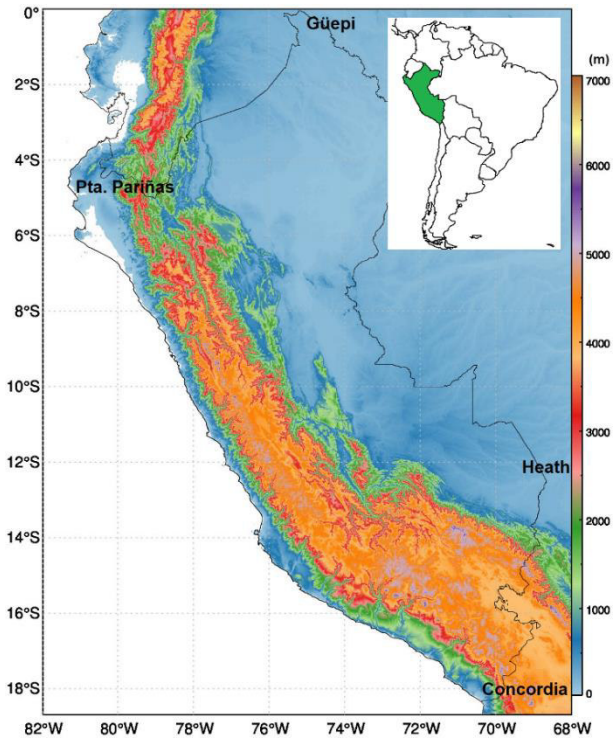

Figura 3.1. Área de estudio: Perú-América Sur. La imagen muestra el modelo de elevación digital del Perú con sus alturas, costas, andinas y amazonia empleando el modelo Etopo 2022 de 15° de arco de resolución espacial. (Fuente: https://www.ncei.noaa.gov/maps/grid-extract/)

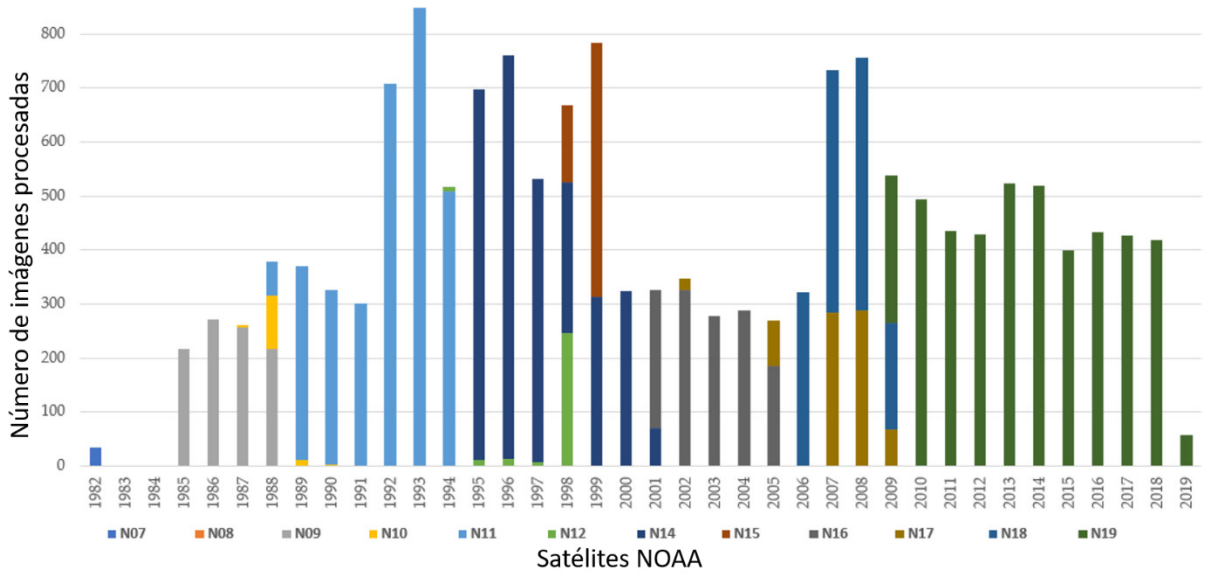

Figura 3.2. Número de imágenes procesadas, clasificado por año y por satélite.

En general, la imagen diaria del Perú está formado por 1~2 escenas (Fig. 3.3), se crea un archivo en formato LAC para almacenar cada imagen con sus cabeceros incluidos. El nombre estandarizado de cada archivo que almacena los datos se muestra como siguiente ejemplo:

NSS.LHRR.NN.D07053.S1910.E1922.B0907172.WI

NSS	=	Centro de procesamiento NOAA/NESDIS
LHRR	=	Archivo en formato LAC
NN	=	Satélite NOAA-18
D07053	=	Día 53 del año 2007
S1910	=	Hora inicio de barrido 19:10
E1922	=	Hora final de barrido 19:22
B0907172	=	Número de la órbita durante el barrido: inicio 9071, final 9072
WI	=	Fuente de datos, WI = Wallop Island, EE. UU.

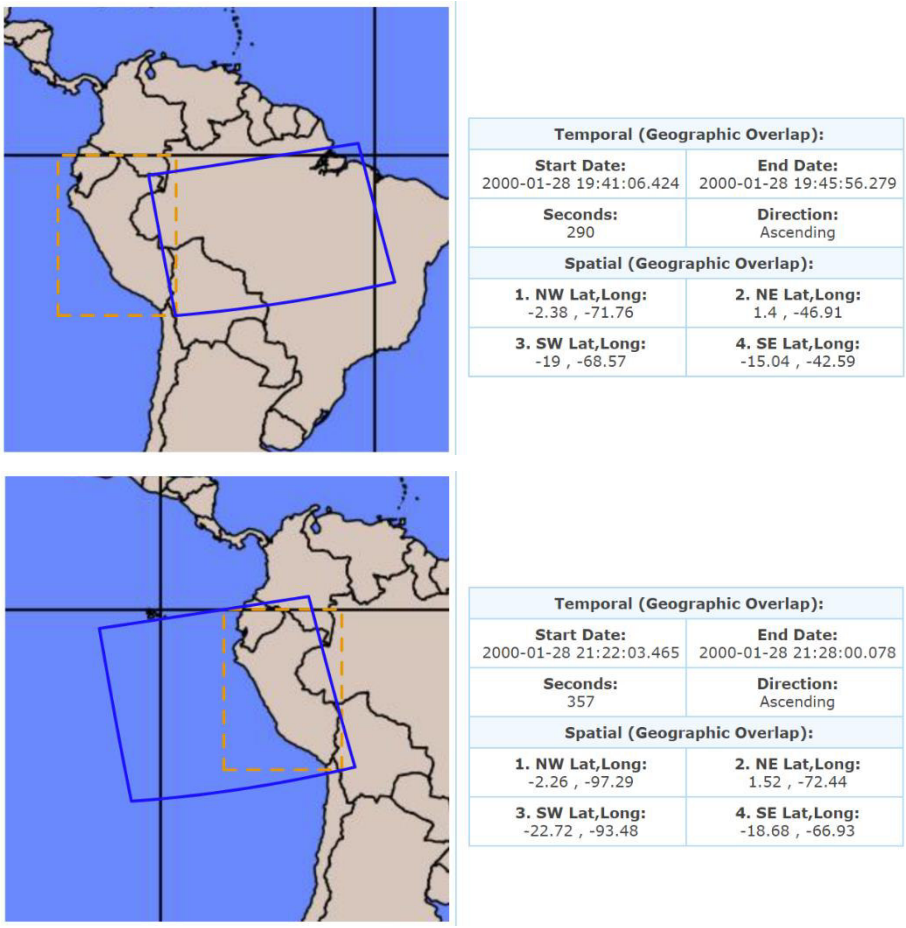

Temporal (Geographic Overlap):	
Start Date: 2000-01-28 19:41:06.424	**End Date:** 2000-01-28 19:45:56.279
Seconds: 290	**Direction:** Ascending
Spatial (Geographic Overlap):	
1. NW Lat,Long: -2.38 , -71.76	**2. NE Lat,Long:** 1.4 , -46.91
3. SW Lat,Long: -19 , -68.57	**4. SE Lat,Long:** -15.04 , -42.59

Temporal (Geographic Overlap):	
Start Date: 2000-01-28 21:22:03.465	**End Date:** 2000-01-28 21:28:00.078
Seconds: 357	**Direction:** Ascending
Spatial (Geographic Overlap):	
1. NW Lat,Long: -2.26 , -97.29	**2. NE Lat,Long:** 1.52 , -72.44
3. SW Lat,Long: -22.72 , -93.48	**4. SE Lat,Long:** -18.68 , -66.93

Figura 3.3. Las dos escenas adquiridas para el día 28 de enero del 2000 (trazo naranja: área solicitada y rectángulo azul: área de barrido del satélite).

Estructura del formato LAC para AVHRR/3

Cada archivo LAC contiene tres paquetes: ARS (Archive Retrieval System), Header Records y Data Records, Donde:

ARS tiene un tamaño de 512 bytes, en la cual se describen informaciones primarias tales como nombre del archivo, ubicación de la estación de recepción, fecha de creación de los datos y otros (Goodrum et al., 2001).

Header Record tiene un tamaño de 15872 bytes y registra el tiempo de barrido y los parámetros orbitales del satélite (Goodrum et al., 2001).

Data Record tiene un tamaño de 15872 x N bytes (N = número de filas de la matriz de datos, número de columnas = 2048). Este registro se divide en tres grupos: En los primeros 1264 bytes se están almacenan los coeficientes de calibración radiométrica y de telemetría; entre los bytes 1265 y 14928 (13656 bytes en total) se almacenan la matriz de los datos en formato binario de 10 bits. Este grupo intermedio se denomina AVHRR SENSOR DATA (barra azul en la Figura 3.4), que está formado por 3414 subpaquetes, en cada subpaquete se almacena 32 bits de información. Para el primer subpaquete, los primeros 10 bits registra el valor del DN de la columna 1 de la fila 1 del canal 1, los siguientes 10 bits representa el DN del pixel de la columna 1 de la fila 1 del canal 2, del bit 20 al 29 representa el DN del primer pixel de la columna 1 de la fila 1del canal 3, y bits 30 y 31 se rellenan con ceros, de esta manera, se completaría el registro de los datos de una imagen (Figura 3.4). En preprocesamieto, se debe convertir los datos de 10 bits a 8 o 16 bits (Goodrum et al., 2001). Fuente para AVHRR/3: https://www1.ncdc.noaa.gov/pub/data/satellite/publications/podguides/N-15%20thru%20N-19/pdf/

La estructura de los datos del sensor AVHRR/2 es similar al AVHRR/3, sus manuales de usuario están disponibles en el portal de la NOAA: Fuente para AVHRR/2: https://www1.ncdc.noaa.gov/pub/data/satellite/publications/podguides/TIROS-N%20thru%20N-14/pdf/

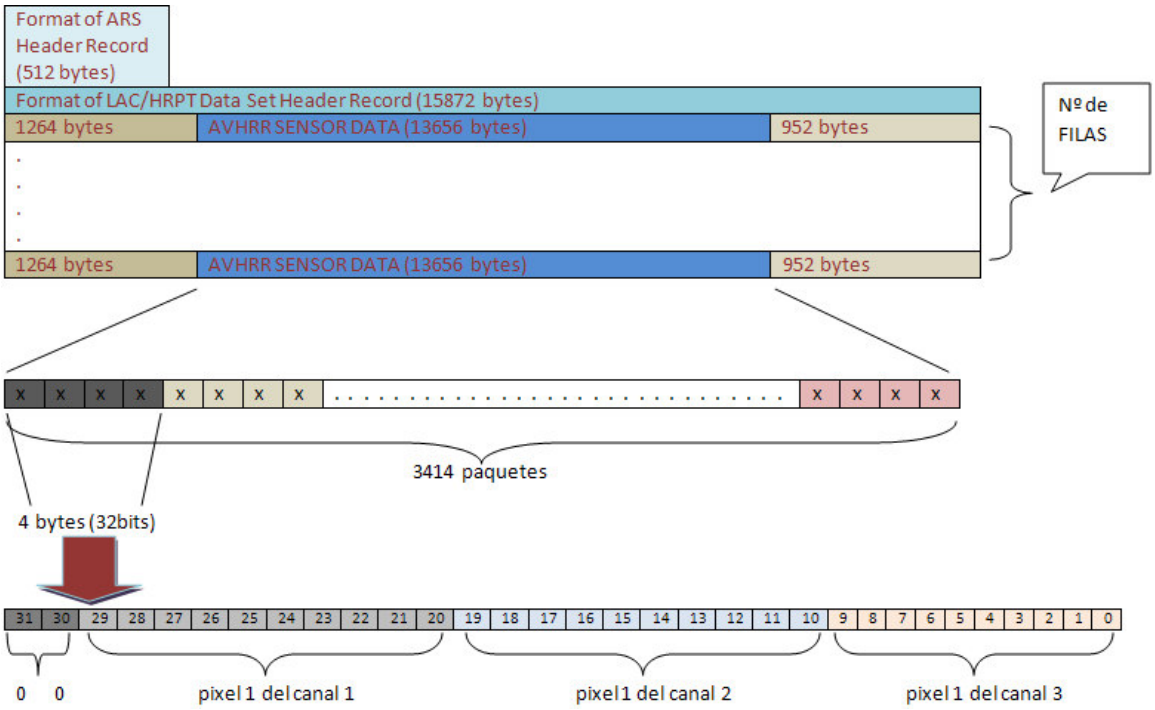

Figura 3.4. Estructura de un archivo LAC del sensor AVHRR/3 (adaptado de Goodrum et al., 2001).

3.3 Imágenes mensuales en formato HDF NDVI/MODIS-AQUA

El producto del NDVI mensual del MODIS/TERRA (MOD13C2) es usado para comparar con el NDVI estimado por AVHRR, compuesto por los datos diarios del NDVI bajo condición de libre de nubes, publicado en el portal Giovanni del GESDISC (Goddard Earth Sciences Data and Information Services Center) de la NASA (National Aeronautics and Space Administration), dicho producto tiene una resolución espacial de 0.05° en CMG (Climate Modeling Grid). La Figura 3.5 muestra la carta del promedio mensual del NDVI/MODIS corresponde al febrero del 2000.

Fuente:

https://giovanni.gsfc.nasa.gov/giovanni/#service=TmAvMp&starttime=&endtime=&dataKeyword=NDVI

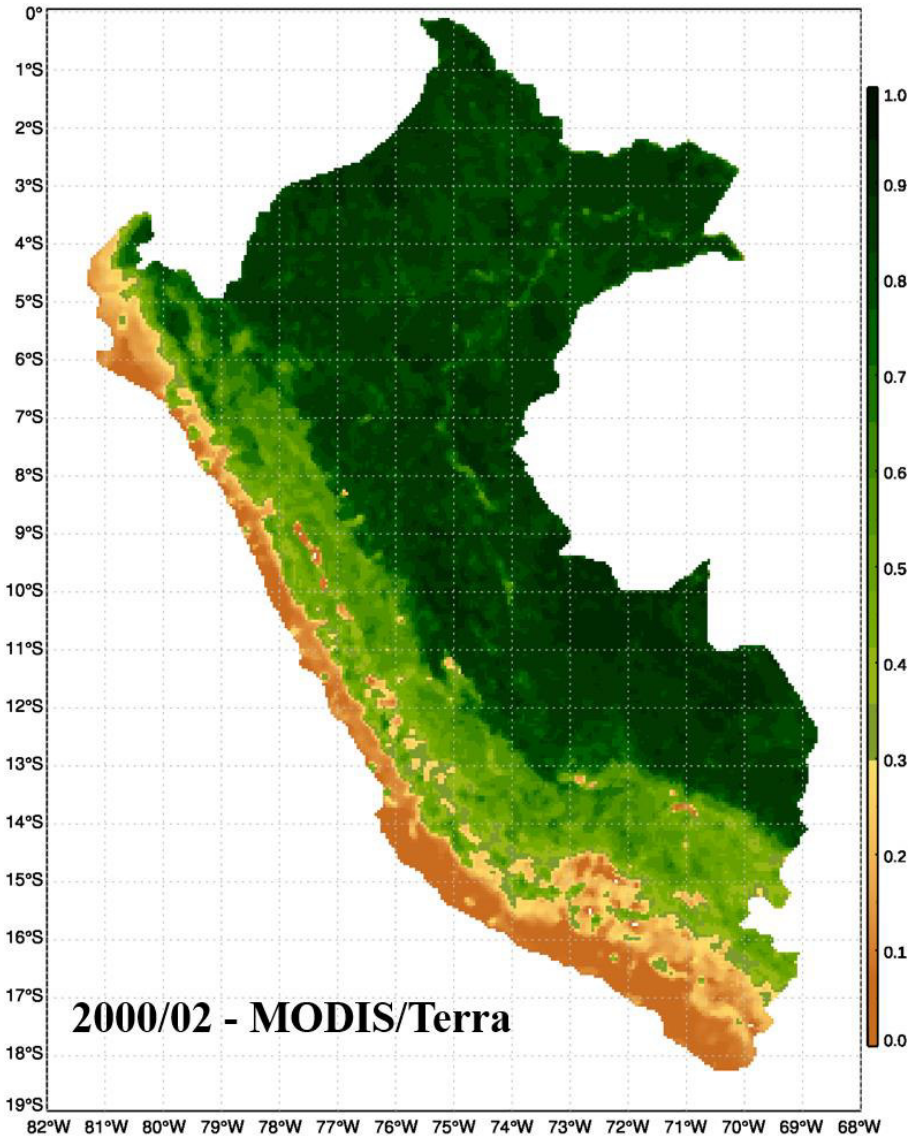

Figura 3.5. Promedio mensual de NDVI/MODIS para el mes de febrero del 2000.

3.4 Precipitación mensual del TRMM

El producto de precipitación mensual TRMM 3B43 fue creado usando la tasa de precipitación medido por microondas e infrarrojo en mm/hora y las estimaciones de error de precipitación por método de RMS (Root Mean Square), los datos están disponibles en el portal Giovanni del GESDISC de la NASA en formato "*.Geotiff", con resolución espacial de 0.25° x 0.25° para el periodo de 1998 hasta 2019. La Figura 3.6 muestra la carta del promedio mensual de la precipitación TRMM corresponde al enero del 1998.

Fuente:

https://giovanni.gsfc.nasa.gov/giovanni/#service=TmAvMp&starttime=&endtime=&dataKeyword=3b43

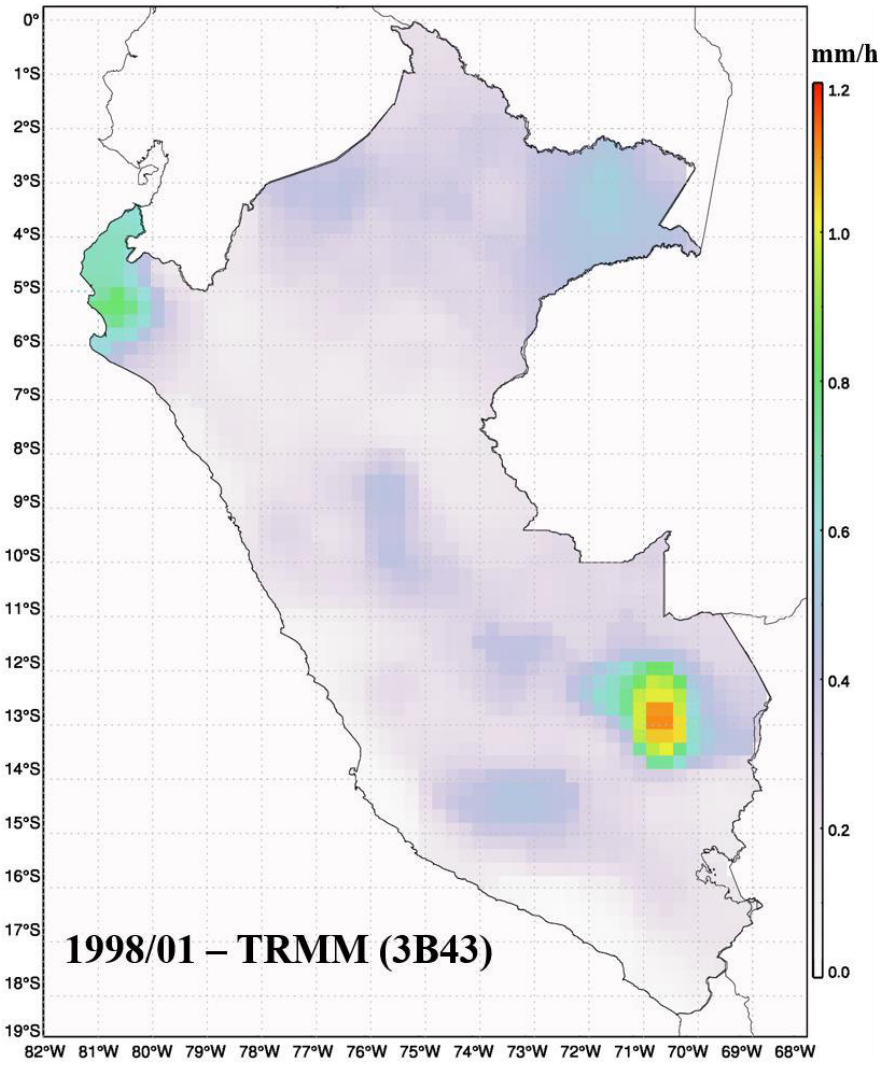

Figura 3.6. Promedio mensual de la precipitación del TRMM para el mes de enero del 1998.

Capítulo 4

Metodología

En este capítulo, se describe detalladamente la metodología del procesamiento de los datos. Se utilizó dos imágenes de escena del mismo día y escogió un pixel en la imagen como ejemplo para explicar cada paso del procesamiento que empieza con la lectura de los datos de números digitales, luego la corrección radiométrica y geométrica de cada canal espectral de cada imagen, el mosaico de las imágenes diarias, el filtrado de nubes, el redimensionado para estandarizar la dimensión de las imágenes y finalmente el cálculo de los índices (Fig. 4.1).

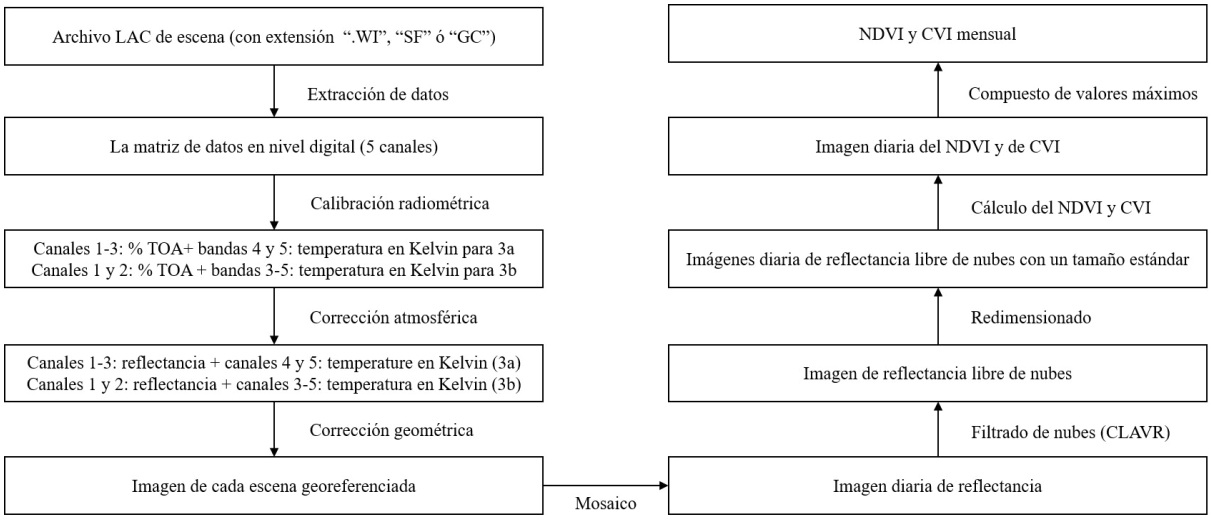

Figura 4.1. Secuencia del procesamiento del sensor AVHRR.

4.1 Extracción de Números Digitales

Las dos imágenes utilizadas fueron del día 02 de enero del 2019, a las 15:28 y 16:58 horas locales respectivamente. El uso de la combinación R(1)-G(2)-B(1) de imágenes en nivel DN (Fig. 4.2) que permite observar los cuerpos de agua (oscuro), suelo (verde) y nubes (blanco). Los datos provienen de la NOAA-19, el intervalo de tiempo de barrido fue de una hora y media. Todas las imágenes de AVHRR tienen mismo número de columnas (2048 pixeles), sin embargo, el número de filas es distinto.

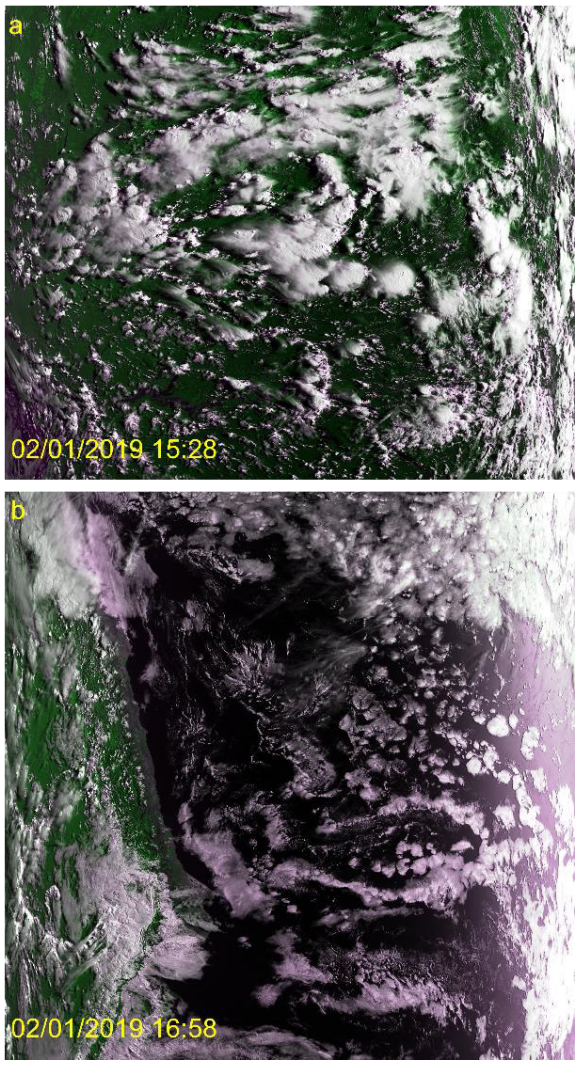

Figura 4.2. Imágenes de falso color para el área de estudio a las horas (a) 15:28 y (b) 16:58 del día 02 de enero del 2019.

4.2 Calibración radiométrica

Conociendo la estructura del archivo LAC, se puede extraer los datos desde nivel de DN y los coeficientes de calibración radiométrica. Donde, los coeficientes están almacenados en archivo cabecero: para los canales 1, 2 y 3a, se utilizarán los coeficientes a y b de la ec. (2.6), y para los canales 3b, 4 y 5, se utilizarán los coeficientes a_0, a_1, a_2, ν_c, A y B de las ecuaciones (2.11) y (2.12).

La Tabla 4.1 muestra el cálculo de reflectancia de un pixel ([480, 780] de la Figura 4.2b) como ejemplo, la ubicación del pixel está en la ciudad de Lima aproximadamente. Los datos de entrada del cálculo son los DN; para los canales 1 y 2, la selección de los coeficientes a y b es mediante el método umbral, sin embargo, para los canales 3b, 4 y 5, los coeficientes son constantes. El cálculo final muestra resultados obtenidos usando el lenguaje de programación IDL y el software ENVI (celdas en color oscuro), se obtuvo mismos valores (% Reflectancia) para los canales 1 y 2, y una ligera diferencia de temperatura (en grados Kelvin) en los canales 4 y 5 (1 K), para el canal 3b, la diferencia fue de 3 K.

El análisis comparativo de los canales de temperatura se realizó mediante diagramas de dispersión, en la cual, se escogió áreas de 50 x 50 pixeles de tres tipos de objetos en la superficie como muestras: suelo (Fig. 4.3a), mar (Fig. 4.3b) y nubes (Fig. 4.3c). Se puede observar que, para los tres tipos de objetos, la relación entre la temperatura estimada por IDL y por ENVI es lineal con alta correlación para cada canal espectral, donde los puntos se ubican alrededor de la línea de identidad (Figura 4.3). Así mismo, la variación de temperatura es distinta para los tipos de pixel, para el suelo, la temperatura de una área de 2500 km^2 varía de 289 a 311K, para el mar, esta variación es mínima (290~296K) y se registró mayor variación (215~302K) en las nubes (Figura 4.3). En este trabajo de tesis, se utilizó las funciones de ENVI en IDL para realizar las correcciones radiométricas y geométricas (ANEXO III) debido a que la cantidad de datos es enorme.

Tabla 4.1. Ejemplo del cálculo de un mismo pixel para cada canal espectral.

Datos de entrada		**Cálculo**							**Cálculo final**	
Canal	**DN**	**Coeficientes de calibración**								
		Si DN > 497.5			**Si DN ≤ 497.5**				**% Reflectancia**	
1	**DN**	**a**		**b**	**a**		**b**		**IDL**	**ENVI**
	165	-2.118		0.05448	-55.25		0.1607		6.8712	6.8712
		Si DN > 500.3			**Si DN ≤ 500.3**					
2		**a**		**b**	**a**		**b**			
	133	-2.474		0.06379	-65.6		0.19		6.01007	6.01007
	C_E	**a_0**	**a_1**	**a_2**	**N_E**	**v_c**	**A**	**B**	**T_E**	
									IDL	**ENVI**
3b	700	2.815	-0.00284	0.00	0.827	2670	-1.678	1.002643	307.655	304.331
4	380	187.349	-0.207	1.98×10^{-5}	111.382	928.9	-0.540	1.0001468	299.589	298.515
5	405	211.865	-0.225	1.16×10^{-5}	122.475	831.9	-0.361	1.001088	296.098	295.434

4.3 Corrección atmosférica

Se estimó la reflectancia en la superficie de la Tierra de los canales 1 y 2 de AVHRR a través del modelo de QUAC empleado de ENVI. Al comparar con las imágenes de la reflectancia TOA (Top Of Atmosphere), se observó que, después de la corrección atmosférica, el rango y el promedio de la reflectancia fueron menores (valor promedio de 0.1163 para canal 1 y de 0.1424 para canal 2, y la desviación estándar fue menor que la de TOA (Tabla 4.2). La mayoría de los datos de la reflectancia superficial se distribuyen entre 0 a 0.4 (Fig. 4.4a), ya que la mayor parte de la imagen es de océano (Fig. 4.1b) y tiene valor bajo de la reflectancia (< 0.1), en cambio, para la reflectancia TOA, existe una cantidad considerable de pixeles con valores superiores a 1 (Fig. 4.4b), este error ya se corrigió con esta corrección.

Tabla 4.2. Valor máximo, mínimo, promedio y desviación estándar de la reflectancia superficial y TOA de cada canal.

Canal	Mínimo	Máximo	Promedio	Desviación estándar
Reflectancia 1	0.0001	1.3810	0.1163	0.1202
Reflectancia 2	0.0000	2.0556	0.1424	0.1579
TOA 1	0.0606	6.6342	0.6152	0.5719
TOA 2	0.0493	7.9530	0.5972	0.6072

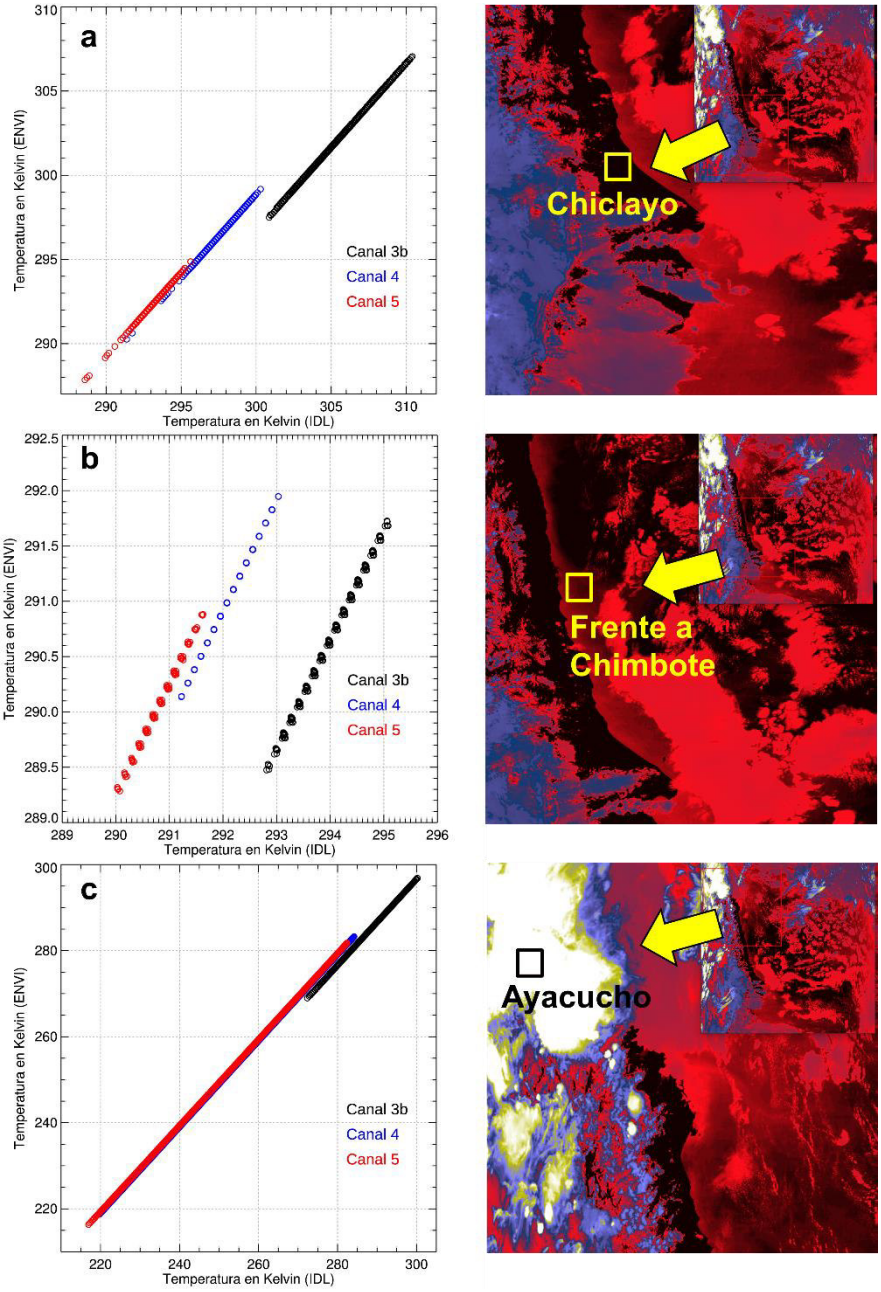

Figura 4.3. Diagrama de dispersión de la temperatura estimada por IDL y ENVI.

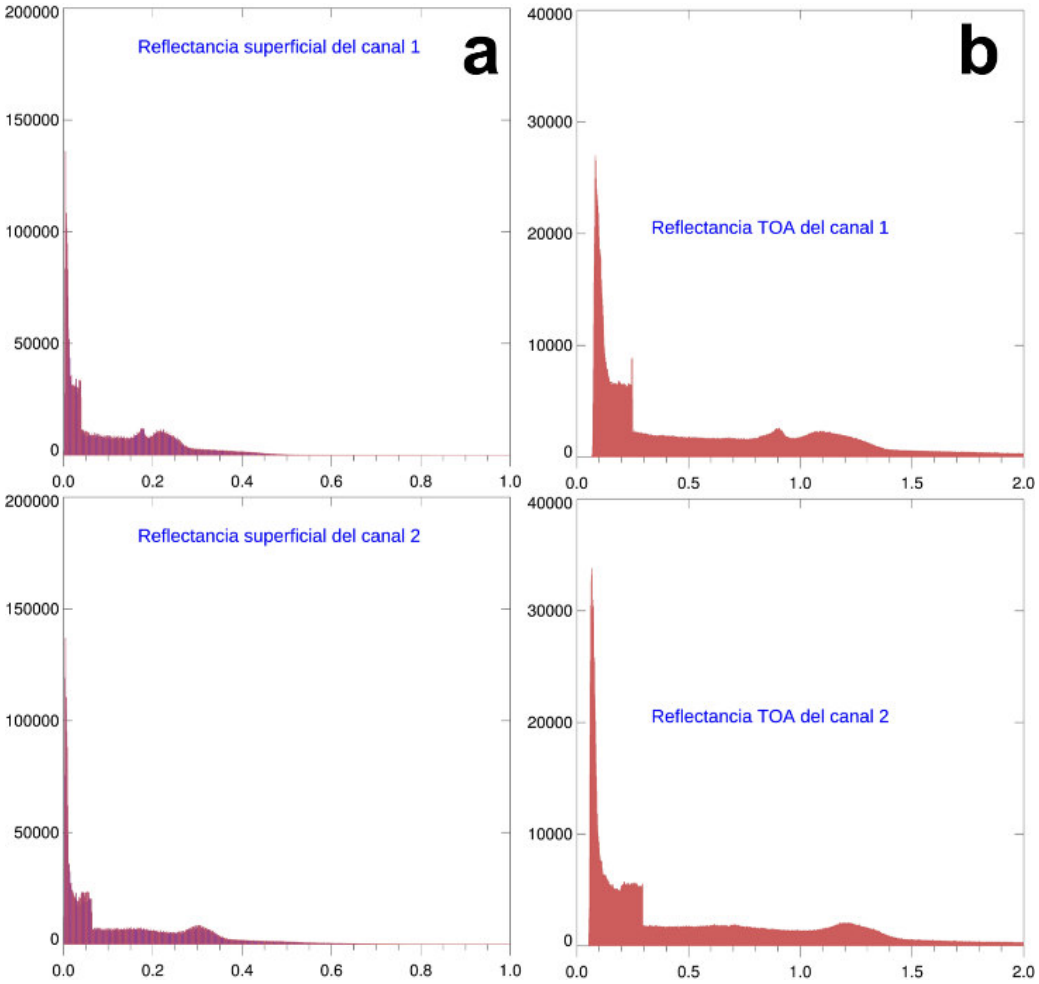

Figura 4.4. Comparación del histograma entre (a) la reflectancia en la superficie y (b) en TOA.

4.4 Corrección geométrica

La corrección geométrica se aplica a los cinco canales corregidos radiométricamente (canales 1 y 2 corresponden a la reflectancia superficial, canales 3 a 5 corresponden a la temperatura) usando los datos de geolocalización que están almacenados el cabecero del archivo LAC. Para cada fila de la imagen (2048 pixeles), hay un total de 51 de puntos de latitud y de longitud, el primer punto que tiene coordenadas corresponde al pixel 25, el intervalo de pixeles de geolocalización es de 40 puntos, es decir, el punto 65, 105 son los pixeles que tienen sus coordenadas, y así sucesivamente. Los 51 puntos se interpolan a dimensión de la fila para obtener la matriz de geolocalización con la cual se realiza la corrección geométrica. Las imágenes georreferenciadas tienen un error menor a 1 pixel, como se puede observar en la Figura 4.5b, los bordes del vector del Perú calza con la línea de costa. Sin embargo, las imágenes de AVHRR no tienen una dimensión fija como los datos de MODIS ó cuasi fija como las

imágenes Landsat y Sentinel; además, las imágenes a menudo solo contienen una pequeña porción del área de estudio (Fig. 4.5a), se debe redimensionar las imágenes a una dimensión estándar.

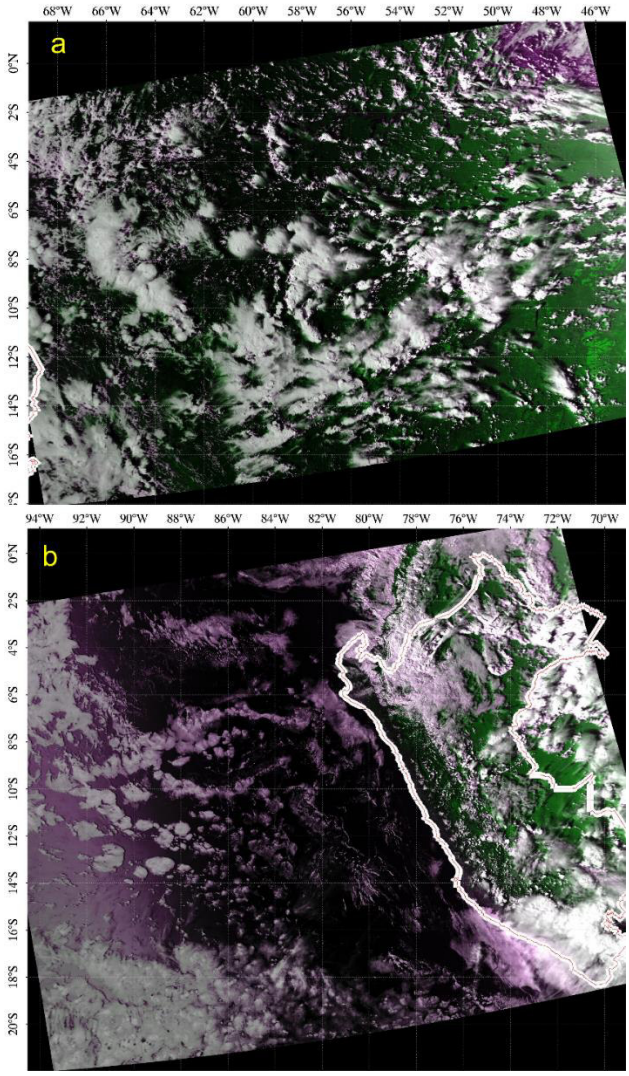

Figura 4.5. Imágenes georreferenciadas de las horas (a) 15:28 y (b) 16:58 horas.

4.5 Redimensionado

Se estandarizó el área con latitudes entre 0.5°N y 19°S, longitudes entre 82°W y 68°W como muestra en el cuadro amarillo de la Figura 4.6a, en la cual, se observa que, el área de la imagen de ejemplo debe realizarse cortes de imagen por norte, sur y oeste, luego completar área por el lado este. Se ha desarrollado un algoritmo que compara cada imagen con el área estandarizada, y detecta la imagen si falta o sobra áreas, el orden de la detección es de norte, sur, oeste, finalmente, este (ANEXO IV), donde, la detección de pixeles norte y sur mediante la

comparación de número de filas con la imagen estándar, y en oeste y este, la comparación es por número de columnas (Fig. 4.6b).

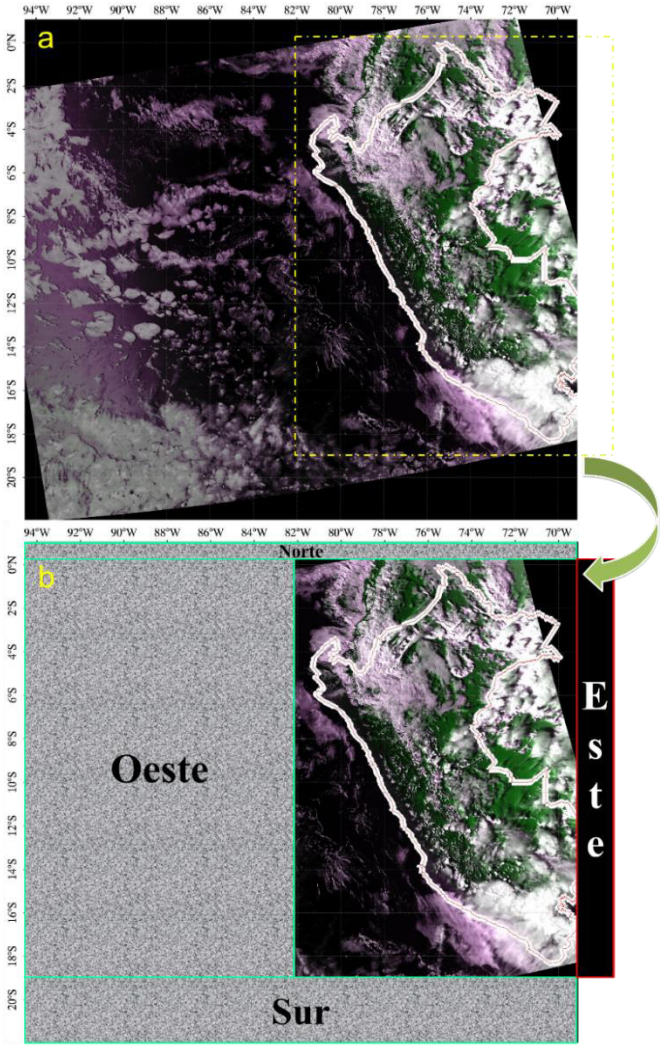

Figura 4.6. (a) Área del estudio en imagen georreferenciada; (b) redimensionado de la imagen eliminando áreas en norte, sur y oeste, y completando a la zona este con un matriz vacío.

4.6 Detección de nubes

Los umbrales de las principales pruebas del algoritmo CLAVR para nubes en tierra han sido modificados (Tabla 4.3). Se aplicó el CLAVR usando el canal 1 como imagen base (Fig. 4.7a), en la cual, se asignan valor de cero a los pixeles que son identificados como nubes (Fig. 4.7b).

Tabla 4.3 Umbrales modificados.

Prueba	Canal	Umbral
RGCT	1	>19%
RUT	1	>15%
TUT	4	>9 K

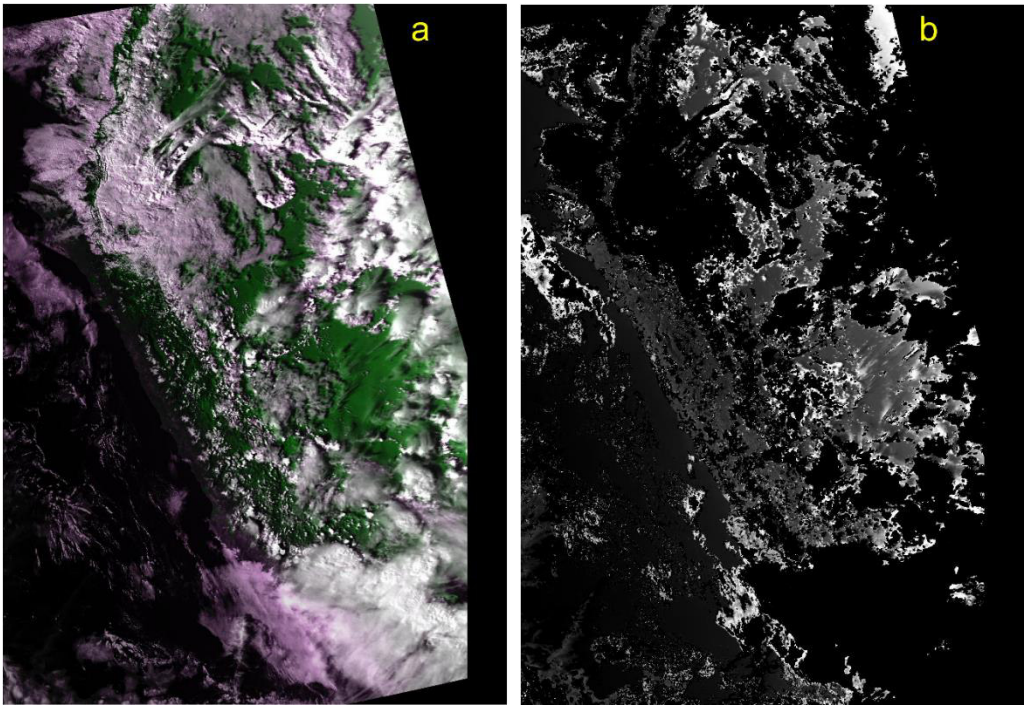

Figura 4.7. (a) Imagen de ejemplo y de (b) canal 1 donde los pixeles de nubes son ceros.

4.7 Estimación del NDVI/AVHRR mensual y su anomalía

Se estimó el NDVI filtrado de nubes para las imágenes diarias, y luego se calculó el NDVI mensual aplicando el método de CVM (Compuesto de Valores Máximos). Los resultados se muestran en el siguiente capítulo. Para el cálculo de la anomalía mensual se usó una climatología de ocho años (1992-1999).

4.8 Análisis comparativo del NDVI

Se realiza un análisis comparativo del NDVI estimado por AVHRR ($NDVI_{AVHRR}$) y el producto del MODIS ($NDVI_{MODIS}$) mediante los parámetros del RMSE (Root Mean Squared Error), el MAE (Mean Absolute Error) y BIAS (sesgo), las expresiones se muestran en la ec. (4.1):

$$\begin{aligned} RMSE &= \sqrt{\frac{\sum\left[NDVI_{AVHRR} - NDVI_{MODIS}\right]^2}{n}} \cdot 100 \\ MAE &= \frac{\sum\left|NDVI_{AVHRR} - NDVI_{MODIS}\right|}{n} \cdot 100. \\ BIAS &= \frac{\sum\left[NDVI_{AVHRR} - NDVI_{MODIS}\right]}{n} \cdot 100. \end{aligned} \tag{4.1}$$

Capítulo 5

Resultados

Se obtuvieron un total de 448 imágenes del NDVI promedio mensual para el periodo de enero del 1982 a abril del 2019. La descripción de los resultados empieza con la serie de tiempo del NDVI promedio mensual por regiones (costa, sierra y selva) y la prueba tendencia de Mann-Kendall que corresponde a cada serie. Luego se calculará una climatología mensual del NDVI de AVHRR, con la cual se generará la anomalía mensual del NDVI. A partir de ambos datos, se calcularán los promedios anual y estacional que permiten monitorear la distribución dinámica del NDVI para el periodo de estudio. Se analizarán la desviación estándar y los diagramas de Hovmoller para detectar las regiones de mayor cambio de cobertura vegetal. Se generará el VCI mensual con las reflectancias estimadas, con los mapas de tendencia de los índices para encontrar posibles zonas desertificadas y analizarlas.

5.1 Serie del NDVI/AVHRR por mes

Se calculó el promedio del NDVI/AVHRR mensual del Perú y de las regiones de costa, sierra y selva, las series del promedio mensual muestran un patrón similar con una tendencia decadal ligeramente positiva (Fig. 5.1). Para todo el litoral (Fig. 5.1a), se observa que, el incremento del NDVI fue de manera progresiva durante tres periodos: del 1986 al 1994, del 1995 al 2001, y del 2002 al 2018, en la cual, para el periodo de 2002 a 2018, cuya serie se muestra una periodicidad más notable que en los periodos 1986-1994 y 1995-2001, el mismo comportamiento también se ilustran en la región de selva (Fig. 5.1d), la cual representa un mayor rango de variación (de 0.2 a 0.8) del NDVI y un mayor incremento con valor de +0.14

por década (dec^{-1}) como se muestra en la Tabla 5.1. El menor incremento (+0.05 dec^{-1}) fue registrado en la región de costa (Fig. 5.1b), y en sierra se muestra claramente la variabilidad periódica para toda la serie (Fig. 5.1c). Se obtuvo un error de a ±0.01 y un p-valor de 0.00 para las series consolidando los resultados de la tendencia.

Tabla 5.1. Tendencia, error y p-valor del NDVI y su anomalía por zonas.

Parámetro	Zonas	Tendencia	Error	p-valor (sig.)
NDVI (dec^{-1})	Perú	+0.11	±0.01	0.00
	Costa	+0.05	±0.00	0.00
	Sierra	+0.09	±0.01	0.00
	Selva	+0.14	±0.01	0.00

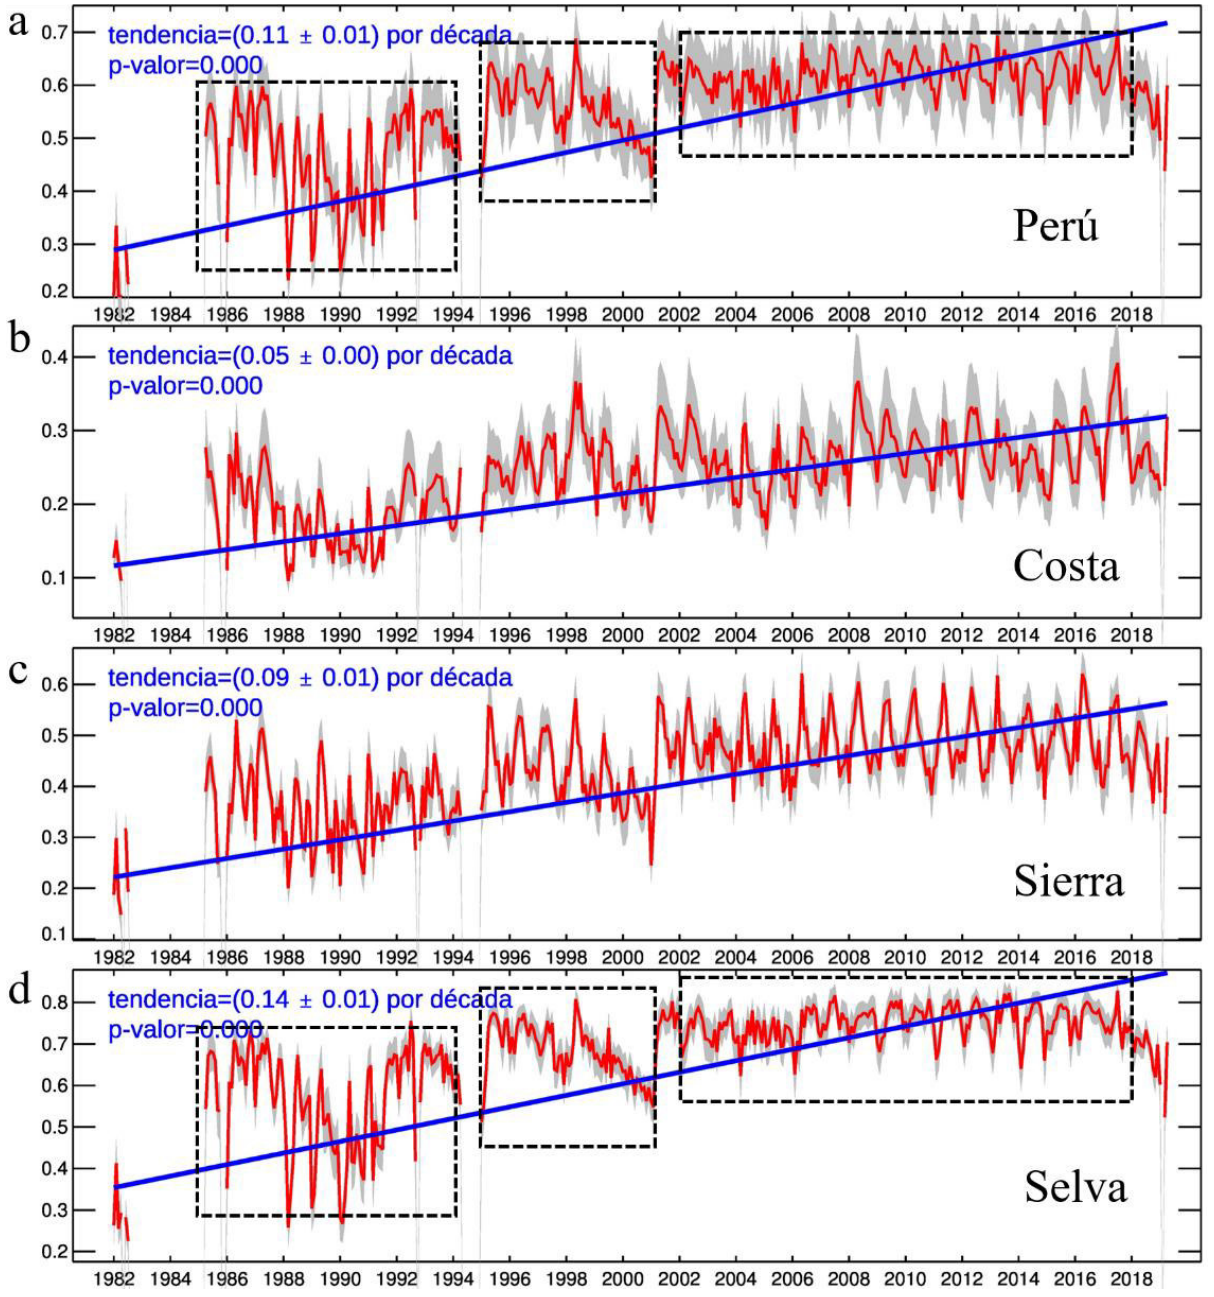

Figura 5.1. Serie de tiempo del NDVI/AVHRR mensual para todo el periodo de estudio.

5.2 NDVI/AVHRR promedio anual

Los promedios del NDVI por año fueron obtenidos a partir de los datos mensuales. La Figura 5.2 muestra la distribución anual del 1982 al 2019, en las cuales, no se disponen los datos de los años 1983 y 1984, y se puede apreciar que, la intensidad del NDVI fue menor en el periodo 1982 al 1994 que en resto años básicamente debido a que los datos de dicho periodo son de menor cantidad y existe mayor cantidad de imágenes malas. Por otro lado, la distribución anual evidenció las tres regiones geográficas del Perú (Fig. 5.2): la costa (NDVI < 0.2), la sierra (0.2< NDVI <0.5) y la selva (NDVI>0.5). Para el año 2019, se usó imágenes de los meses de enero a marzo.



Figura 5.2. Promedio del NDVI/AVHRR por año.

5.3 NDVI/AVHRR promedio estacional

Se calcularon los promedios del NDVI por estación usando los datos mensuales para todo el periodo de estudio (Fig. 5.3), en la cual, se puede observar una ligera diferencia de la intensidad del NDVI entre las estaciones. La Tabla 5.2 muestra valores minino, máximo, promedio y desviación estándar del NDVI.

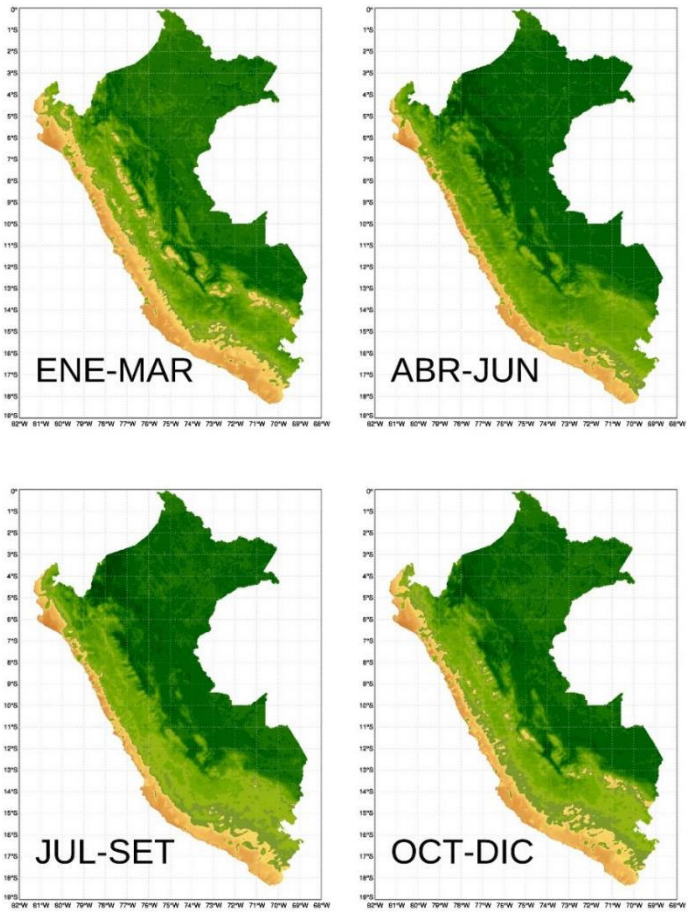

Figura 5.3. Promedio del NDVI/AVHRR estacional.

5.4 Climatología mensual del NDVI/AHVRR

La distribución mensual del NDVI muestra el cambio de cobertura vegetal para todo el territorio peruano, en la cual, la mayor intensidad del NDVI está entre los meses de abril-setiembre y menor entre octubre-marzo (Fig. 5.4)

5.5 Promedio de la anomalía del NDVI/AVHRR mensual

El promedio de la anomalía del NDVI por mes fue calculado usando los datos de la climatología mensual del NDVI del 1992 al 1999 (Fig. 5.5). En la cual, se observa la distribución de las anomalías negativas en la región de la costa y positivas en la región de la selva durante mayoría de los meses.

Tabla 5.2. Valores máximo, mínimo, promedio y desviación del NDVI.

Estación	Región	Mínimo	Máximo	Promedio	Desviación estándar
Verano (Enero-Marzo)	Perú	0.094	0.835	0.561	0.195
	Costa	0.095	0.608	0.233	0.089
	Sierra	0.143	0.798	0.410	0.091
	Selva	0.211	0.835	0.700	0.084
Primavera (Abril-Junio)	Perú	0.088	0.831	0.575	0.185
	Costa	0.088	0.724	0.260	0.117
	Sierra	0.144	0.788	0.430	0.087
	Selva	0.244	0.831	0.708	0.064
Otoño (Julio-Setiembre)	Perú	0.086	0.841	0.599	0.171
	Costa	0.091	0.716	0.279	0.137
	Sierra	0.141	0.806	0.505	0.097
	Selva	0.216	0.841	0.709	0.069
Invierno (Octubre-Diciembre)	Perú	0.102	0.823	0.533	0.182
	Costa	0.105	0.594	0.223	0.090
	Sierra	0.137	0.781	0.422	0.121
	Selva	0.186	0.823	0.649	0.094

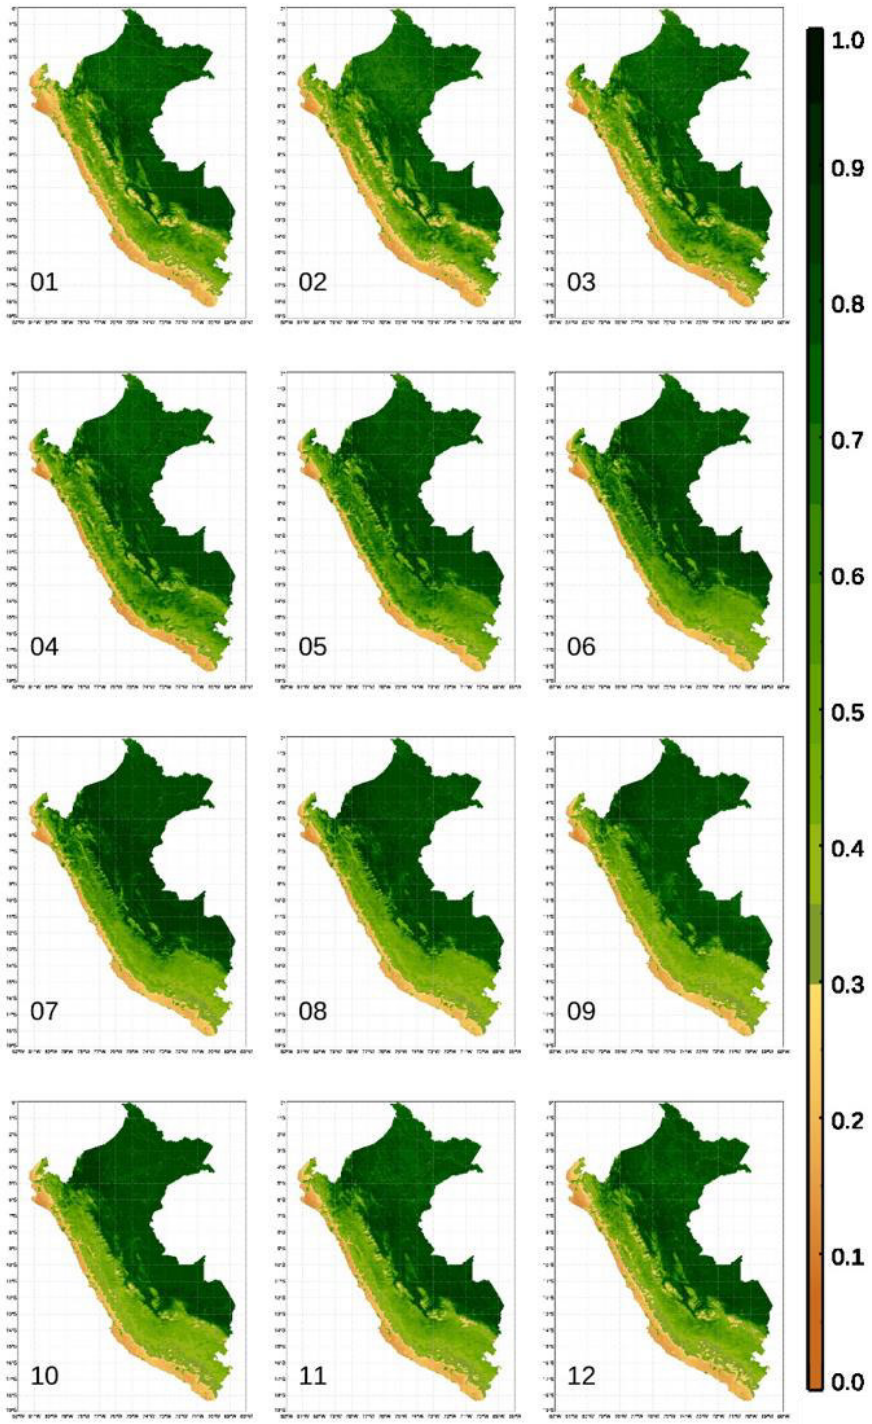

Figura 5.4. Climatología mensual del NDVI/AVHRR (1992-1999).

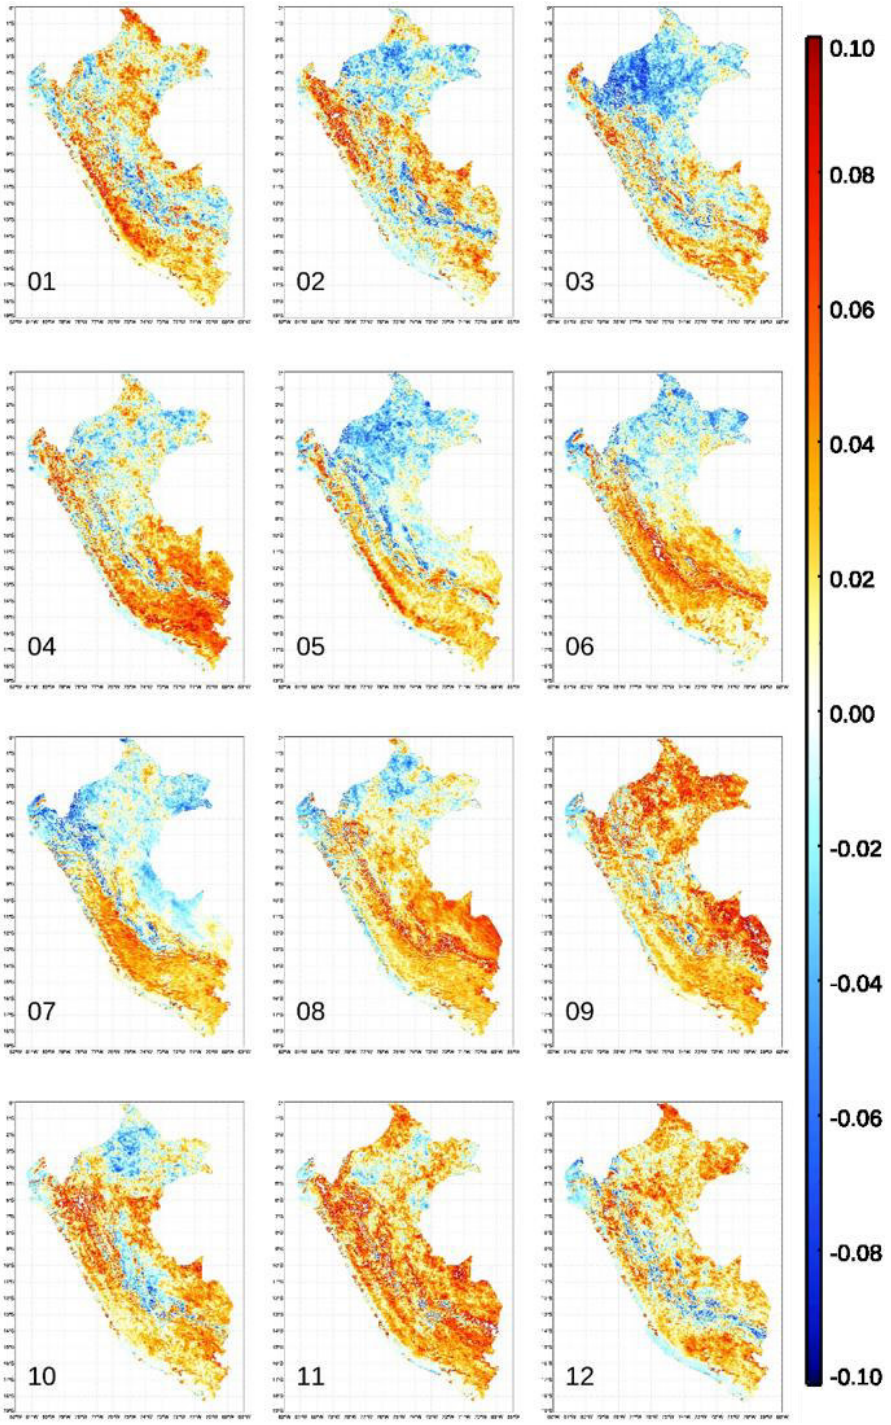

Figura 5.5. Promedio de la anomalía del NDVI/AVHRR mensual.

5.6 Promedio de la anomalía del NDVI/AVHRR anual

En general, la anomalía del NDVI promedio por año tiene valor negativo del periodo 1982 al 1994, y en los años posteriores se muestran anomalías positivas, a excepción de los años 1999-2000, 2018-2019, además, se presentó una anomalía negativa en la costa norte del Perú para mayoría de los años (Fig. 5.6).

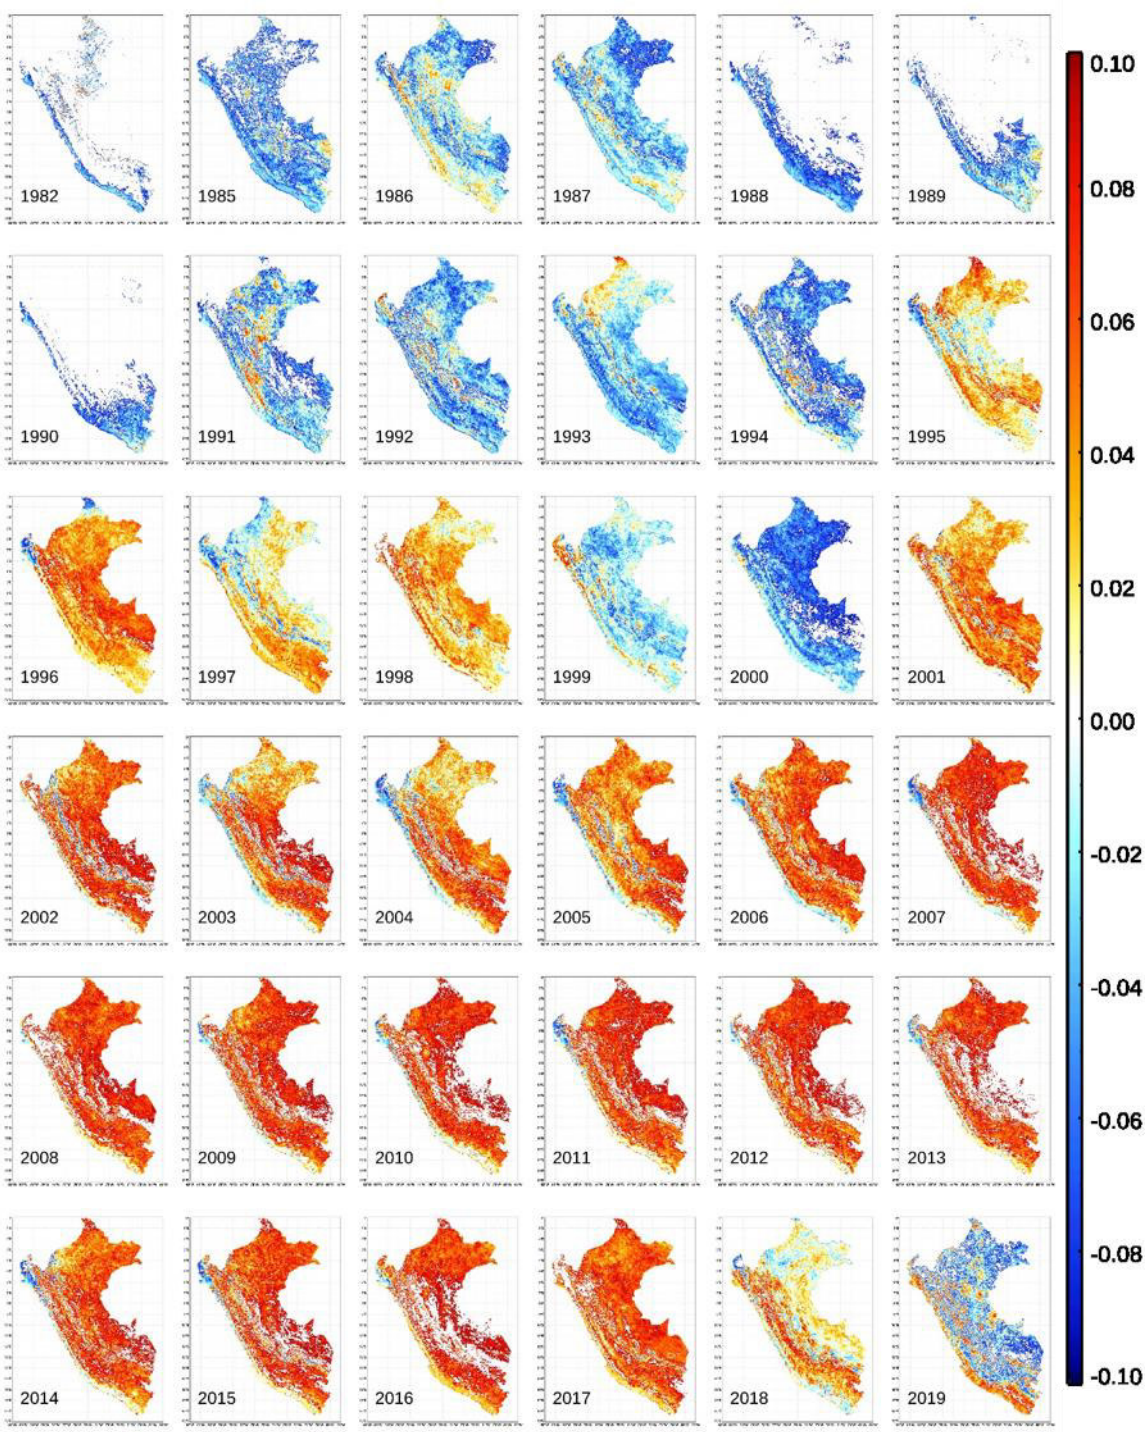

Figura 5.6. Promedio de la anomalía del NDVI/AVHRR anual.

5.7 Promedio de la anomalía del NDVI/AVHRR estacional

La anomalía del NDVI estacional tiene valor negativo en mayor parte de la región costera, durante las estaciones de verano (enero a marzo) y otoño (abril a junio) se presentó anomalías negativas en la región de Loreto y de la selva alta (Fig. 5.7).

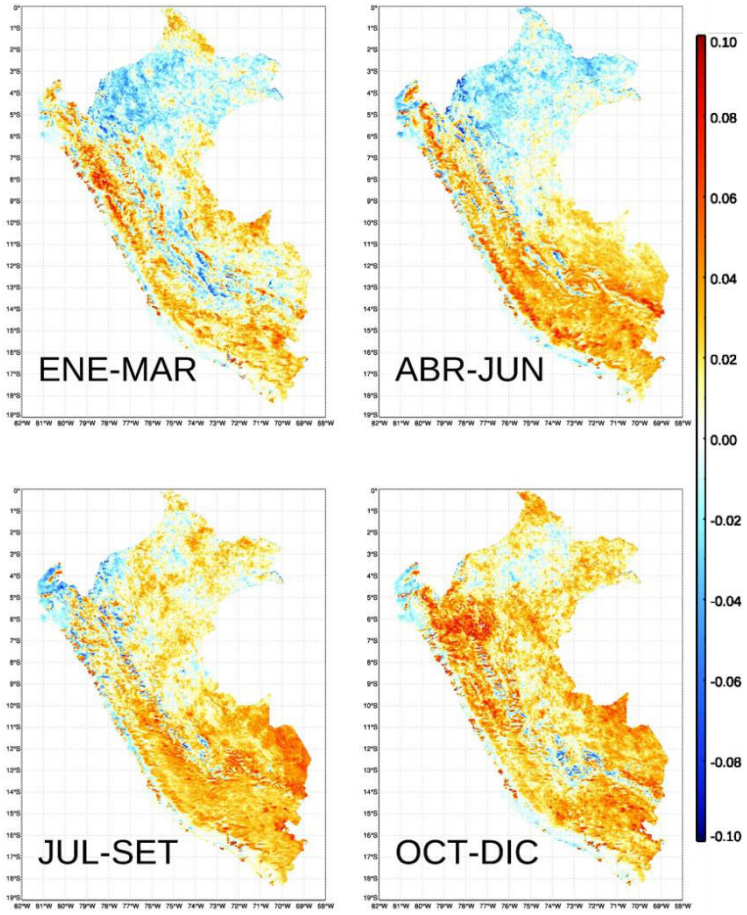

Figura 5.7. Promedio de la anomalía del NDVI/AVHRR mensual.

5.8 Promedio del NDVI/AVHRR (1986-2018)

La Figura 5.8a muestra el NDVI promedio para el periodo 1986-2018, en la cual, se evidenció las tres regiones (vector rojo): en la región costera, los valores del NDVI son bajos (NDVI<0.3), en la sierra, el rango está entre 0.3 a 0.5 y en la selva, los valores son más altos (NDVI>0.5). La Figura 5.8b muestra la desviación estándar del NDVI estimada para el mismo periodo, y Figura 5.8c, mapa de ecorregiones, elaborado por Brack (Brack, 1986), al comparar las figuras 5.8b y 5.8c, las altas desviaciones han sido registradas en selva alta, páramo, bosque tropical pacífico, norte y centro de las regiones de puna y serranía esteparia, este de la costa norte del Perú, límite entre bosque seco y selva alta. Asimismo, se observó un menor valor de la desviación en la región costera con respecto a la sierra y la selva que coincide con resultado de Rojas (Rojas et al., 2009).

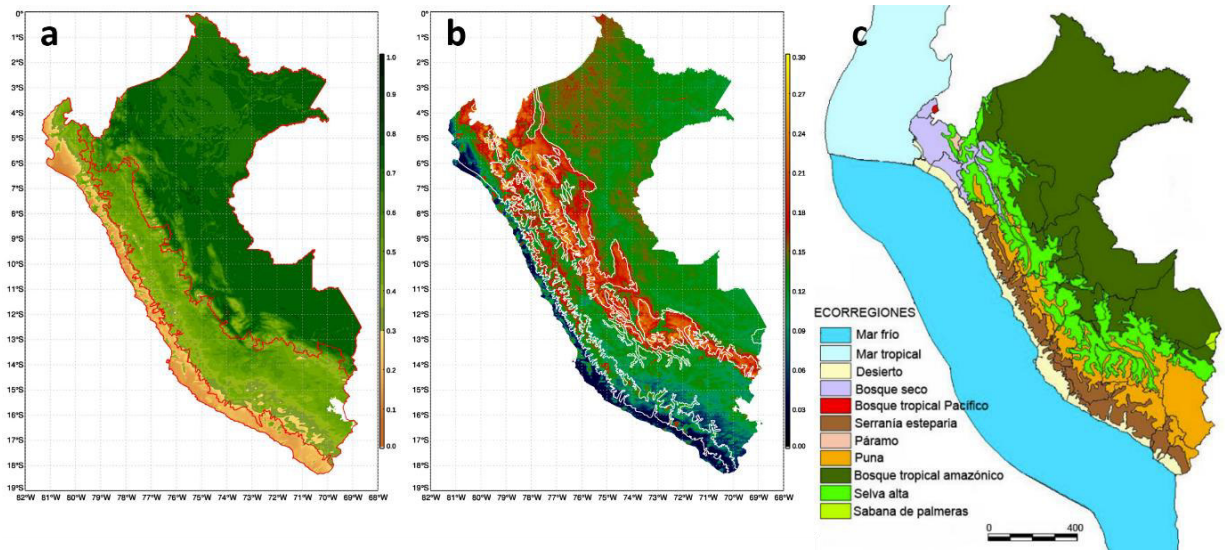

Figura 5.8. (a) NDVI promedio, (b) desviación estándar del NDVI/AVHRR para el periodo 1986-2018, (c) ecorregiones propuestas por Brack (MINAM, 2010).
(Fuente de vectores de regiones naturales y ecorregiones: https://www.geogpsperu.com)

5.9 Hovmoller del NDVI/AVHRR

El Hovmoller del NDVI es elaborado a partir de los promedios mensuales del NDVI, en la cual, se evidenció un incremento progresivo de la intensidad del NDVI desde la costa hacia la selva (Fig. 5.9). En la costa, se registró presencia de NDVI de 0.3 principalmente en dos regiones: entre las latitudes de 3°S a 5°S, la alta intensidad de vegetación se distribuyen en el Parque Nacional Cerros de Amotape y la Reserva Nacional de Tumbes; de 7°S a 9°S por las zonas agrícolas de las provincias costeras (Fig. 5.9a). En la sierra, la distribución del NDVI es más homogénea con valores no mayor a 0.6 (Fig. 5.9b). En la selva se presentó NDVI de mayor intensidad (0.8) que se distribuyen entre 0 a 15°S (Fig. 5.9c).

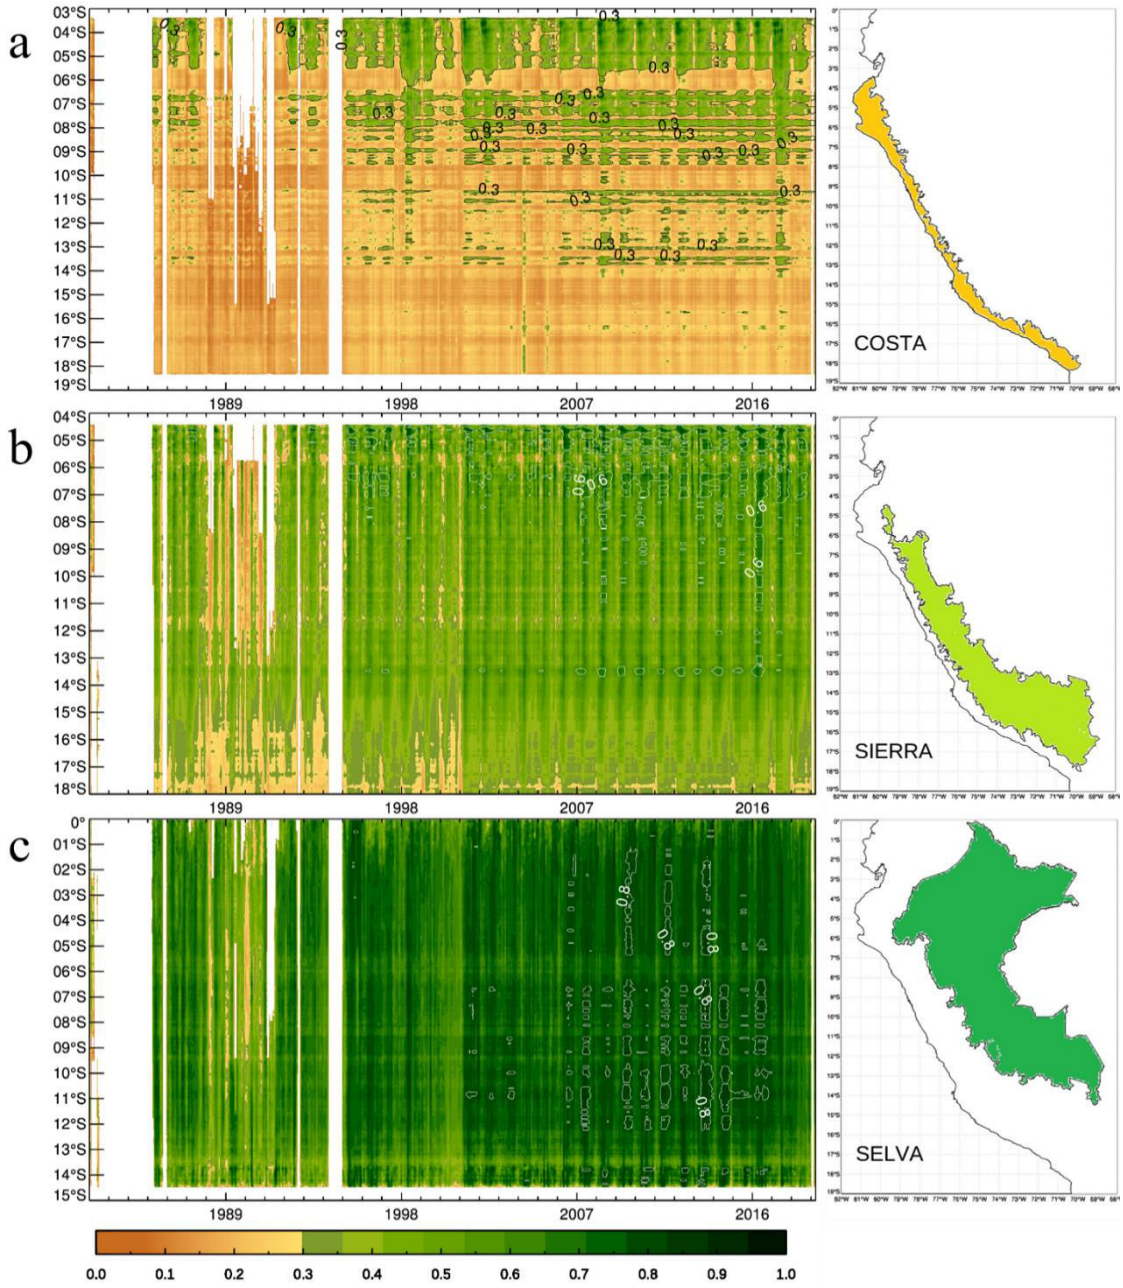

Figura 5.9. Diagrama de Hovmoller del NDVI/AVHRR mensual en las regiones de la (a) costa, (b) sierra, (c) selva para el periodo de estudio.

5.10 Hovmoller de la anomalía del NDVI/AVHRR

El Hovmoller de la anomalía del NDVI registró valores negativos para el periodo del 1982 al 1994 en las tres regiones, y a partir del 2015, se observa la anomalía positiva en mayor parte del Perú (Fig. 5.10). En la región costera, la anomalía positiva (+0.1) se localiza en la región Norte, de 3°S a 7°S (Fig. 5.10b), en la sierra, los mayores valores de la anomalía (+0.2) se registraron en latitud 14°S aproximadamente (Fig. 5.10b), en la selva, la distribución es más homogénea (Fig. 5.10c).

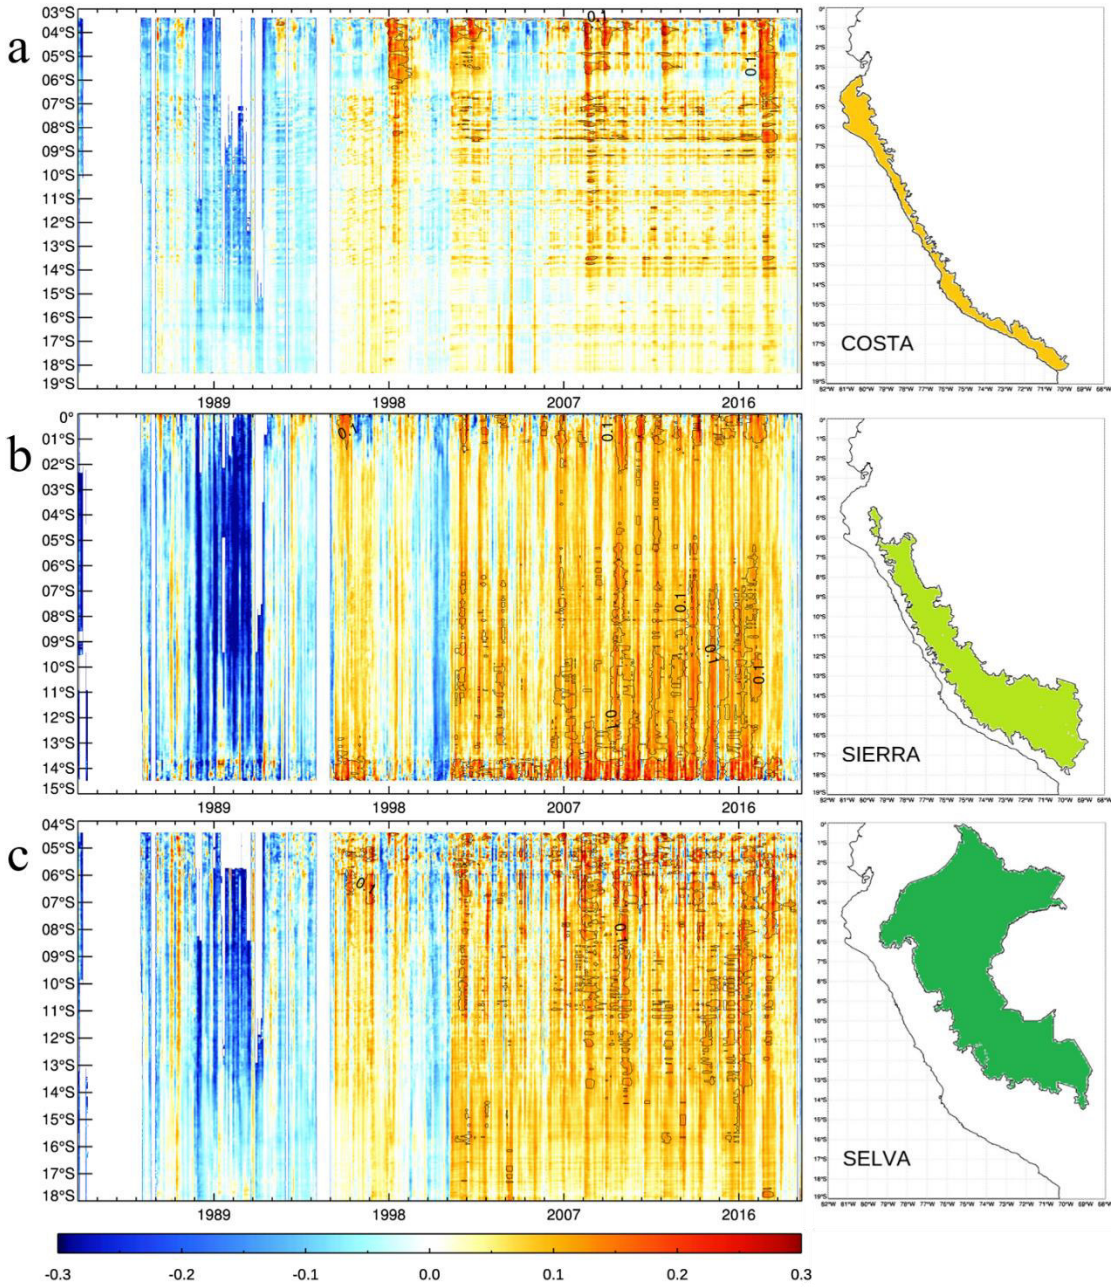

Figura 5.10. Diagrama de Hovmoller de la anomalía del NDVI/AVHRR mensual en las regiones de la (a) costa, (b) sierra, (c) selva.

5.11 Serie de tendencia del VCI/AVHRR por departamentos

En las series de tendencia del VCI de los 24 departamentos del Perú se observan tendencias positivas durante del 1986 al 2018 (Fig. 5.11), donde, en Piura se registró un menor crecimiento de +0.07 dec^{-1} mientras que en Huancavelica, se obtuvo el mayor (+0.12 dec^{-1}).

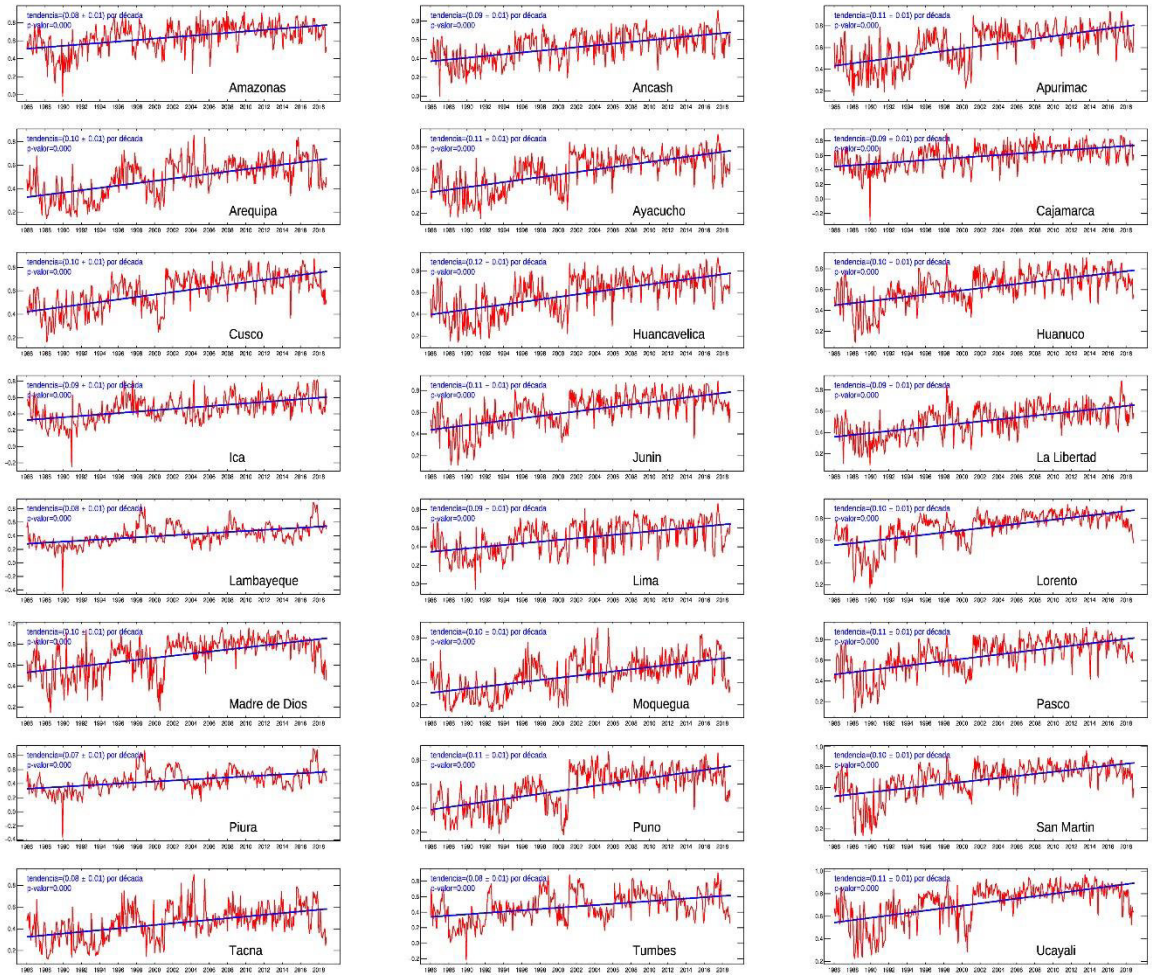

Figura 5.11. Serie de tendencias del VCI de las regiones del Perú.

5.12 Mapa de tendencia del NDVI/AVHRR

Se elaboró el mapa de tendencia del NDVI con el fin de encontrar las posibles regiones de desertificación (Fig. 5.12). En la cual, las zonas de color blanco son aquellos pixeles que no presentan una tendencia significativa estadísticamente a través de la prueba de Mann-Kendall. Se observa que en mayor parte del territorio se registraron tendencias ligeramente positivas (+0.05 dec^{-1}), la zona de mayor tendencia (+0.1 dec^{-1}) se localiza en la selva alta y puna, las tendencias negativas fueron registrados en las zonas costeras y alguna zonas de la selva como se presentó en color verde.

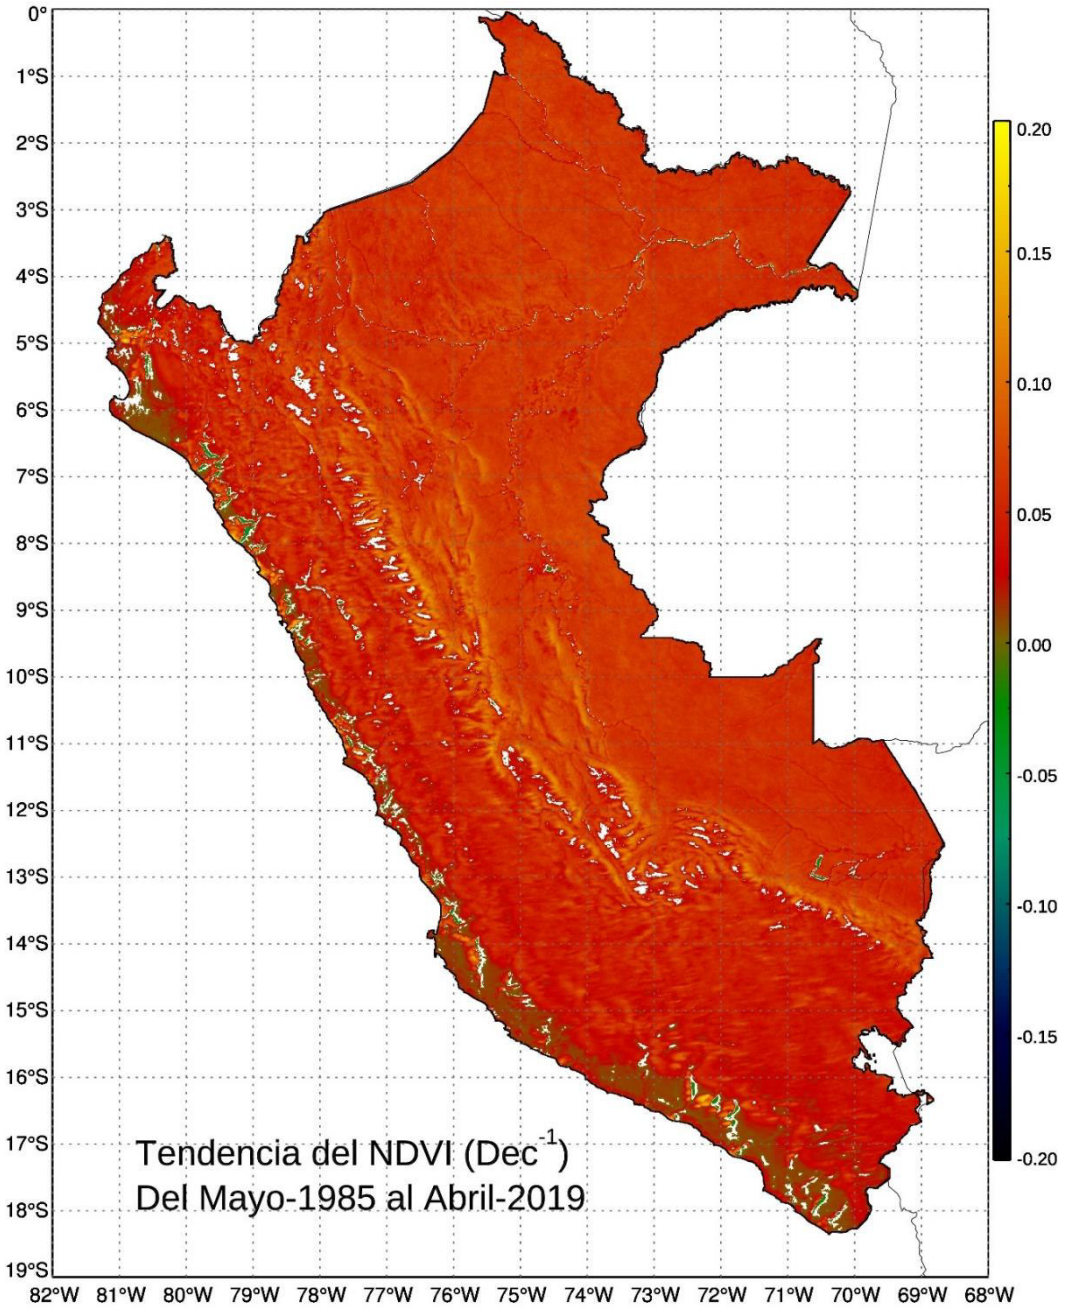

Figura 5.12. Mapa de tendencia del NDVI (dec^{-1}).

5.13 Mapa de tendencia del VCI/AVHRR

De manera similar, se elaboró mapa de tendencia del VCI, en la cual se evidenció las mismas regiones de tendencias negativas registradas por mapa de tendencia del NDVI (Fig. 5.12), en este trabajo se destacan siete posibles zonas de desertificación: a), sur de ciudad de Piura, b) sur y este de Chiclayo, c) Chicama, d) Pisco, e) distrito Majes de Arequipa, f) ciudad de Pucallpa, g) distrito Huepetuhe de Madre de dios (Fig. 5.13).

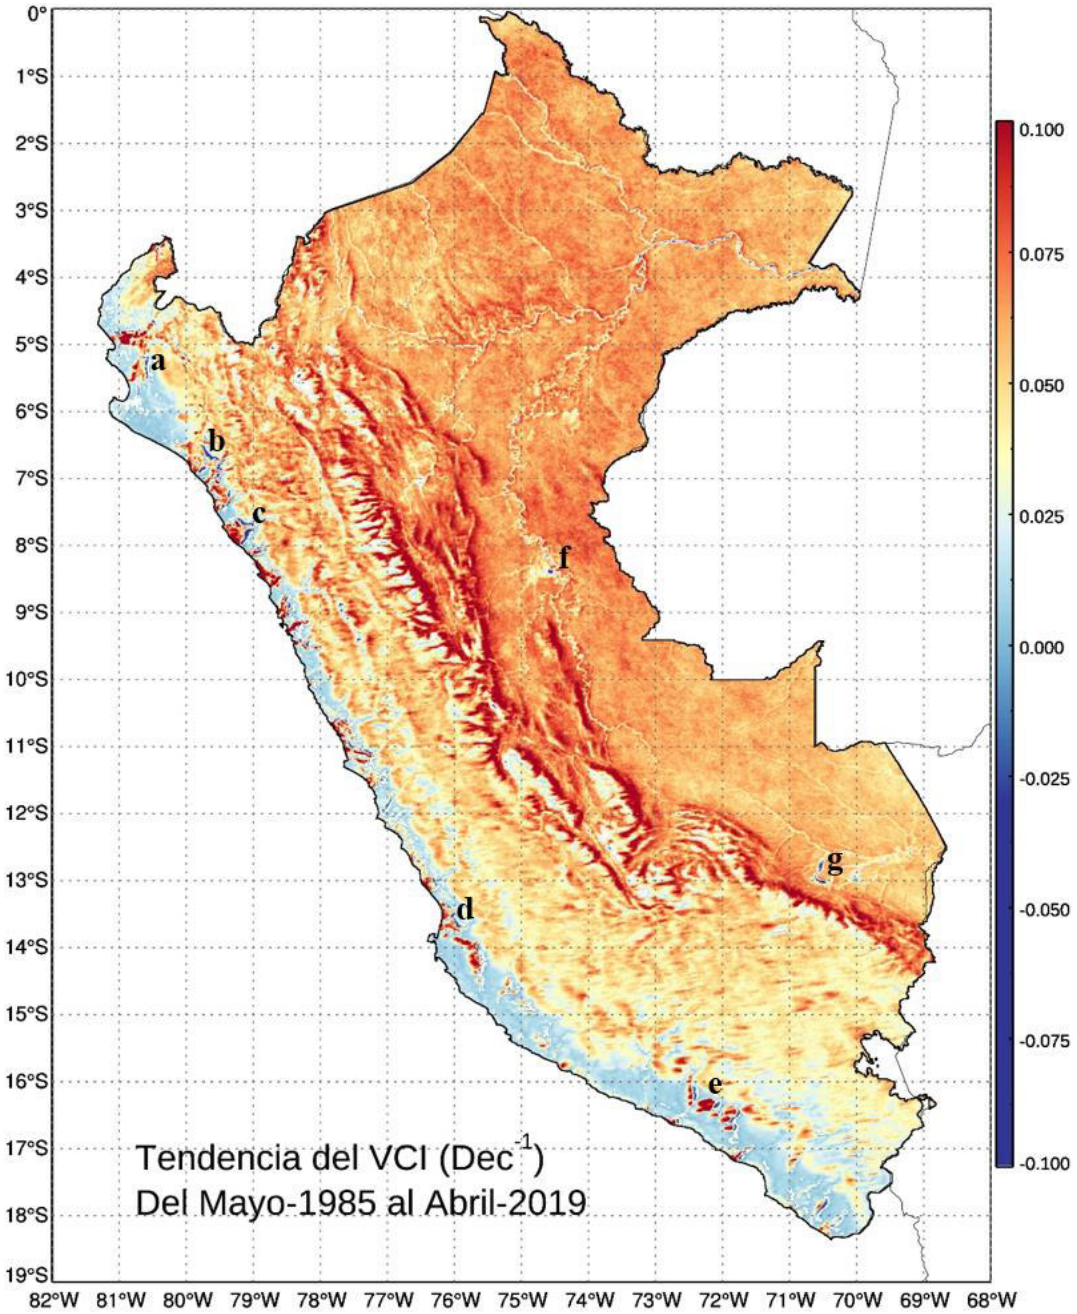

Figura 5.13. Mapa de tendencia del VCI (Dec^{-1}).

5.14 Serie de tendencia del NDVI/AVHRR

Las series de tendencia del NDVI mensual de las posibles zonas desertificadas para el periodo de enero del 1986 al abril del 2019 muestran una tendencia positiva (+0.01 dec^{-1}) en la zona de sur de la ciudad de Piura con un p-valor de 0.314 (Fig. 5.14a), en además zonas, se registraron tendencias ligeramente negativas (de -0.02 a -0.01 dec^{-1}) con p-valor de 0.0 (Fig. 5.14b – 5.14f).

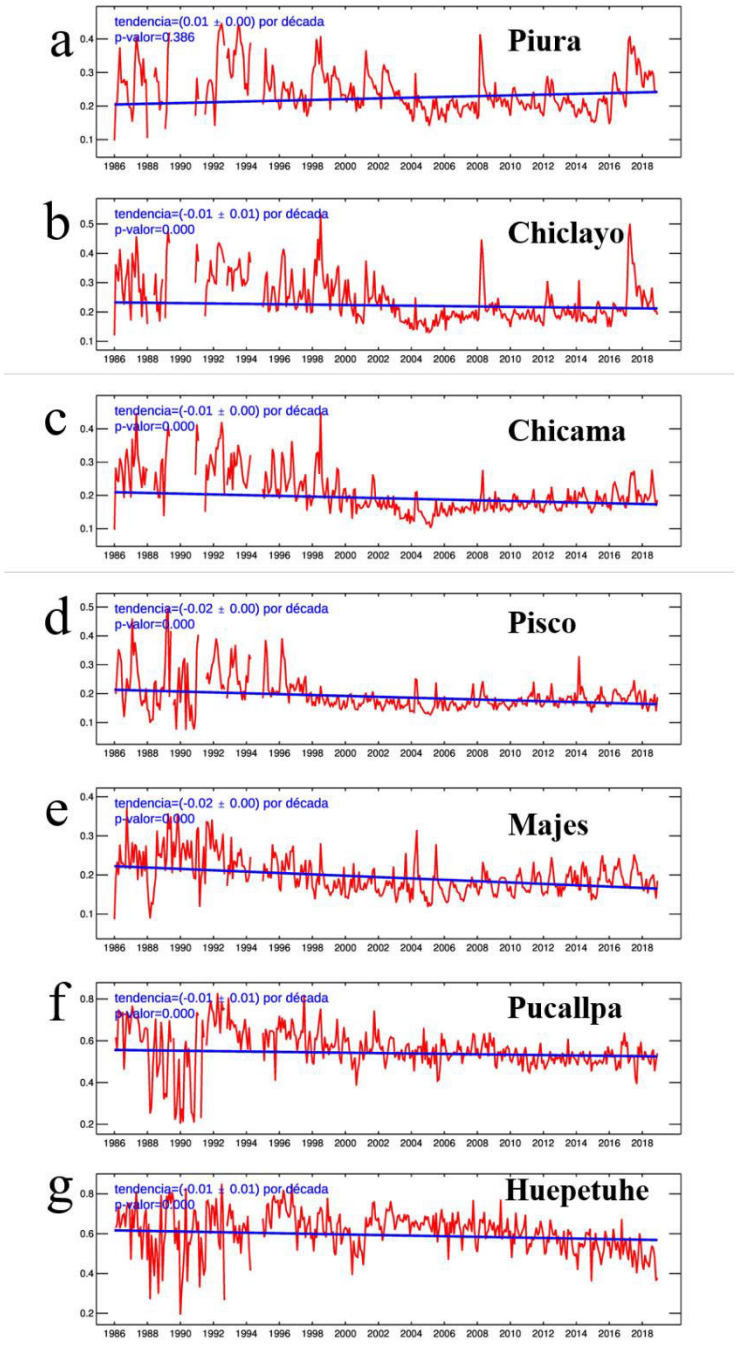

Figura 5.14. Serie de tendencia del NDVI de las posibles zonas desertificadas para el periodo del enero 1986 al abril 2019.

5.15 Serie de tendencia del VCI/AVHRR

En las series del VCI se puede apreciar mejor las tendencias negativas (de -0.11 a -0.06 dec^{-1}) en las zonas destacadas durante el periodo de 1986 al abril de 2019 con p-valor de 0.0 (Fig. 5.15). Donde las zonas de mayor tendencia negativa fueron de Chiclayo (-0.1 dec^{-1}) y Chicama (-0.11 dec^{-1}).

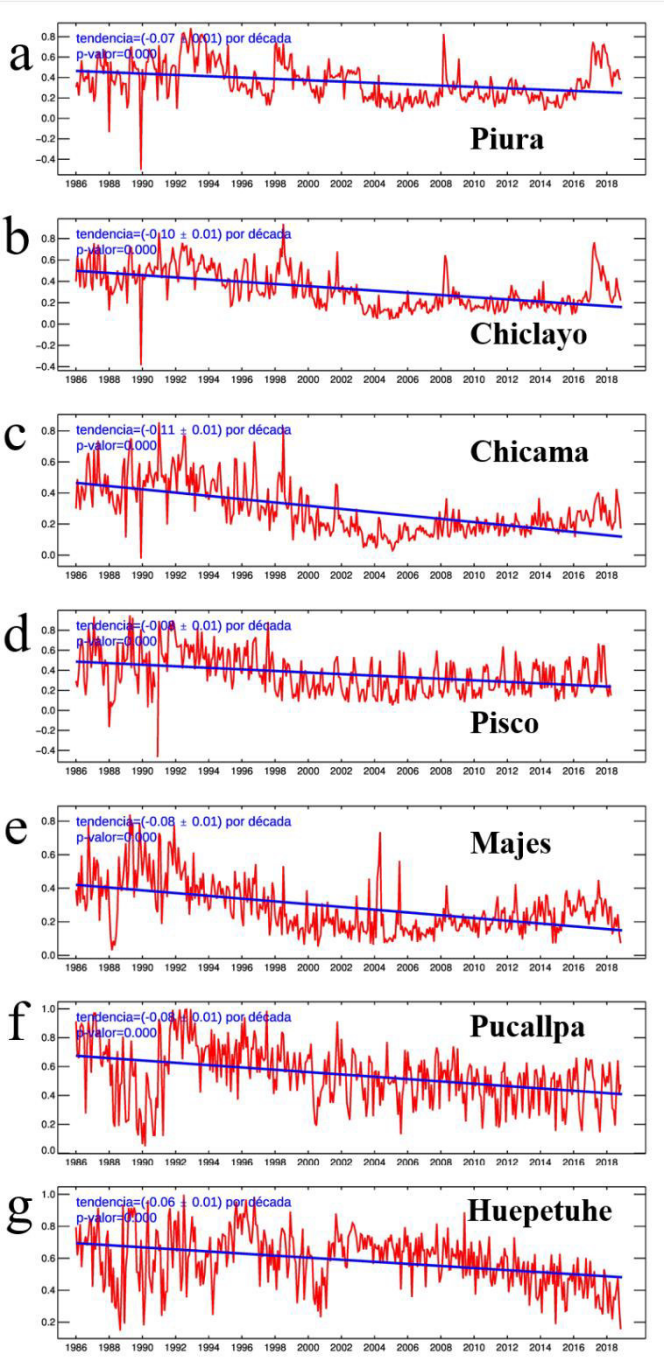

Figura 5.15. Serie de tendencia del VCI de las posibles zonas desertificadas para el periodo del enero 1986 al abril 2019.

La Tabla 5.3 describe el área, la tendencia, el error y el p-valor para las posibles zonas desertificadas. La tendencia del NDVI muestra un valor positivo en la zona de sur de ciudad de Piura, sin embargo, estadísticamente no fue significativa ($p = 0.386$), mientras que, la tendencia del VCI fue negativa para la misma zona. Por otro lado, en el distrito de Majes de Arequipa y Chicama se registraron mayores áreas con tendencias negativas de los índices de vegetación

alcanzando a 244 y 218 km^2 respectivamente, mientras que en la ciudad de Pucallpa, la zona de tendencia negativa fue mucho menor (26 km^2).

Tabla 5.3. Área, tendencia, error y p-valor de los índices de NDVI y VCI para las zonas identificadas como posibles zonas de desertificación.

Parámetro	**Zonas**	**Área (km^2)**	**Tendencia**	**Error**	**p-valor (sig.)**
NDVI ($déc^{-1}$)	Sur de ciudad de Piura	130	+0.01	±0.00	0.386
	Sur y este de Chiclayo	163	-0.01	±0.01	0.000
	Chicama	218	-0.01	±0.00	0.000
	Pisco	58	-0.02	±0.00	0.000
	Majes de Arequipa	244	-0.02	±0.00	0.000
	Ciudad de Pucallpa	26	-0.01	±0.01	0.000
	Huepetuhe de Madre de dios	98	-0.01	±0.01	0.000
VCI ($déc^{-1}$)	Sur de ciudad de Piura	130	-0.07	±0.01	0.000
	Sur y este de Chiclayo	163	-0.10	±0.01	0.000
	Chicama	218	-0.11	±0.01	0.000
	Pisco	58	-0.08	±0.01	0.000
	Majes de Arequipa	244	-0.08	±0.01	0.000
	Ciudad de Pucallpa	26	-0.08	±0.01	0.000
	Huepetuhe de Madre de dios	98	-0.06	±0.01	0.000

Capítulo 6

Discusiones

En este capítulo, se discutirán las observaciones encontradas en el desarrollo del trabajo de tesis, luego la comparación con los datos productos del NDVI de MODIS para evaluar la consistencia de los datos con el fin de encontrar el periodo más adecuado para la climatología mensual, también se correlacionarán los datos del NDVI con la precipitación y finalmente, clasifican las posibles zonas desertificadas por la agricultura intensiva y por expansión urbana.

6.1 Sobre la base de datos

De los datos adquiridos del portal de la NOAA, la información válida (buena) proviene básicamente de seis satélites: NOAA-09, -11, -14, -16, -18 y -19, cuya información fueron de mayor estabilidad y abarca un mayor periodo (> 3años), además, la cantidad de datos por mes es más homogénea. Restos satélites tienen escaso de información en el área de estudio debido a varios factores: abarcan la zona con menor frecuencia; tiempo de funcionamiento corto; alta cantidad de imágenes con fallas que generalmente son de fechas consecutivas.

6.2 Sobre el filtrado de nubes

La mayoría de la técnica de filtrado de nubes depende tanto del espacio como tiempo, el CLAVR es el algoritmo generalizado para todo el globo, y funciona mejor para el caso del Perú con respecto a otros métodos “locales”. Por otro lado, la modificación del algoritmo CLAVR es principalmente dirigida para los datos de la noche y del suelo debido a que la mayoría de los datos tienen el canal 3b.

6.3 Sobre el periodo para la climatología

Al comparar el ciclo anual del NDVI/MODIS (Fig. 6.1a) con los del NDVI/AVHRR de los periodos de 1992-1999 (Fig 6.1b), 1992-2018 (Fig 6.1c), 2000-2006 (Fig 6.1d), 2007-2018 (Fig 6.1e), se mostró un mayor similitud entre el NDVI/AVHRR del 1992-1999 y el del MODIS, en la cual, se observó una periodicidad notable que el NDVI es mayor en los meses de primavera y verano, menor en invierno y otoño. Otra razón de considerar este periodo para elaborar la climatología es que existe mayor cantidad de imágenes disponibles con respecto a restos periodos (Fig. 6.1).

6.4 Comparación con el producto del NDVI/MODIS

Se eligió la costa norte del Perú para realizar un análisis comparativo entre el NDVI/AHVRR y el NDVI/MODIS con mayor detalle. Dicha región tiene multi-ecorregiones y condiciones iniciales para la generación de desertificación según la definición de MINAM y clasificación por SENAMHI (Fig. 1.1), además, la desviación estándar es de alta variabilidad en dicha región (Fig. 5.8b).

Al comparar la distribución del NDVI entre ambos sensor, se observó que a pesar que poseen distinta resolución espacial, ambas climatología muestra un patrón de distribución similar: en la región costera, un suelo de aproximadamente 50% del área total de la costa norte presentó un NDVI de menor intensidad (< 0.3) indicando que es un suelo de muy poca vegetación, en restos áreas se registró NDVI de mayor intensidad entre 0.4 a 0.7 (Fig. 6.2).

La serie de tiempo del NDVI mensual de ambos sensores en la costa norte del Perú, en la cual se muestran una alta similitud de la tendencia mensual en el periodo común de 19 años (febrero 2000 al enero 2019), en la cual, se evidenció que el NDVI se alcanzó su valor máximo histórico (0.6) en el periodo de marzo a junio del 2017 (Fig. 6.3), en dicho periodo se ocurrió el evento de El Niño Costero, la fuerte lluvia causó la formación de Laguna La Niña en la costa norte del Perú, en el inicio de abril del 2017, la laguna alcanzó su máxima área (Escudero and Xu, 2019), mientras que se registraron un mayor crecimiento de vegetación en dicha región. En la serie también se destacan valores altos del NDVI en otros periodos de ocurrencia de El Niño (1998, 2002 y 2008). El NDVI mínimo de dicha zona se mantiene a un valor de 0.25 desde el 2006 hasta 2022 para ambos sensor (Fig. 6.3). Se obtuvo un RMSE de 6.83% indicando una buena

homogeneidad de los datos (Moore, et al., 2009), el MAE y BIAS fueron de 5.75% y el BIAS de +0.71 demostrando que una ligera sobreestimación del NDVI de los sensores de AVHRR con respecto al MODIS (Fig. 6.3). El coeficiente de correlación entre ambos sensores fue de 0.662, también se observó la ligera sobreestimación del NDVI por AVHRR (Fig. 6.4).

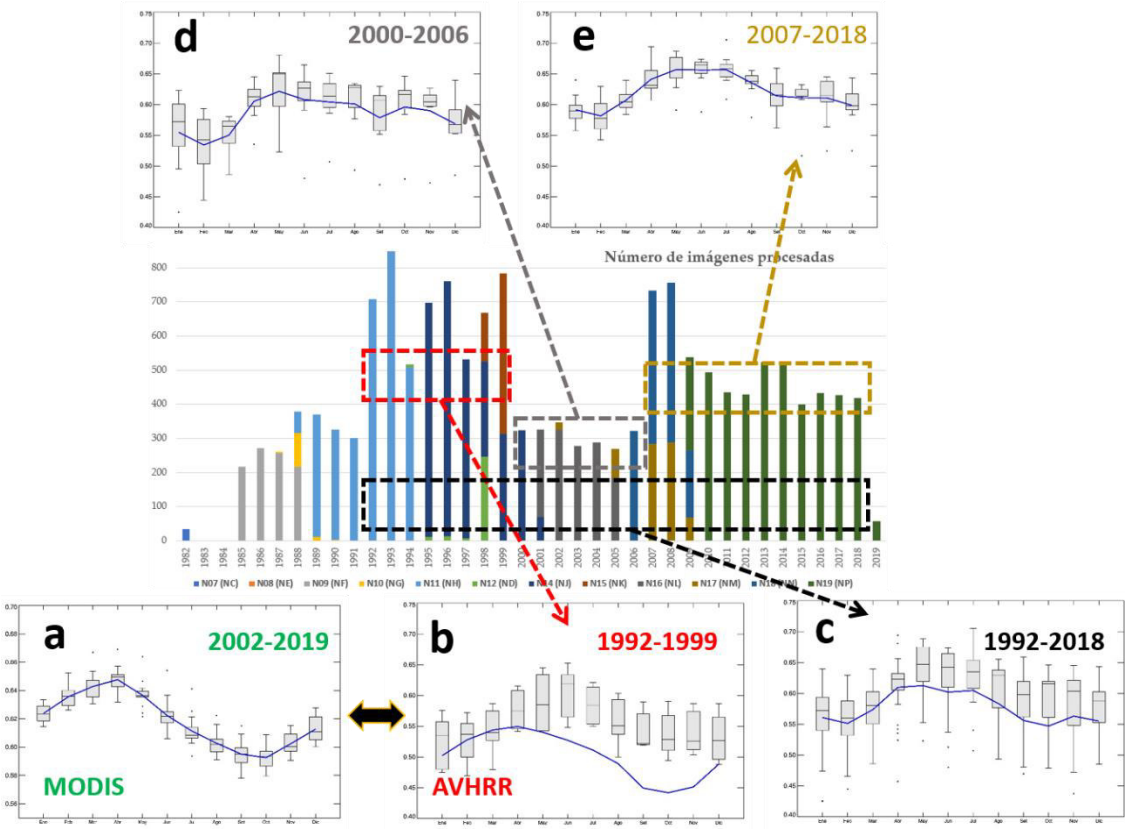

Figura 6.1. Ciclos anuales del NDVI del sensor (a) MODIS de periodo 2002-2019, del AVHRR para los periodos de (b) 1992-1999, (c) 1992-2018, (d) 2000-2006 y (e) 2007-2018.

6.5 Comparación con la precipitación TRMM

La Figura 6.5 muestra una superposición del histograma de los datos del NDVI del AVHRR y la serie de la precipitación del TRMM (línea azul) en la costa norte del Perú para el periodo común (1998-2019), el color amarillo representa los meses con NDVI > 0.4, y el verde son para el NDVI < 0.4. Es evidente que existe un desfase de 1 a 2 meses entre el pico de la precipitación y del NDVI, es decir, se ha observado que, después de registrar un alto valor mensual de precipitación, se inicia un periodo de crecimiento de vegetación, en general, este periodo dura

de cuatro a seis meses. Para correlacionar ambas información, se calculó la relación entre el promedio anual del NDVI y el logarítmico en base 10 de la precipitación en la costa norte del Perú para el periodo común (1998-2018), se obtuvo un coeficiente de correlación lineal de R=0.810 (Fig. 6.6a), y un R= 0.701 (Fig. 6.6b) para la anomalía de la precipitación.

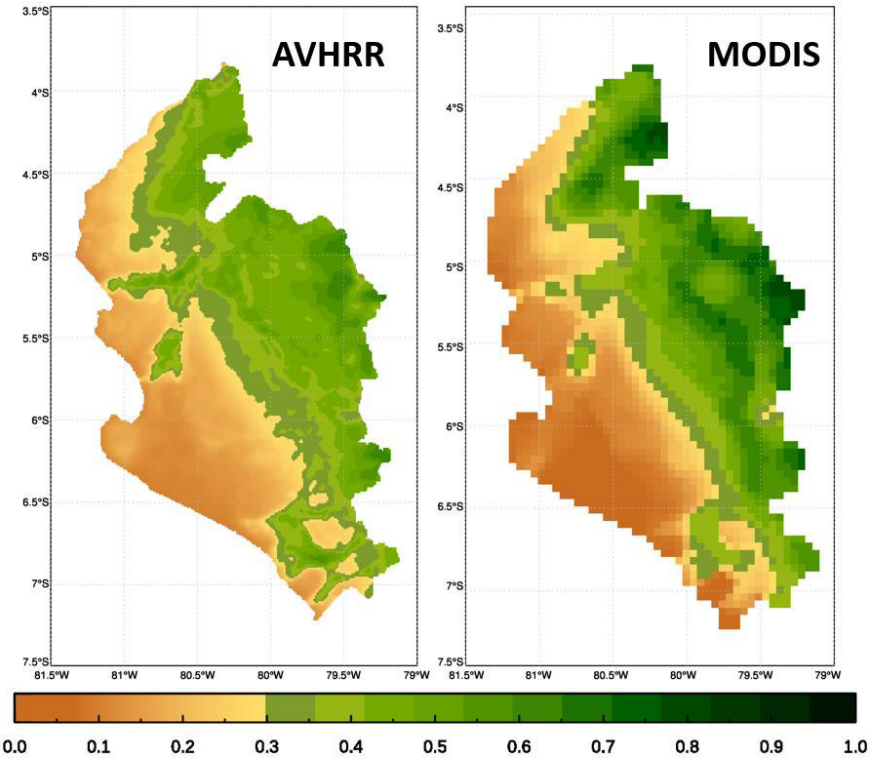

Figura 6.2. Comparación de la distribución del NDVI de ambos sensor para el periodo común (2000-2019).

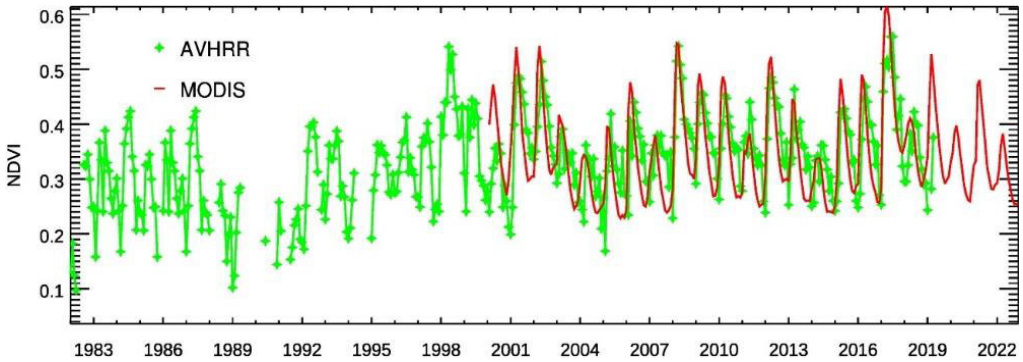

Figura 6.3. Serie mensual del NDVI de los sensores AVHRR y MODIS de la región de costa norte del Perú.

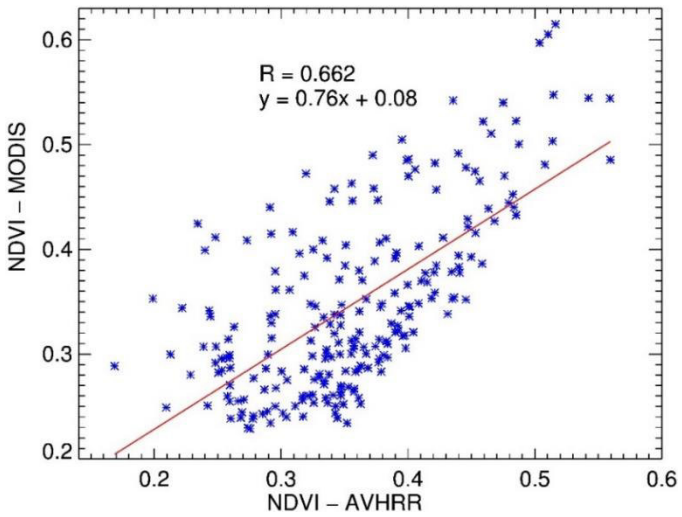

Figura 6.4. Diagrama de dispersión del NDVI de los sensores AVHRR y MODIS.

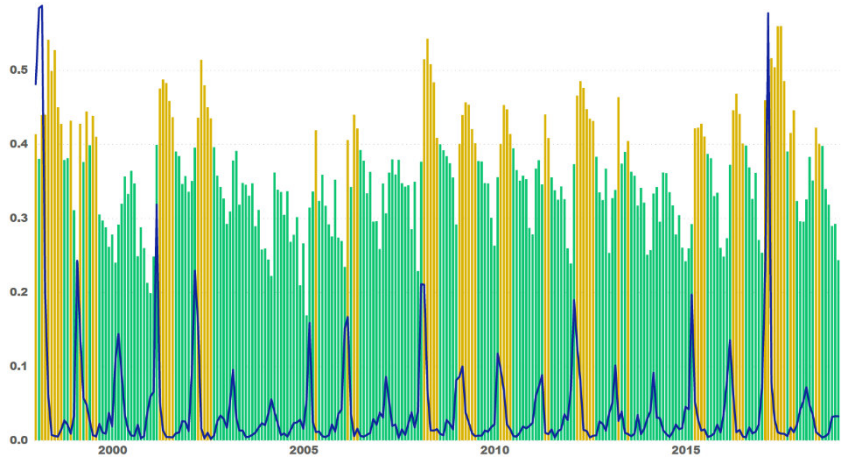

Figura 6.5. Histograma del NDVI de AVHRR y de precipitación TRMM (línea azul) en la costa norte del Perú para el periodo 1998-2019, el color amarillo representa los meses con NDVI > 0.4, y el verde son para el NDVI < 0.4.

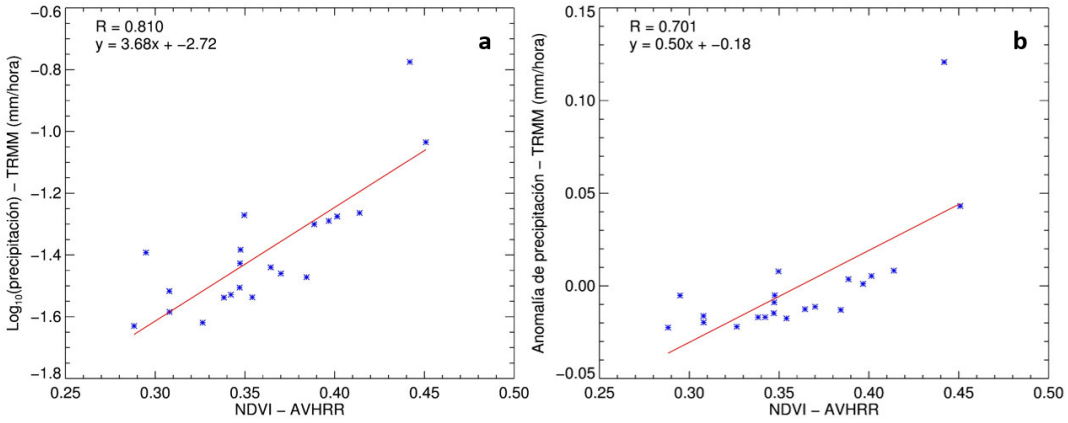

Figura 6.6. Comparación del NDVI/AVHRR promedio anual con precipitación anual (a) logarítmico en base 10 y (b) su anomalía en costa norte del Perú durante el periodo 1998-2018.

6.6 Evaluación de la técnica de tendencia

La técnica de tendencia es una herramienta adecuada para la detección de desertificación, el mapa de tendencia permite localizar las posibles zonas desertificadas de manera rápida y eficiente. La serie de tendencia para una zona específica permite monitorear dinámicamente el cambio de cobertura vegetal, principalmente, conocer los periodos y la tasa de desertificación, además, pronosticar su comportamiento en el próximo periodo. Sin embargo, algunas zonas presentan tendencia no significativa estadísticamente, queda verificar dichos casos con datos de otras fuentes.

6.7 Sobre las tendencias por departamentos

En el mapeo del promedio de la tendencia del VCI por departamentos se observa que, en la costa norte del Perú, la tendencia del VCI ha sido de menor magnitud (de +0.07 a +0.08 dec^{-1}), los departamentos de la costa tienen tendencias no mayor a +0.09 dec^{-1} a excepción de Arequipa y Moquegua (+0.1 dec^{-1}). En las regiones de sierra y selva se registraron mayores tendencias positivas de +0.1 al +0.12 dec^{-1} (Fig. 6.7). Las tendencias positivas indican que a pesar de la intervención antropogénica, en promedio la salud vegetal está en aumento.

6.8 Sobre posibles zonas desertificadas

De acuerdo de la serie de tendencia de VCI de las siete posibles zonas desertificadas, cinco de ellas (Piura, Chiclayo, Chicama, Pisco y Majes) se localizan en los límites de zonas agrícolas, entre ellos, en las dos zona de mayor tendencia negativa (Chiclayo y Chicama) se registró también una mayor área supuestamente afectada por desertificación y una mayor área agrícola, es decir, es muy probable que la desertificación está presentada como consecuencia de la agricultura intensiva en la zona costera del Perú. En la selva, principalmente, en Pucallpa y Huepetuhe, la posible causa de la supuesta desertificación está relacionado más con la expansión urbana que se puede observar con las imágenes de alta resolución espacial.

En Piura y Chiclayo se registraron incrementos de VCI en periodo cortos (en meses) posterior de los eventos de El Niño 1997-98, 2007 y El Niño Costero 2017 mediante su serie de tendencia (Figs.5.15a y 5.15b). Por esta razón, se calcularon las tendencias por tres etapas: de 1986 a 1996, de 1997 a 2006 y de 2007 a 2018 (Fig. 6.8).

De 1986 a 1996, se registraron tendencias positivas del VCI en las zonas de Piura, Pisco, Pucallpa y Huepetuhe, donde los mayores valores fueron encontrados en la región de la selva con Pucallpa de +0.11 dec^{-1} y Huepetuhe de +0.13 dec^{-1}, mientras que, en las zonas de Chiclayo, Chicama y Majes, las tendencias fueron ligeramente negativas con valores que fluctúan entre -0.06 a -0.02 dec^{-1}. Sin embargo, de acuerdo de resultados de la prueba MK, las tendencias no tienen significado estadístico a excepción de Huepetuhe (p-valor =0.012).

De 1997 a 2006, las tendencias fueron significativas excepto la zona Huepetuhe que tuvo una tendencia positiva de +0.08 dec^{-1} y un p-valor de 0.173, en restos zonas se presentaron tendencias negativas, en las cuales, las mayor magnitudes se registraron en las zonas de Piura (-0.29 dec^{-1}), Chiclayo (-0.36 dec^{-1}) y Chicama (-0.27 dec^{-1}) indicando un posible proceso de desertificación.

De 2007 a 2018, se registraron tendencias positivas en las zonas de la costa mostrando un proceso de ligera recuperación de área de vegetación, mientras que en las dos zonas de la selva, se observó tendencias negativas, este comportamiento supuestamente han sido por la expansión urbana en Pucallpa y Madre de Dios, donde en la zona de Huepetuhe, la tendencia alcanzó a -0.25 dec^{-1} (Fig. 6.8).

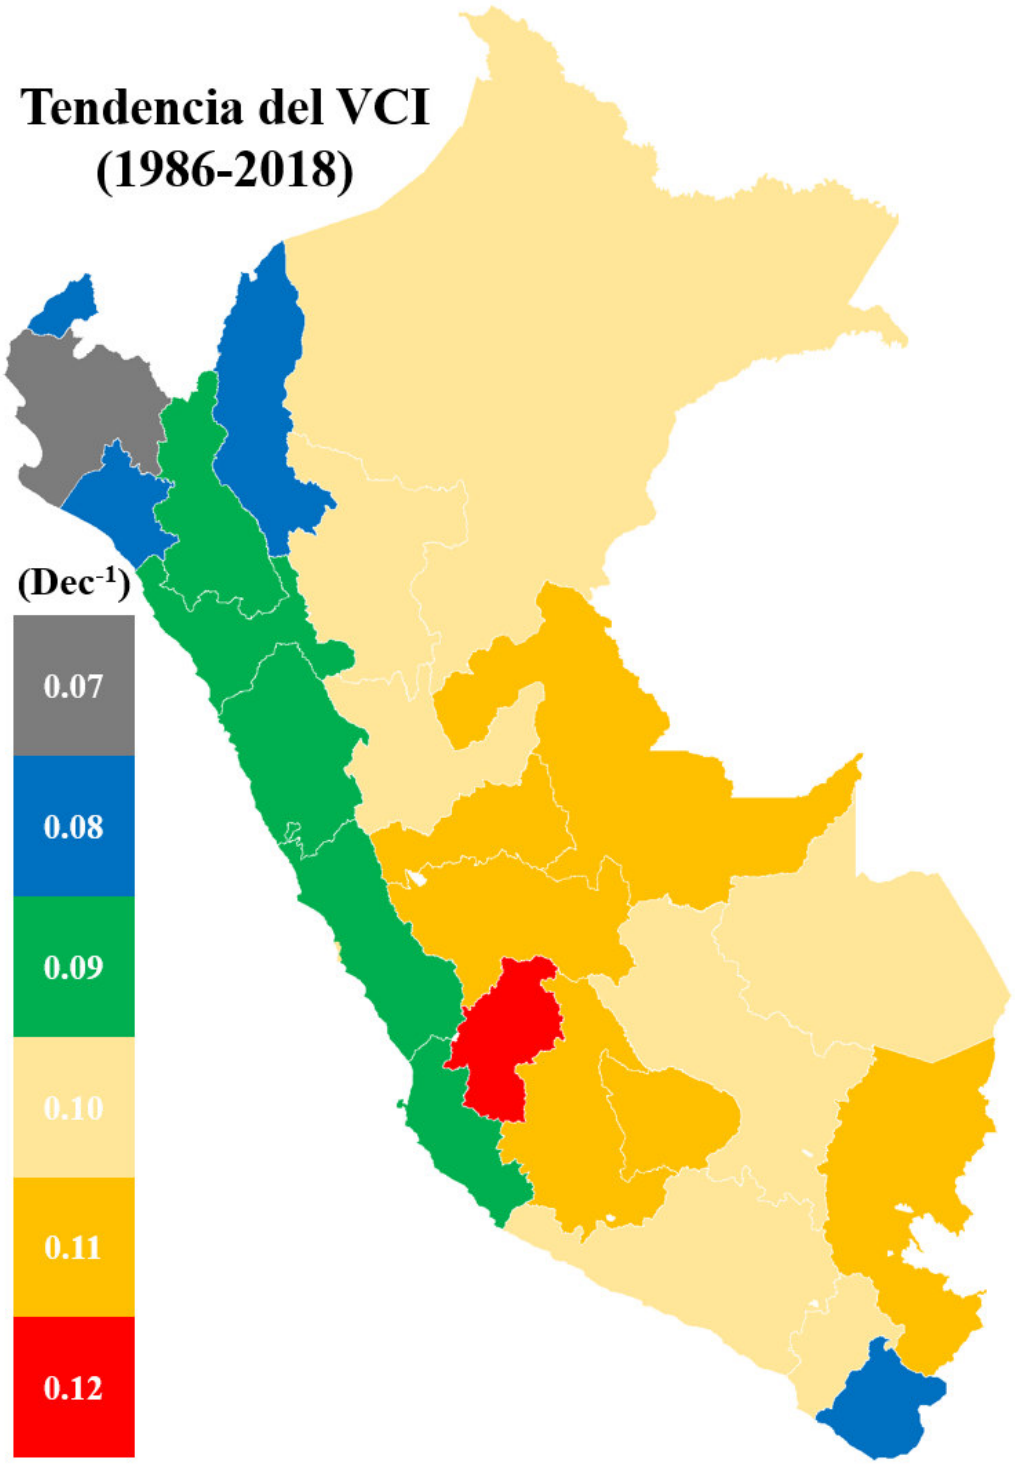

Figura 6.7. Mapa de tendencia del NDVI/AVHRR por departamentos.

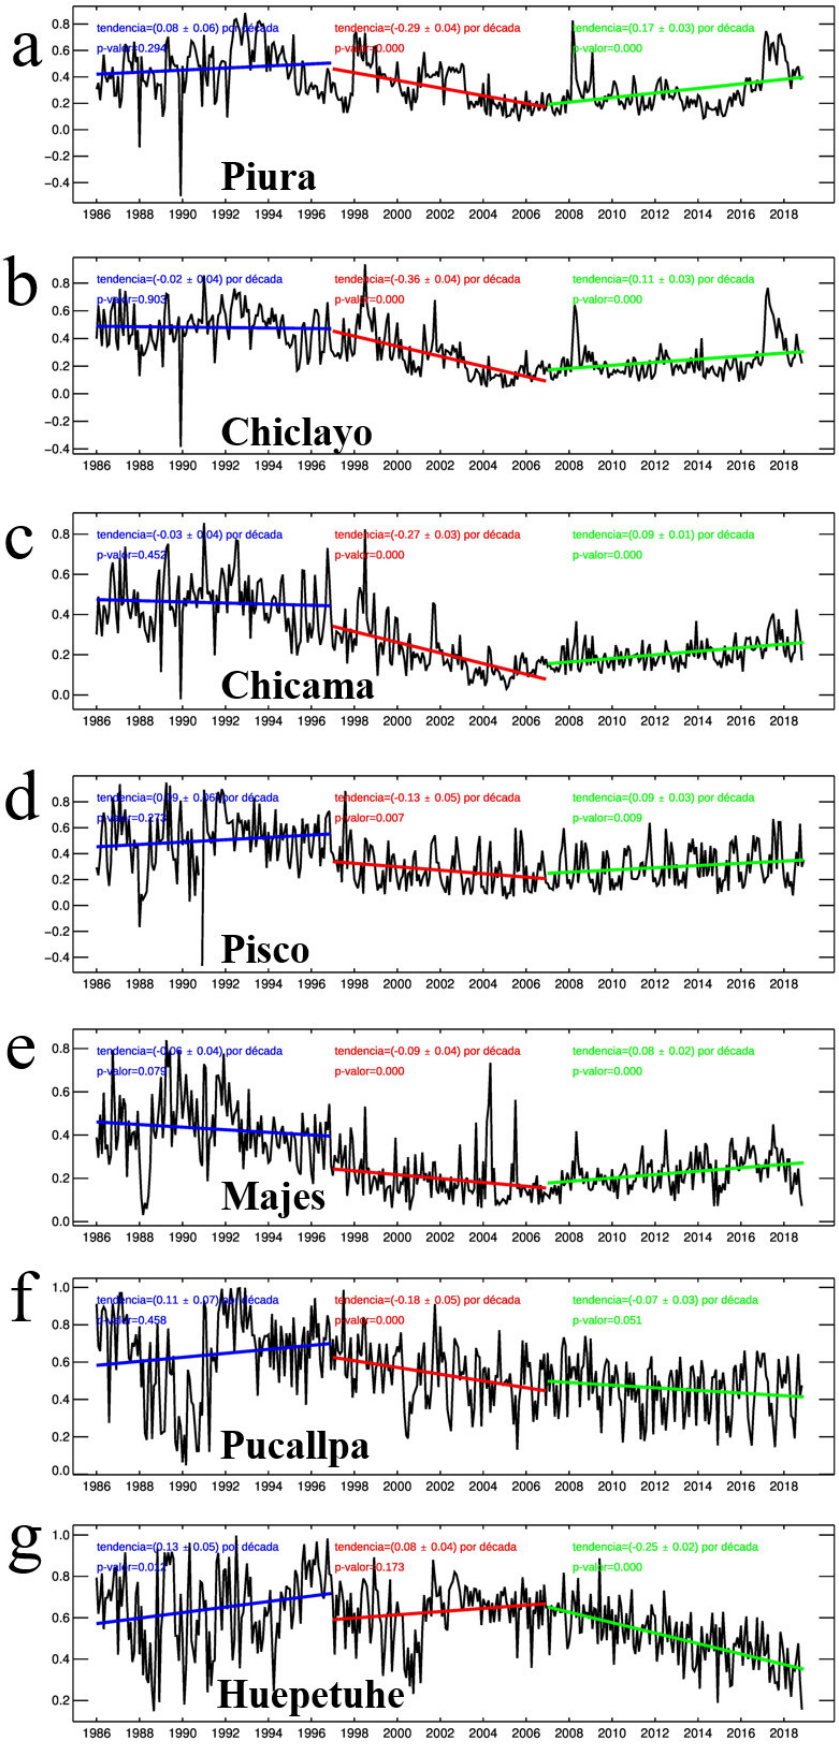

Figura 6.8. Serie de tendencia del NDVI de las posibles zonas desertificadas por periodos.

Capítulo 7

Conclusiones y Recomendaciones

7.1 Conclusiones

El uso de la serie de imágenes AVHRR de casi 40 años permite monitorear el cambio de cobertura vegetal, lo cual es adecuado para estudiar la tendencia decadal de vegetación a escala regional.

La mayor parte de los datos utilizados en este trabajo provienen de los satélites NOAA-09, -11, -14, -16, -18 y -19 que tienen una mayor estabilidad y consistencia entre ellos.

De acuerdo de la serie del NDVI mensual, las tres regiones de costa, sierra, selva y todo territorio del Perú muestran un patrón similar con una tendencia decadal ligeramente positiva, donde, el incremento de la intensidad del NDVI fue mayor en la selva (0.14 dec^{-1}) y menor en la costa (0.05 dec^{-1}).

La distribución del NDVI promedio de cada año evidenció las tres regiones geográficas del Perú: costa (NDVI < 0.2), sierra (0.2< NDVI <0.5) y selva (NDVI>0.5). La variación estacional de la intensidad del NDVI fue ligera visualmente, se presentó mayor intensidad entre los meses de abril a setiembre y menor en restos meses del año.

Se presentaron patrón similar de distribución del NDVI entre AVHRR y MODIS que se registraron el valor máximo histórico (0.6) en el periodo que ocurrió el Niño Costero en 2017, también destacaron valores altos en los eventos de El Niño 1998, 2002 y 2008.

De acuerdo de los mapas de la anomalía del NDVI promedio anual, los valores negativos se distribuyen en la región de costa mientras que las anomalías positivas se distribuyen en la región selva en mayoría de los meses del año. Se registró anomalías negativas en el periodo 1982 al 1994, y los años posteriores fueron de anomalías positivas, excepción de los años 1999-2000, 2018-2019.

En la costa del Perú, se presentaron anomalías negativas durante las estaciones de verano, y en otoño se registraron anomalías negativas en la región de Loreto y de la selva alta.

El diagrama de Hovmoller del NDVI evidenció que zonas de mayor intensidad del NDVI en la región costera fueron en zonas de reserva y en zonas agrícolas mientras que, la distribución del NDVI en las regiones de sierra y selva fue más homogénea. El diagrama de Hovmoller de la anomalía también muestra un patrón similar.

En las regiones de selva alta, páramo, bosque tropical pacífico, límite norte y centro de las regiones de puna y serranía esteparia, límite este de la costa norte del Perú, límite entre bosque seco y selva alta fueron de mayor desviación estándar.

Se registró un incremento progresivo de la concentración del NDVI de la costa hacia la selva, además, se observó anomalías negativas en el periodo del 1982 al 1994.

Las tendencias del NDVI y VCI permiten conocer el estado de vegetación de periodo más reciente con respecto a la serie histórica y pronosticar su comportamiento en los próximos meses.

Mapa de tendencia del VCI muestra un mayor contraste entre la posible zona desertificada y su alrededor con respecto a la de NDVI.

De acuerdo de la serie y el mapa de tendencia por departamentos, en la región costa (de Tumbes a ICA) se registró menor tendencia del VCI, en la cual, los departamentos de costa norte tienen un valores mínimos (de +0.07 a +0.08 Dec^{-1}).

En general, se presentó una tendencia positiva de la intensidad de los índices de vegetación, sin embargo, se observó zonas de área mucho menor que presentan tendencias negativas. Estas zonas pueden ser detectadas fácilmente con mapas de tendencia.

Las tendencias del NDVI de las posibles zonas de desertificadas tienen menor rango y magnitud (de -0.02 a +0.01 dec^{-1}) con respecto a las de VCI (de -0.11 a -0.06 dec^{-1}). Se observó un mayor contraste entre la zona identificada y su alrededor en mapa de tendencia de VCI.

Se propone que, entre las posibles zonas desertificadas, las zonas en la región costera (Piura, Chiclayo, Chicama, Pisco y Majes) fueron generados por la agricultura intensiva mientras que, la posible desertificación de las zonas de Pucallpa y Huepetuhe fueron por la expansión urbana.

De acuerdo de las series de tendencias por periodo, las zonas de la selva tienen comportamiento de tendencias muy distinto a las de costa: En el periodo de 1986 a 1996, las zonas costeras muestran tendencias cercanas a cero mientras que, en las zonas de la selva, las tendencias son más notables (+0.11 y +0.13 dec^{-1}), de 1997 a 2006, se registró mayor tendencias negativas en la costa norte (hasta -0.36 dec^{-1}) mientras que, se registró tendencia positiva en Huepetuhe, de 2007 a 2018, las tendencias en las zonas costeras fueron positivas mientras que, se observó tendencias negativas en las dos zonas de la selva.

7.2 Recomendaciones

Utilizar otros modelos de corrección atmosférica y algoritmo de filtrado de nubes para realizar una comparación los datos del NDVI y VCI mensual del mismo periodo.

Calcular las tendencias de otros índices de vegetación (o productos de los índices) y compararlos con los datos in situ para evaluar la eficiencia de esta técnica de detección de desertificación.

Correlacionar los datos mensuales del NDVI y VCI con otros parámetros tales como la elevación, la superconductividad del suelo por regiones.

Estimar la variabilidad de magnitud y área de las posibles zonas desertificadas con imágenes de mayor resolución espacial, se recomienda el uso de las imágenes de la serie Landsat y Sentinel.

Evaluar el impacto de las actividades humanas (por ejemplo, área de expansión, población) en las posibles zonas de desertificación.

Referencias

Adler-Golden, S. M., Matthew, M. W., Bernstein, L. S., Levine, R. Y., Berk, A., Richtsmeier, S. C., Acharya, P. K., Anderson, G. P., Felde, J. W., Gardner, J. A., Hoke, M. L., Jeong L. S., Pukall, B., Ratkowski, A. J., & Burke H. (1999). Atmospheric correction for short-wave spectral imagery based on MODTRAN4. Summaries of the Eighth Annual JPL Earth Science Workshop, Jet Propulsion Laboratory, Pasadena, JPL Publication 99-17, 12-23. https://www.spiedigitallibrary.org/conference-proceedings-of-spie/3753/0000/Atmospheric-correction-for-shortwave-spectral-imagery-based-on-MODTRAN4/10.1117/12.366315.short

Aguilar, J. (2015). Variabilidad espacio-temporal de la temperatura de la superficie del suelo en El Perú y su relación con los eventos extremos, mediante imágenes MODIS/Terra durante el periodo 2000 – 20122. Tesis de Maestría en Física mención Geofísica, Universidad Nacional Mayor de San Marcos. Facultad de Ciencias Físicas, Lima. pp: 109. https://cybertesis.unmsm.edu.pe/bitstream/handle/20.500.12672/9989/Aguilar_lj.pdf?sequence=3&isAllowed=y

Ariza, A., Irizar, M., & Bayer, S. (2018). Empirical line model for the atmospheric correction of sentinel-2A MSI images in the Caribbean Islands. European Journal of Remote Sensing, 51:1, 765-776. https://www.tandfonline.com/doi/full/10.1080/22797254.2018.1482732

Badaracco, R. R. (2012). Detección de la salinidad en los suelos de cultivos de algodón usando imágenes de satélite en la costa norte del Perú. Tesis de licenciado en Física, Universidad Nacional Mayor de San Marcos. Facultad de Ciencias Físicas, Lima. pp: 112. https://cybertesis.unmsm.edu.pe/bitstream/handle/20.500.12672/3071/Badaracco_mr.pdf?sequence=1&isAllowed=y

Bankert, R. L. (1994). Cloud classification of AVHRR imagery in maritime regions using a probabilistic neural network, Journal of Applied Meteorology (1988-2005), 33(8), 909-918. https://journals.ametsoc.org/view/journals/apme/33/8/1520-0450_1994_033_0909_ccoaii_2_0_co_2.xml

Baum, B. A., & Trepte, Q. (1999). A grouped threshold approach for scene identification in AVHRR imagery. American Meteorological Society. 793-800. https://journals.ametsoc.org/view/journals/atot/16/6/1520-0426_1999_016_0793_agtafs_2_0_co_2.xml

Bernstein, L. S., Adler-Golden, S. M., Jin X. M., Gregor, B., & Sundberg, R. L. (2012). Quick atmospheric correction (QUAC) code for vnir-swir spectral imagery: algorithm details. 2012 4th Workshop on Hyperspectral Image and Signal Processing (WHISPERS), pp: 4. https://ieeexplore.ieee.org/document/6874311

Bernstein, L. S., Adler-Golden, S. M., Sundberg, R. L., Levine, R. Y., Perkins, T. C., Berk, A., Ratkowski, A. J., Felde, G., & Hoke, M. L. (2005). A new method for atmospheric correction and aerosol optical property retrieval for vis-swir multi- and hyperspectral imaging sensors: QUAC (Quick Atmospheric Correction). Proceedings. 2005 IEEE International Geoscience and Remote Sensing, 3549-3552. https://ieeexplore.ieee.org/document/1526613

Bernstein, L. S., Adler-Golden, S. M., Sundberg, R. L., & Ratkowski, A. J. (2008). In-scene-based atmospheric correction of uncalibrated VISble-SWIR (VIS-SWIR) hyper- and multispectral imagery. Proc. SPIE Int. Soc. Opt. Eng., 7107, pp: 7 https://www.spiedigitallibrary.org/conference-proceedings-of-spie/7107/1/In-scene-based-atmospheric-correction-of-uncalibrated-VISible-SWIR-VIS/10.1117/12.808193.short

Brack A. (1986). Ecología de un país complejo, en gran geografía del Perú: naturaleza y hombre, tomo II, Edit. Manfer-Mejia Baca, España, 145-319. https://civ.uap.edu.pe/cgi-bin/koha/opac-detail.pl?biblionumber=5218

Carbajal, G. (2017). Estimación del índice de sequía a partir de datos imágenes NDVI y LST del sensor MODIS y TRMM para las regiones de Lambayeque, Piura y Cajamarca – Perú, durante el periodo 2000-2013. Tesis de Maestría en Física mención Geofísica, Universidad

Nacional Mayor de San Marcos. Facultad de Ciencias Físicas, Lima. pp: 130. https://cybertesis.unmsm.edu.pe/bitstream/handle/20.500.12672/7235/Carbajal_dg.pdf?sequence=3&isAllowed=y

Chen, X. W., Tateishi, R., & Wang, C. Y. (1999). Development of a 1-km landcover dataset of China using AVHRR data. ISPRS Journal of Photogrammetry & Remote Sensing, 54, 305-316. https://www.sciencedirect.com/science/article/abs/pii/S0924271699000271

Coakley, J. A., & Bretherton, F. P. (1982). Cloud cover from high-resolution scanner data: Detecting and allowing for partially filled fields of view. J. Geophys. Res., 87, 4917-4932. https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/JC087iC07p04917

Christodoulou, C. I., Michaelides, S. C., & Pattichis, C. S. (2003). Multifeature texture analysis for the classification of clouds in satellite imagery. IEEE Transactions on Geoscience and Remote Sensing, Vol. 41, No. 11, 2662-2668. https://ieeexplore.ieee.org/document/1245253

Concha, J. A., & Schott, J. R. (2014). A model-based ELM for atmospheric correction over case 2 water with Landsat 8. Proc. SPIE 9111, Ocean Sensing and Monitoring VI, 911112, 9. https://www.spiedigitallibrary.org/conference-proceedings-of-spie/9111/911112/A-model-based-ELM-for-atmospheric-correction-over-Case-2/10.1117/12.2050589.short

Curtis, H. D. (2005). Orbital mechanics for engineering students. Oyrdye Ybuversity, Elsevier Butterworth-Heinemann, 3rd Edition pp: 673. http://www.nssc.ac.cn/wxzygx/weixin/201607/P020160718380095698873.pdf

Davis, P. D., Majors, G., & Jacobowitz, H. (1984). An assessment of Nimbus-7 EWarth Radiation Budget shortwave scanner data by correlative analysis with narrow-band CZCS data. J. Geophys. Res., 89, 5077-5088. https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/JD089iD04p05077

Defries, R. S., & Townshend, J. R. G. (1994). NDVI – derived land cover classification at a global scale. Int. J. of Remote Sensing, 15:17, 3567-3586. https://www.tandfonline.com/doi/abs/10.1080/01431169408954345

Deng, C. W., Wang, W. Z., & Wang, S. G. (2018). Cloud detection in satellite images based on natural scene statistics and gabor features. IEEE Geoscience and Remote Sensing Letters, Vol. 16, No. 4, 608-612. https://ieeexplore.ieee.org/document/8534367

Dutta, D., Kundu, A., Patel, N. R., Saha, S. K., & Siddiqui, A. R. (2015). Assessment of agricultural drought in Rajasthan (India) using remote sensing derived Vegetation Condition Index (VCI) and Standardized Precipitation Index (SPI). Egypt. J. Remote Sens. Space Sci., Vol. 18, Issue 1, pp: 53-63. https://www.sciencedirect.com/science/article/pii/S1110982315000095?via%3Dihub

Dong, Z. P., Wang, M., Li, D. R., Wang, Y. L., & Zhang, Z. Q. (2019). Cloud detection method for high resolution remote sensing imagery based on the spectrum and texture of superpixels. Photogrammetric Engineering & Remote Sensing, Vol. 85, No. 4, 257-268. https://www.ingentaconnect.com/content/asprs/pers/2019/00000085/00000004/art00011

Ehrlich, D., Estes, J. E. & Singh, A. (1994). Applications of NOAA-AVHRR 1 km data for environmental monitoring. Int. J. of Remote Sensing, 15:1, 145-161. https://www.tandfonline.com/doi/abs/10.1080/01431169408954056

Emery, W., Brown, J. & Nowak, Z. (1989). AVHRR image navigation: summary and review. Photogrammetric Engineering and Remote Sensing, Vol. 55, No. 8, 1175-1183. https://www.asprs.org/wp-content/uploads/pers/1989journal/aug/1989_aug_1175-1183.pdf

Escudero, L., & Xu, H. (2019). Formación y evolución de la Laguna La Niña, utilizando imágenes satelitales Modis-Aqua. Bol. Inst. Mar Perú. Vol. 34, No. 1, 105-114. https://repositorio.imarpe.gob.pe/handle/20.500.12958/3358

Fontana, F. M. A., Coops, N. C., Khlopenkov, K. V., Trishchenko, A. P., Riffler, M., & Wulder, M. A. (2012). Generation of a novel 1 km NDVI data set over Canada, the northern United States and Greenland based on historical AVHRR data. ELSEVIER, Remote Sensing of Environment, 15:1, 145-161. https://www.sciencedirect.com/science/article/abs/pii/S0034425712000193?via%3Dihub

Gaitán, J. J., Bran, D., Oliva, G., Ciari, G., Nakamatsu, V., Salomone, J., Ferrante, D., Buono, G., Massara, V., Humano, G., Celdrán., D., Opazo, W., & Maestre, F. T. (2013). Evaluating the performance of multiple remote sensing indices to predict the spatial variability of ecosystem structure and functioning in Patagonian steppes. ELSEVIER, Ecological Indicators, Vol. 34, 181-191. https://www.sciencedirect.com/science/article/abs/pii/S1470160X13002033?via%3Dihub

Gilbert, R. O. (1987). Statistical methods for environmental pollution monitoring. Wiley, ISBN: 978-0-471-28878-7, pp: 336. https://www.wiley.com/en-us/Statistical+Methods+for+Environmental+Pollution+Monitoring-p-9780471288787

Goodrum, G., Kidwell, K. B., & Winston, W. (2001). NOAA KLM user's guide, NASA, 1, pp: 182. https://www1.ncdc.noaa.gov/pub/data/satellite/publications/podguides/N-15%20thru%20N-19/pdf/

Gocic, M., & Trajkovic, S. (2013). Analysis of changes in meteorological variables using Mann-Kendall and Sen's slope estimator statistical tests in Serbia. Global and Planetary Change, Vol. 100, 172-182. https://sci-hub.se/10.1016/j.gloplacha.2012.10.014

Gruninger, J. H., Lee, J., & Sundberg, R. L. (2003). Application of convex cone analysis to hyperspectral and multispectral scenes. Pros. SPIE 4885, Image and Signal Processing for Remote Sensing VIII. 188-198. https://www.spiedigitallibrary.org/conference-proceedings-of-spie/4885/1/Application-of-convex-cone-analysis-to-hyperspectral-and-multispectral-scenes/10.1117/12.463103.short

Ho, D., & Asem, A. (1986). NOAA AVHRR image referencing. Int. J. Remote Sensing VIII, Vol. 7, No. 7, 895-904. https://www.tandfonline.com/doi/abs/10.1080/01431168608948898

Hutchison, L. (2004). Determining land use change and desertification in China using remote sensing data. Thesis for the degree of B.S. in Geosciences, Massachusetts Institute of Technology, pp: 64. https://dspace.mit.edu/handle/1721.1/114113

Irish, R. R. (2000). Landsat7 automatic cloud cover assessment. Proceedings Volume 4049, Algorithms for Multispectral, Hyperspectral, and Ultraspectral Imagery VI, 1, pp: 8. https://www.spiedigitallibrary.org/conference-proceedings-of-spie/4049/1/Landsat-7-automatic-cloud-cover-assessment/10.1117/12.410358.short?SSO=1

Jackson, R. D., & Huete, R. A. (1991). Interpreting vegetation indices. Preventive Veterinary Medicine, Vol. 11, 185-200. https://www.sciencedirect.com/science/article/abs/pii/S0167587705800042

Ishida, N., Matsuo, K., Imamura, K., & Craig, V. S. (2018). Hydrophobic attraction measured between asymmetric hydrophobic surfaces. Langmuir, Vol. 34, No. 12, pp: 40. https://pubs.acs.org/doi/epdf/10.1021/acs.langmuir.7b04246#

Jedlovec, G. J., Haines, S. L., & LaFontaine, F. J. (2008). Spatial and temporal varying thresholds for cloud detection in GOES imagery. IEEE Transactions on Geoscience and Remote Sensing, Vol. 46, No. 6, 1705-1717. https://ieeexplore.ieee.org/document/4505540/authors#authors

Jerry, J. S., William, J. A., Robert, B. G., & Wiely, L. (2000). Understanding space: an introduction to astronautics. McGraw-Hill Primis Custom Publishing, 2dn Ed., pp: 772. https://books.google.com.pe/books?id=IIcgAQAAIAAJ&hl=es&source=gbs_book_other_versions

Jiménez-Muñoz, J. C., Sobrino, J. A., Mattar, C., & Franch, B. (2010). Atmosperic correction of optical imagery from MODIS and reanalysis atmospheric products. ELSEVIER, Remote Sensing of Environment, Vol. 114, 2195-2210. https://www.researchgate.net/publication/220008235_Atmospheric_correction_of_optical_imagery_from_MODIS_and_Reanalysis_atmospheric_products

Kalluri, S., Cao, C., Heidinger, A., Ignatov, A., Key, J., & Smith, T. (2020). The advanced very high resolution radiometer: contributing to earth observations for over forty years. Bulletin of the American Meteorological Society, 1, pp: 16. https://journals.ametsoc.org/view/journals/bams/102/2/BAMS-D-20-0088.1.xml

Kegelmeyer, W. P. (1994). Using TBUS orbital elements for AVHRR image gridding. International Journal of Remote Sensing, 10: 4-5, 653-569. https://www.osti.gov/servlets/purl/10141846

Kendall, M. G. (1970). Rank correlation methods. Griffin London, fourth edition, pp: 202. https://www.abebooks.com/9780852641996/Rank-correlation-methods-Kendall-Maurice-0852641990/plp

Kloster, K. (1989). Using TBUS orbital elements for AVHRR image gridding. International Journal of Remote Sensing, Vol. 10, 653-659. https://www.tandfonline.com/doi/abs/10.1080/01431168908903906

Kogan, F. N. (1995). Application of vegetation index and brightness temperature for drought detection. Adv. Space Res., Vol. 15, No. 11, 91-100. https://www.sciencedirect.com/science/article/abs/pii/027311779500079T?via%3Dihub

Kotarba, A. Z. (2015). Evaluation of ISCCP cloud amount with MODIS observations. ELSEVIER, Atmospheric Research, Vol. 153, 310-317. https://www.sciencedirect.com/science/article/abs/pii/S0169809514003639?via%3Dihub

Liu, C., Yang, S., Di, D., Yang, Y. J., Zhou, C., Hu, X. Q., & Sohn, B. J. (2021). A machine learning-based cloud detection algorithm for the Himawari-8 spectral image. Advances in Atmospheric Sciences, 39, 1994-2007. https://link.springer.com/article/10.1007/s00376-021-0366-x

Ma, X., Niu, X., Gu, L., Wang, Y., Zhao, Y., Bailey, J., & Lu, F. (2021). Understanding adversarial attacks on deep learning based medical image analysis systems. Pattern Recognition, Vol. 110, 107332, pp: 11. https://www.sciencedirect.com/science/article/abs/pii/S0031320320301357

Mann, H. B. (1945). Nonparametric tests against trend. Econometrica, 13, 245-259. http://danida.vnu.edu.vn/cpis/files/Refs/PCAs/Mann_1945_NONPARAMETRIC%20TESTS%20AGAINST%20TREND.pdf

Marsouin, A., & Brunel, P. (1991). Navigation of AVHRR images using ARGOS or TBUS bulletins, International Journal of Remote Sensing, 12:7, 1575-1592. https://www.tandfonline.com/doi/abs/10.1080/01431169108955190

Matthew, M. W., Adler-Golden, S. M., Berk, A., Felde, G., Anderson, G. P., Gorodetzky, D., Paswaters, S., & Shippert, M. (2003). Atmospheric Correction of Spectral Imagery: Evaluation of the FLAASH Algorithm with AVIRIS Data. SPIE Proceeding, Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery IX, 5093, 474-482. https://www.spiedigitallibrary.org/conference-proceedings-of-spie/5093/0000/Atmospheric-correction-of-spectral-imagery--evaluation-of-the-FLAASH/10.1117/12.499604.short

Melgarejo, O. R., Ariza, A., Ramírez, H. M., & Rincón, H. L. (2018). Comparison of ATCOR atmospheric and ELM linear empirical correction models applied to WorldView-2 images. TECCIENCIA, Vol. 13, No. 25, 29-38. https://revistas.ecci.edu.co/index.php/TECCIENCIA/article/view/29

MINAM. (2010). Cuarto informe nacional sobre la aplicación del convenio de diversidad biológica años 2006-2009 capítulos I, II, III, IV, apéndices, y anexo área protegidas, Fondo Editorial de MINAM, 1, pp: 184. https://www.minam.gob.pe/diversidadbiologica/wp-content/uploads/sites/21/2013/10/Cuarto-Informe_Convenio-de-Diversidad-Biologica.pdf

MINAM. (2011). La desertificación en el Perú: cuarta comunicación nacional del Perú a la convención de lucha contra la desertificación y la sequía. Dirección de Diversidad Biológica – MINAM, 1, pp: 76. https://repositoriodigital.minam.gob.pe/handle/123456789/200?show=full

Mittaz, P., & Harris, R. (2009). A physical method for the calibration of the AVHRR/3 thermal IR channel 1: the prelaunch calibration data. Journal of Atmospheric and Oceanic Technology, 26, 996-1019. https://journals.ametsoc.org/view/journals/atot/26/5/2008jtecho636_1.xml

Molnar, G., & Coakley, J. A. (1985). Retrieval of cloud cover from satellite imagery data: A statistical approach. Journal of Geophysical Research: Atmospheres, Vol. 90, Issue D7, 12960-12970. https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/JD090iD07p12960

Naciones Unidas. (1977). Report of the United Nations Conference on Desertification. Nairobi, Vol.29, pp: 139. https://digitallibrary.un.org/record/733000

Njomo, D. (2008). Mapping deforestation in Congo Basin Forest using multi-temporal SPOT VGT imagery from 2000-2004. EARSeL eProceedings, 7, pp: 10. http://eproceedings.uni-oldenburg.de/website/vol07_1/07_1_njomo1.pdf

NOAA. (2014). NOAA KLM user's guide with NOAA-N, N prime, and MetOp supplements. National Oceanic and Atmospheric Administration, National Environmental Satellite, Data, and Information Service National Climatic Data Center, Remote Sensing and Applications Division, Revision 2014, pp: 2530. https://ia801005.us.archive.org/8/items/noaa-klm-guide/0.0%20NOAA%20KLM%20Users%20Guide.pdf

Ormsby, J. P., Choudhury, B. J., & Owe, M. (1987). Vegetation spatial variability and its effect on vegetation indices. Int. J. of Remote Sensing, 8:9, 1301-1306. https://www.tandfonline.com/doi/abs/10.1080/01431168708954775

Paylore, P., & Mcginnies, W. G. (1969). Desert research: selected references 1965-1968. Arizona Univ. Tucson Inst. of Arid Lands Research: Tucson, AZ, USA. pp: 410. https://apps.dtic.mil/sti/tr/pdf/AD0703884.pdf

Pearson, K., Embury, O., & Bulgin, C. (2014). Bayesian cloud detection algorithm theoretical basis document. EUMETSAT, EUM-BC-ATBD-003, pp: 56. https://www-cdn.eumetsat.int/files/2020-04/pdf_bay_clo_atbd.pdf

Pearson, R. L., & Miller, L. D. (1972). Remote mapping of standing crop biomass for estimation of the productivity of the short-grass prairie, Pawnee National Grasslands, Colorado. Proceedings of the 8th International Symposium on Remote Sensing of Environments, ERIM International, Ann Arbor, MI. pp: 1357-1381. https://www.researchgate.net/publication/234425797_Remote_Mapping_of_Standing_Crop_Biomass_for_Estimation_of_Productivity_of_the_Shortgrass_Prairie

Rahman, H., & Dedieu, G. (1994). SMAC: a simplified method for the atmospheric correction of satellite measurement in the solar spectrum. International Journal of Remote Sensing, 15, 123-143. https://www.tandfonline.com/doi/abs/10.1080/01431169408954055

Rojas J., Casanova, J. L., Calle, A., Romo, A., Fashé, O., & Eche, C. (2001). La temperatura de la superficie del mar a partir de imágenes del sensor AVHRR/2 del satélite de órbita polar NOAA-14. Revista de Investigación de Física Vol. 4, No. 1, 9-26. https://revistasinvestigacion.unmsm.edu.pe/index.php/fisica/article/view/8709

Rojas, J., Eche, J., Tito, P., Lauro, A., Fashé, O., Casanova, J., Calle, A., & Romo, A. (2000). Calibración radiométrica de los canales visibles 1 y 2 del sensor AVHRR/2 del satélite en órbita polar NOAA – 14 para la estimación del NDVI. Revista de investigación de física, Vol. 3, No. 1, 41-47. https://revistasinvestigacion.unmsm.edu.pe/index.php/fisica/article/view/8613/7459

Rojas, J., Rufasto, E., Eche, J., & Carrillo, F. (2009). Modelo del inicio de la sequía en la costa norte de Perú usando los índices ENOS y los índices de vegetación del AVHRR/NOAA. Anais XIV Simpósio Brasileiro de Sensoramiento Remoto, Natal, Brasil, INPE, 5055-5063. http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.17.21.45/doc/5055-5063.pdf

Rosborough G. W., Baldwin, D. G., & Emery, W. J. (1994). Precise AVHRR image navigation. IEEE Transactions on Geoscience and Remote Sensing, Vol. 32, No. 3, 644-657. https://ieeexplore.ieee.org/document/297982

Rossow, W. B., & Garder, L. C. (1994). Cloud detection using satellite measurements of infrared and visible radiances for ISCCP. Journal of Climate, Vol. 6, No. 12, 2341-2369. https://journals.ametsoc.org/view/journals/clim/6/12/1520-0442_1993_006_2341_cdusmo_2_0_co_2.xml

Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. NASA, Goddard Space Flight Center 3d ERTS-1 Symp., Vol. 1, Sect. A, 309-317. https://ntrs.nasa.gov/citations/19740022614

Saunders, R. W., & Kriebel, K. T. (1988). An improved method for detecting clear sky and cloudy radiances from AVHRR data. Int. J. Remote Sens., 9, 123-150. https://www.tandfonline.com/doi/abs/10.1080/01431168808954841

Schiffer, R. A., & Rossow, W. B. (1983). The international satellite cloud climatology project (ISCCP): the first project of the world climate research program. Bull. Am. Meteorol. Soc, 64, 779-784. https://journals.ametsoc.org/view/journals/bams/64/7/1520-0477-64_7_779.xml

SENAMHI. (2021). Climas del Perú – mapa de clasificación climática nacional. Servicio Nacional de Meteorología e Hidrología del Perú, 1, pp: 70. https://www.senamhi.gob.pe/load/file/01404SENA-4.pdf

Soca, R. 2015. Identificación de tierras degradadas por salinidad del suelo en los cultivos de caña de azúcar en Pomalca usando imágenes satélites. Tesis de Maestría en Física mención Geofísica, Universidad Nacional Mayor de San Marcos. Facultad de Ciencias Físicas, Lima. pp: 139
https://cybertesis.unmsm.edu.pe/handle/20.500.12672/5968

Stowe, L. L., McClain, E. P., Carey, R., Pellegrino, P., Gutman, G. G., Davis, P., Long, C., & Hart, S. (1991). Global distribution of cloud cover derived from NOAA/Avhrr operational satellite data. Adv. Space Res, Vol. 11, No. 3, 51-54. https://www.sciencedirect.com/science/article/pii/0273117791904026

Stowe, L. L., Davis, P., & McClain, P. (1999). Scientific basis and initial evaluation of the CLAVR-1 Global Clear/Cloud Classification algorithm for the Advanced Very High Resolution Radiometer. Journal of atmospheric and oceanic technology, Vol. 16, 656-681. https://journals.ametsoc.org/view/journals/atot/16/6/1520-0426_1999_016_0656_sbaieo_2_0_co_2.xml

Tucker, C. J., & Miller, L. D. (1977). Soil spectra contributions to grass canopy spectral reflectance. Photogrammetric Engineering and Remote Sensing, Vol. 43, No. 6, 721-726. https://www.asprs.org/wp-content/uploads/pers/1977journal/jun/1977_jun_721-726.pdf

Tucker, C. J., Dregne, H. E., & Newcomb, W. W. (1991). Expansion and contraction of the Sahara desert from 1980 to 1990. American Association for the Advancement of Science, Vol. 253, No. 5017, 299-301. https://www.science.org/doi/10.1126/science.253.5017.299

Vera, R. M., (2005). Altas climático de irradiación solar a partir de imágenes del satélite NOAA. Aplicación a la Península Ibérica. Tesis de doctorado, Universidad Politécnica de Cataluña. Departamento de Proyectos de Ingeniería, España. pp: 364. https://www.tesisenred.net/handle/10803/6839

Vermote, E., Tanzé, D., Deuzé, J. L., Herman, M., Morcrette, J. J., & Kotchenova, S. Y. (2006). Second simulation of a satellite signal in the solar spectrum – vector (6SV). 6S user guide version 3, part 1, pp: 55. https://ltdri.org/files/6S/6S_Manual_Part_1.pdf

Visa, A., Valkealahti, K., & Simula, O. (1991). Cloud detection based on texture segmentation by neural network methods. IEEE International Joint Conference on Neural Networks, Vol. 2, 170529, 1001-1006. https://ieeexplore.ieee.org/abstract/document/170529

Wang, S., Deng, C., Liu, X., Li, Z., Feng, F., & Zhao, B. (2017). Cloud-cover assessment: From spectral properties to spatial domain natural scene statistic. IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Fort Worth, TX, USA, 5034-5037. https://ieeexplore.ieee.org/document/8128134

Xu, H. (2014). Modelo físico de la corrección atmosférica en las imágenes de satélite. Tesis de licenciado en Física, Universidad Nacional Mayor de San Marcos. Facultad de Ciencias Físicas, Lima. pp: 161. https://cybertesis.unmsm.edu.pe/handle/20.500.12672/9848

Xu, G. C. (2007). GPS theory, algorithms and applications. Berlin, Heidelberg: Springer. pp: 340. https://nguyenduyliemgis.files.wordpress.com/2014/09/gps-theory-algorithms-and-applications-2007.pdf

Yu, F., He, Z., & Xu, N. (2019). Autonomous navigation for GPS using inter-satellite ranging and relative direction measurements. ELSEVIRE, Acta Astronautica, Vol. 160, 646-655. https://www.sciencedirect.com/science/article/abs/pii/S0094576518315212?via%3Dihub

Zhang, C. L., Li, Q., Shen, Y. P., Zhou, N., Wang, X. S., Li J., & Jia, W. R. (2018). Monitoring of Aeolian desertification on the Qinghai – Tibet plateau from the 1970s to 2015 using Landsat images. ELSEVIRE, Vol. 619-620, 1648-1659. https://www.sciencedirect.com/science/article/abs/pii/S0048969717328474?via%3Dihub

Zhang, W. X., Liu, W. K., & Gong, X. Y. (2011). Influence of groud station number and its geographical distribution on combined orbit determination of navigation satellite. ELSEVIRE, SciVerse ScienceDirect, Vol. 10, 2058-2066.

Zhang, Y. C., Rossow, W. B., Lacis, A. A., Oinas, V., & Mishchenko, M. I. (2004). Calculation of radiative fluxes from the surface to top of atmosphere based on ISCCP and other global data sets: Refinements of the radiative transfer model and the input data. Journal of Geophysical Research, Vol. 109, pp: 27. https://agupubs.onlinelibrary.wiley.com/doi/10.1029/2003JD004457

Zhu, Z., & Woodcock, C. E. (2014). Automated cloud, cloud shadow, and snow detection in multitemporal Landsat data: An algorithm designed specifically for monitoring land cover change. ELSEVIRE, Remote Sensing of Environment, Vol. 152, 217-234. https://www.sciencedirect.com/science/article/abs/pii/S0034425714002259?via%3Dihub

Anexos

Anexo I

A-I. Derivación de la ecuación de excentricidad

En general se utilizan seis elementos de la órbita reportados en los boletines de la órbita, el cálculo se muestra es lo siguiente (Curtis, 2005):

1. Calculo de la distancia (A.1):

$$r = \sqrt{\vec{r} \cdot \vec{r}} = \sqrt{X^2 + Y^2 + Z^2} \quad . \tag{A.1}$$

2. Calculo de la velocidad (A.2):

$$v = \sqrt{\vec{v} \cdot \vec{v}} = \sqrt{v_X^2 + v_Y^2 + v_Z^2} \quad . \tag{A.2}$$

3. Calculo de la velocidad radial (A.3):

$$v_r = \frac{\vec{r} \cdot \vec{v}}{r} = \frac{Xv_X + Yv_Y + Zv_Z}{r} \quad . \tag{A.3}$$

4. Calculo del momento angular especifico (A.4):

$$\vec{h} = \vec{r} \times \vec{v} = \begin{vmatrix} \hat{I} & \hat{J} & \hat{K} \\ X & Y & Z \\ v_X & v_Y & v_Z \end{vmatrix} \quad . \tag{A.4}$$

5. Calculo de la magnitud del momento angular especifico (2.22):

$$h = \sqrt{\vec{h} \cdot \vec{h}} = \sqrt{h_X^2 + h_Y^2 + h_Z^2} \quad . \tag{A.5}$$

6. Calculo de la inclinación (A.6):

$$i = \cos^{-1}\left(\frac{h_Z}{h}\right), \qquad 0° < i < 180° \; . \tag{A.6}$$

7. Calculo del línea de nodo (A.7):

$$\vec{N} = \hat{K} \times \vec{h} = \begin{vmatrix} \hat{I} & \hat{J} & \hat{K} \\ 0 & 0 & 1 \\ h_X & h_Y & h_Z \end{vmatrix} \quad . \tag{A.7}$$

8. Calculo de la magnitud de $\vec{N}$ (A.8):

$$N = \sqrt{\vec{N} \cdot \vec{N}} = \sqrt{N_X^2 + N_Y^2 + N_Z^2} \quad . \tag{A.8}$$

9. Calculo de la longitud del nodo ascendente (A.9):

$$\Omega = \cos^{-1}\left(\frac{N_X}{N}\right) = \begin{cases} \cos^{-1}\left(\frac{N_X}{N}\right) & (N_Y \geq 0) \\ 360° - \cos^{-1}\left(\frac{N_X}{N}\right) & (N_Y < 0) \end{cases} \; . \tag{A.9}$$

Por otro lado, de la ecu. (2.17) podemos obtener la ecu. (A.10):

$$\ddot{\vec{r}} \times \vec{h} = -\frac{\mu}{r^3} \vec{r} \times \vec{h} \quad , \tag{A.10}$$

como $\frac{d}{dt}(\dot{\vec{r}} \times \vec{h}) = \ddot{\vec{r}} \times \vec{h} + \dot{\vec{r}} \times \dot{\vec{h}}$, la ecu. (A.1) se expresa a la ecu. (A.11):

$$\ddot{\vec{r}} \times \vec{h} = \frac{d}{dt}(\dot{\vec{r}} \times \vec{h}) - \dot{\vec{r}} \times \dot{\vec{h}} = \frac{d}{dt}(\dot{\vec{r}} \times \vec{h}) \quad , \tag{A.11}$$

ya que el momento angular $\vec{h}$ es constante. Por otro lado, vemos la ecu. (A.12):

$$\begin{aligned} &\text{como:} && r \cdot r = r^2 \quad , \\ &\text{entonces:} && \frac{d}{dt}(\vec{r} \cdot \vec{r}) = 2r\frac{dr}{dt} \quad , \\ &\text{sin embargo:} && \frac{d}{dt}(\vec{r} \cdot \vec{r}) = \vec{r} \cdot \frac{d\vec{r}}{dt} + \frac{d\vec{r}}{dt} \cdot \vec{r} = 2\vec{r}\frac{d\vec{r}}{dt} \quad , \\ &\text{entonces} && : \vec{r} \cdot \dot{\vec{r}} = r\dot{r} \quad , \end{aligned} \tag{A.12}$$

entonces, la parte derecha de la ecu. (A.10) se puede transformar con la secuencia siguiente expresada en la ecu. (A.13):

$$\begin{aligned}
\frac{1}{r^3}\,\vec{r}\times\vec{h} &= \frac{1}{r^3}\left[\vec{r}\times(\vec{r}\times\dot{\vec{r}})\right], \qquad \text{de la ecu.(2.21)} \\
&= \frac{1}{r^3}\left[\vec{r}\cdot(\vec{r}\cdot\dot{\vec{r}}) - \dot{\vec{r}}\cdot(\vec{r}\cdot\vec{r})\right], \text{ regla de BAC} - \text{CAB} \\
&= \frac{1}{r^3}\left[\vec{r}(r\dot{r}) - \dot{\vec{r}}r^2\right], \qquad \text{de la ecu.(2.30)} \\
&= \frac{\vec{r}\dot{r} - \dot{\vec{r}}r}{r^2},
\end{aligned} \tag{A.13}$$

como, $\frac{d}{dt}(\frac{\vec{r}}{r}) = \frac{\dot{\vec{r}}r - \vec{r}\dot{r}}{r^2} = -\frac{\vec{r}\dot{r} - \dot{\vec{r}}r}{r^2}$ entonces se tiene (A.14):

$$\frac{1}{r^3}\,\vec{r}\times\vec{h} = -\frac{d}{dt}(\frac{\vec{r}}{r}) \quad , \tag{A.14}$$

sustituyendo las ecuaciones (A.11) y (A.14) en la ecu. (A.1) se tiene (A.15):

$$\begin{aligned}
&\frac{d}{dt}(\dot{\vec{r}}\times\vec{h}) = \frac{d}{dt}(\mu\frac{\vec{r}}{r}) \quad , \\
&\text{equivalente a:} \quad \frac{d}{dt}(\dot{\vec{r}}\times\vec{h} - \mu\frac{\vec{r}}{r}) = 0 \quad , \\
&\text{es decir:} \quad \dot{\vec{r}}\times\vec{h} - \mu\frac{\vec{r}}{r} = \vec{C} \quad ,
\end{aligned} \tag{A.15}$$

donde, el vector $\vec{C}$ es una constante arbitraria, tomando el producto escalar de ambos lados con el vector $\vec{h}$ se obtiene la ecu. (A.16):

$$(\dot{\vec{r}}\times\vec{h})\cdot\vec{h} - \mu\frac{\vec{r}\cdot\vec{h}}{r} = \vec{C}\cdot\vec{h} \quad , \tag{A.16}$$

dado que el $\dot{\vec{r}}\times\vec{h}$ es perpendicular tanto a $\dot{\vec{r}}$ como a $\vec{h}$, $(\dot{\vec{r}}\times\vec{h})\cdot\vec{h} = 0$. De forma similar, dado que $\vec{h} = \vec{r}\times\dot{\vec{r}}$, que es perpendicular a $\dot{\vec{r}}$ y $\vec{r}$, por lo tanto, $\dot{\vec{r}}\cdot\vec{h} = 0$, y se obtiene que $\vec{C}\cdot\vec{h} = 0$, es decir, $\vec{C}$ es perpendicular a $\vec{h}$ que es normal al plano orbital, esto

significa que $\vec{C}$ debe estar en el plano orbital. Reescribiendo la (A.15) se obtiene la (A.17):

$$\frac{\vec{r}}{r} + e = \frac{\dot{\vec{r}} \times \vec{h}}{\mu} \quad , \quad \text{con } e = \frac{\vec{C}}{\mu} \tag{A.17}$$

10. Calculo del vector de excentricidad $\vec{e}$ a partir de la ecuación (A17) del Anexo-I se obtiene (A.18):

$$\begin{aligned} e &= \frac{1}{\mu}\left[\vec{v} \times \vec{h} - \mu\frac{\vec{r}}{r}\right] \\ &= \frac{1}{\mu}\left[\vec{v} \times (\vec{r} \times \vec{v}) - \mu\frac{\vec{r}}{r}\right] \\ &= \frac{1}{\mu}\left[\vec{r}v^2 - \vec{v}(\vec{r} \cdot \vec{v}) - \mu\frac{\vec{r}}{r}\right] \\ &= \frac{1}{\mu}\left[(v^2 - \frac{\mu}{r})\vec{r} - rv_r\vec{v}\right] \end{aligned} \quad . \tag{A.18}$$

11. Calculo de la excentricidad e se expresa por (A.19):

$$e = \sqrt{\vec{e} \cdot \vec{e}} = \frac{1}{\mu}\sqrt{(2\mu - rv^2)rv_r^2 + (\mu - rv^2)^2} \quad , \tag{A.19}$$

12. Calculo del argumento de perigeo se expresa por (A.20):

$$\omega = \begin{cases} \cos^{-1}(\dfrac{\vec{N} \cdot \vec{e}}{Ne}) \end{cases} \quad , \tag{A.20}$$

si $\vec{N} \cdot \vec{e} > 0$, ω se encuentra en el primer o cuarto cuadrante, si $\vec{N} \cdot \vec{e} < 0$, ω se encuentra en el segundo o tercer cuadrante. Para colocar ω en el cuadrante adecuado, observe que el perigeo se encuentra por encima del plano ecuatorial ($0° \le \omega \le 180°$) si $\vec{e}$ apunta hacia arriba (en dirección Z positiva, $e_Z \ge 0$), y el perigeo se encuentra por debajo del plano ($180° \le \omega \le 360°$) si $\vec{e}$ apunta en dirección Z negativa $e_Z \le 0$, como se expresa en (A.22):

$$\omega = \begin{cases} \cos^{-1}(\dfrac{\vec{N} \cdot \vec{e}}{Ne}) & (e_Z \ge 0) \\ 360° - \cos^{-1}(\dfrac{\vec{N} \cdot \vec{e}}{Ne}) & (e_Z < 0) \end{cases} \quad . \tag{A.21}$$

13. Calculo de la anomalía verdadera se expresa en la ec. (A.22):

$$\theta = \cos^{-1}\left(\frac{\vec{e}\cdot\vec{r}}{er}\right) \quad , \tag{A.22}$$

si $\vec{e}\cdot\vec{r} > 0$, θ se encuentra en el primer o cuarto cuadrante, si $\vec{e}\cdot\vec{r} < 0$, θ en el segundo o tercer cuadrante. Para colocar θ en el cuadrante adecuado, tenga en cuenta que si el satélite se aleja del perigeo ($\vec{r}\cdot\vec{v} \geq 0$), entonces $0° \leq \theta \leq 180°$, mientras que si el satélite se acerca al perigeo ($\vec{r}\cdot\vec{v} < 0$), entonces $180° \leq \theta \leq 360°$), esto se expresa en la ec. (A.23):

$$\theta = \begin{cases} \cos^{-1}\left(\frac{\vec{e}\cdot\vec{r}}{er}\right) = \cos^{-1}\left(\frac{1}{e}\left(\frac{h^2}{\mu r} - 1\right)\right) & (v_r \geq 0) \\ 360° - \cos^{-1}\left(\frac{\vec{e}\cdot\vec{r}}{er}\right) = 360° - \cos^{-1}\left(\frac{1}{e}\left(\frac{h^2}{\mu r} - 1\right)\right) & (v_r < 0) \end{cases} . \tag{A.23}$$

Como es bien sabido, no se dispone de datos de telemetría continua sobre los vectores de la posición ni de la velocidad, sino, los calculamos inversamente a partir de los elementos orbitales para construir la órbita.

Anexo II

A-II. Código IDL para generar las series y tendencias con prueba de Mann-Kendall

```
pro Serie_tendencia_NDVI_MK

factor_tendencia = 120; decadal

; datos de entrada: ".csv"
serie = 'D:\avhrr data\NDVI\NDVI_mensual\por
mes\climatologia_mensual\m_1992_2018\sierra.csv'

; datos de salida: ".ps"
outname = 'D:\avhrr data\NDVI\NDVI_mensual\por
mes\climatologia_mensual\m_1992_2018\sierra.ps'

data = read_csv(serie,HEADER=SedHeader)

costa_pimentel_chimbote=reform(data.FIELD1)


STDDEV_costa_pimentel_chimbote=reform(data.FIELD2)


mcosta_pimentel_chimbote=costa_pimentel_chimbote


STDDEV_costa_pimentel_chimbote=STDDEV_costa_pimentel_chimbote

high_error_costa_pimentel_chimbote = (costa_pimentel_chimbote +
reform(STDDEV_costa_pimentel_chimbote)*.3) < 1
low_error_costa_pimentel_chimbote = (costa_pimentel_chimbote -
reform(STDDEV_costa_pimentel_chimbote)*.3) > (0)

years=(findgen(456)/456)*(2020-1982)+1982 ; (2020-1982)*12 = 456

years=YEARS[0:n_elements(years)-9] ; quitando los 8 meses del 2019

  vector=findgen(448) ; son 448 meses en total
  des=N_ELEMENTS(vector)
  c=fltarr(des)
  xx=(vector-mean(vector))^2.

  ajuste1=linfit(vector,mcosta_pimentel_chimbote, yfit=cc)
  res2=(mcosta_pimentel_chimbote-cc)^2.
  SE_costa_pimentel_chimbote=((1/(des-2.))*(total(res2)/total(xx)))^0.5; error estandar de la
pendiente
  p1=mks(mcosta_pimentel_chimbote)
```

```
  tendencia1=ajuste1[1]*factor_tendencia

  recta1=ajuste1[1]*vector+ajuste1[0]


 PS_Start, outname

k = 5
DEVICE, DECOMPOSED = 1

cgDisplay, /FREE, XSIZE=3000, YSIZE=800
DEVICE, SET_FONT='Helvetica' ,/TT_FONT
; !P.Multi = [0, 1, 6, 0, 1]

bad = where(mcosta_pimentel_chimbote eq 0.)
mcosta_pimentel_chimbote[bad] = !VALUES.F_NAN


rango=mcosta_pimentel_chimbote[where((mcosta_pimentel_chimbote ge
0.)and(mcosta_pimentel_chimbote le 1))]

    cgPlot, years, mcosta_pimentel_chimbote, Color='black', YRange=[min(rango)-
0.05,max(rango)+.05], xRange=[1981.5,2019.5],YStyle=1,xstyle=3,$
    font=0 ,thick=2,ytitle=' ',xTICKINTERVAL=2, yminor=1, xminor=1,CHARSIZE=0.8,
/nodata

    cgColorFill, [years, Reverse(years), years[0]], $
     [high_error_costa_pimentel_chimbote, Reverse(low_error_costa_pimentel_chimbote),
high_error_costa_pimentel_chimbote[0]],$
    Color="gray",/window

    cgoPlot, years, mcosta_pimentel_chimbote, Color="red", thick=5

    cgoplot, years, recta1, Color=cgcolor('blue'), thick=8

  void2 = ANSI_Value('década')

cgtext,0.15, 0.82-0.02,font=1, CHARSIZE=1.5,/Normal, Color=cgcolor('blue'),$
 'tendencia=('+ StrTrim(String(tendencia1, FORMAT='(F8.2)'),2)+' $\+-$ '+
StrTrim(String(SE_costa_pimentel_chimbote*factor_tendencia, FORMAT='(F8.2)'),2)+')
'+'por '+void2
 cgtext,0.15,0.82-0.02-0.08,font=1, CHARSIZE=1.5,/Normal, Color=cgcolor('blue'), 'p-
valor='+ StrTrim(String(p1, FORMAT='(F8.3)'),2)+'
PS_End, /jpeg, RESIZE=150,density=400

end

; Funcion de MK
```

```
function mks,x,undef=undef ; la function MK

 ;The non parametric mann-kendall (mk) statistics to determine if there
 ;is (or not) a signifcant trend . The slope is calculated
 ;by using the Sen's method(s). S is robust and less affected by
 ;outliers (Sen p.k. 1968, ASAJ).
 ;
 ;ex1. sl=mkstrend(x,undef=-999.). x: ts. ex: x=[0.5, 0.1, 0.2, 0.1, 0.3], (dt=1)
 ;                          no slope = -999.
 ;
 ;20070225  Created by RNJ @ Georgia Tech
 ;20070307  Paola Arias @ Georgia Tech completed Vn (Eq. 2.6  Sen P.K. 1968, ASAJ).
 ;20080917  RNJ @ Tulane University. The trend and the p-val (two-sides) on your screen.
 ;
 ; This software is provided "as-is", without any express or
 ; implied warranty. The author WILL NOT BE
 ; resposable for any damage arising from its use.
 ;
 ; If you find bugs and have the solutions please contac me: rjuarez@tulane.edu


 If Total(Finite(x,/nan)) Eq 0 Then Begin
  print,Total(Finite(x,/nan))

  x=Float(x)
  nx=N_Elements(x)
  nx1=nx-1.
  n=nx*(nx-1)/2.  ; The number of elements in d
  d=FltArr(n)
  m=0.

  For i=0,nx1-1 Do Begin
   For j=i+1,nx-1 Do Begin
    d(m)=x(j)-x(i)
    m=m+1
   Endfor
  Endfor

  For i=0L,n-1 Do Begin
   If d(i) LT 0. Then d(i)=-1.
   If d(i) EQ 0. Then d(i)= 0.
   If d(i) GT 0. Then d(i)= 1.
  EndFor

  s=total(d)

  U=x(uniq(x(sort(x))))
  Corr=0.      ;Correction for tied observations (equal value)

  For y=0,N_Elements(U)-1 Do Begin
```

```
    find=Where(x eq U(y))
    uj=N_Elements(find)
    Corr=Corr+uj*(uj-1)*(2*uj+5)
  EndFor

  Vs=(nx*(nx-1.)*(2*nx+5.)-Corr)/18.   ;For long series it is necessary to use the whole eq.
2.6 (Corr) (Sen p.k. 1968, ASAJ)

  If s GT 0. Then z=(s-1)/sqrt(Vs)
  If s LT 0. Then z=(s+1)/sqrt(Vs)
  If s EQ 0. Then z=0.

  ;   nor=gauss_cvf(0.025)  ;nor=1.96;  ;Prob at 95% (two-side)
  ;   nor=gauss_cvf(0.04)

  ;The slope
  Sn=fltarr(n)
  m=0.
  For i=0,nx1-1 Do Begin
    For j=i+1,nx-1 Do Begin
      Sn(m)=(x(i)-x(j))/(i-j)
      m=m+1
    EndFor
  EndFor

  Snsorted=Sn(sort(Sn))
  m=float(fix(n/2.))
  pval=2*(1.-GAUSS_PDF(abs(z)))  ; (two-side)
  ;   If abs(z) LT nor Then Begin
  ;     slope=undef
  ;   Endif Else Begin
  If 2*m    Eq n Then slope=0.5*(Snsorted(m)+Snsorted(m+1))
  If 2*m+1. Eq n Then slope=Snsorted(m+1)
  ;   EndElse
 Endif Else Begin
   Print, 'There are missing values"
   slope=undef
 EndElse
 mksres=[pval]
 Return, mksres
End
```

Anexo III

A-III. Código IDL para el preprocesamiento AVHRR

```
pro preprocesamiento_avhrr
  COMPILE_OPT idl2

; definir las carpetas de los datos
  carpeta = 'C:\trabajo\AVHRR\'
  carpeta_datos = carpeta + '\Datos\'
  cd, carpeta_datos
  lista = FILE_SEARCH('*.{WI,SF,GC}') ; las extensiones utilizados (tres estaciones de recepción)
  for i = 0, n_elements(lista)-1 do begin
    print,lista[i]

    ; extraer la fecha de cada imagen
    year='20'+strmid(lista[i],13,2)
    day=strmid(lista[i],15,3)
    hora=strmid(lista[i],20,4)

    ; convertir las fechas a días del año
    CALDAT, JULDAY(1, day, year), mes, dia
    if mes lt 10 then mes = '0'+string(mes,format='(I1)')
    if mes ge 10 then mes = string(mes,format='(I2)')
    if dia lt 10 then dia = '0'+string(dia,format='(I1)')
    if dia ge 10 then dia = string(dia,format='(I2)')
    dataname=string(year, Format='(I4)')+mes+dia+'_'+hora+'_'+strmid(lista[i],9,2)

; definir nombre de las imágenes de salida
    toa_img     = carpeta+'Toa_'+dataname+'.img'  ;reflectancia TOA + tb
    geo_toa_img = carpeta+'Geo_toa_'+dataname+'.img' ; geo de toa_img
    ref_img     = carpeta+'Ref_'+dataname+'.img'  ;reflectancia + tb
    geo_ref_img = carpeta+'Geo_ref_'+dataname+'.img' ; geo de ref_img
```

```
; extraer los datos DN
   envi_open_data_file, carpeta_datos + lista[i], r_fid=avhrrfid, /avhrr

   envi_file_query, avhrrfid, ns=ns, nl=nl, nb=nb,dims=dims

 ; Calibración radiométrica con la función envi_avhrr_calibrate_doit, aquí se considera el
ángulo cenit del Sol
   envi_doit, 'envi_avhrr_calibrate_doit', $
     fid=avhrrfid, dims=dims, pos=[0,1,2,3,4], $
     out_name=toa_img, /correct_solarz, $
     ;    /calc_sst, method=0, $
     r_fid=fid_rad

; crear la proyección geográfica
     envi_file_query, fid_rad, ns=ns, nl=nl, nb=nb
     dims = [-1l, 0, ns-1, 0, nl-1]
     units = envi_proj_units_translate('Degrees')
     proj = envi_proj_create(/geographic, unit=units)
     ps = [.01,.01]

; corrección geométrica de los canales
     envi_doit, 'envi_avhrr_warp_doit', fid=fid_rad, $
       avhrr_fid=avhrrfid, dims=dims, pos=[0,1,2,3,4], $
       out_name=geo_toa_img, method=6, /zero_edge, $
       background=0, grid=[50,50], proj=proj, $
       pixel_size=ps, R_FID= FID_rad_temp;,/IN_MEMORY

; crear el archivo cabecero para cada imagen
geo_toa_hdr=strmid(geo_toa_img,0, strpos(geo_toa_img,'.',/REVERSE_SEARCH))+'.hdr'
openr,lun,geo_toa_hdr,/get_lun
lines=''
waveflag=0.
waves=''
n_cols=0
```

```
while (~eof(lun)) do begin
  readf,lun,lines
  if (lines.indexof('samples') gt -1) then begin
    samples = lines.split('=')
    n_cols = fix(samples[1])
  endif
  if ((lines.indexof('wavelength = {') gt -1) and waveflag eq 0) then begin
    waveflag = 1
    continue
  endif
  if (waveflag eq 1) then begin
    waves = waves + lines
  endif
endwhile
free_lun,lun
x=float(strsplit(waves, ',', /extract))
if x[2] eq 3.74 then begin
  escena_img = carpeta+'Escena_'+dataname+'_3b.img' ;banda 3b

; calibración de los canales 3-5 cuando el canal 3 corresponde a 3b
  envi_file_query, FID_rad_temp, dims=dims, nb=nb
  ref= fltarr(dims[2]+1,dims[4]+1,5)

;  extraer los datos de los canales 3-5
  ref[*,*,2] = ENVI_GET_DATA(fid=FID_rad_temp, dims=dims, pos=2)
  ref[*,*,3] = ENVI_GET_DATA(fid=FID_rad_temp, dims=dims, pos=3)
  ref[*,*,4] = ENVI_GET_DATA(fid=FID_rad_temp, dims=dims, pos=4)
  envi_file_mng,id = FID_rad_temp, /remove
  pos_ref = [0,1]
endif

; calibración de los canales 3-5 cuando el canal 3 corresponde a 3a
if x[2] eq 1.607 then begin
  escena_img = carpeta+'Escena_'+dataname+'_3a.img' ;banda 3a
```

```
  envi_file_query, FID_rad_temp, dims=dims, nb=nb
  ref= fltarr(dims[2]+1,dims[4]+1,5)
  ref[*,*,3] = ENVI_GET_DATA(fid=FID_rad_temp, dims=dims, pos=3)
  ref[*,*,4] = ENVI_GET_DATA(fid=FID_rad_temp, dims=dims, pos=4)
  envi_file_mng,id = FID_rad_temp, /remove
  pos_ref = [0,1,2]
endif
    envi_file_query, fid_rad, dims=dims, nb=nb
    data = ENVI_GET_DATA(fid=fid_rad, dims=dims, pos=[0,1,2,3,4])

   ; Corrección atmosférica usando la función envi_quac_doit
    if min(data) ne 0. then begin
    envi_doit, 'envi_quac_doit', $
      fid=fid_rad, pos=pos, dims=dims, $
      quac_sensor='Generic / Unknown Sensor', $
      out_name=ref_img, r_fid=fid_quac

; liberar espacio en memoria RAM
    envi_file_mng,id = fid_rad, /remove

; crear proyección para estos canales calibrados atmosfericamente
    envi_file_query, fid_quac, ns=ns, nl=nl, nb=nb
    dims = [-1l, 0, ns-1, 0, nl-1]
    units = envi_proj_units_translate('Degrees')
    proj = envi_proj_create(/geographic, unit=units)
    ps = [.01,.01]
; corrección geométrica para estos últimos canales
    envi_doit, 'envi_avhrr_warp_doit', fid=fid_quac, $
      avhrr_fid=avhrrfid, dims=dims, pos=pos_ref, $
      out_name=geo_ref_img, method=6, /zero_edge, $
      background=0, grid=[50,50], proj=proj, $
      pixel_size=ps,r_fid=fid_quac_cali;,/IN_MEMORY
     envi_file_query, fid_quac_cali, dims=dims, nb=nb
; se divide a los canales por 10 mil.
```

```
    num_bands_ref = n_elements(pos_ref)
    for j = 0, num_bands_ref-1 do begin
      ref[*,*,j] = ENVI_GET_DATA(fid=fid_quac_cali, dims=dims, pos=j)
      ref[*,*,j] = float(ref[*,*,j])/10000.
    Endfor

; agregar map_info
    map_info = ENVI_GET_MAP_INFO(fid=fid_quac_cali)

; guarder las imagines con map_info definido
envi_write_envi_file,ref,out_name=escena_img,map_info=map_info,data_type=4,SENSOR_
TYPE =27, /NO_OPEN

; eliminar los productos intermediarios
     envi_file_mng,id = fid_quac, /remove
     envi_file_mng,id = avhrrfid, /remove
     envi_file_mng,id = fid_quac_cali, /remove

 ; los archivos generados con Ref, Geo_toa, Geo_ref, Toa, son los datos intermediarios. Lo
pueden elimiar para liberar espacio en disco de la computadora.
  vector_elimi=['Ref*','Toa*','Geo_toa*','Geo_ref*']
  endif else begin

    envi_file_mng,id = fid_rad, /remove
   vector_elimi=['Toa*','Geo_toa*']
   cd,carpeta
   for n_datos = 0, n_elements(vector_elimi)-1 do begin
     ;  print,vector_elimi[n_datos]
     lista_elimi=findfile(vector_elimi[n_datos])
     ;  print,lista_elimi
     for neli = 0, n_elements(lista_elimi)-1 do begin
       file_delete, carpeta+lista_elimi[neli]
     endfor
   endfor
```

```
  endelse
  endfor
  tmp = dialog_Message('Fin!',/information)
end
```

Anexo IV

A-IV. Código IDL para el redimensionado

```
pro redimensionado_avhrr

; carpeta de los datos
carpeta = 'C:\trabajo\AVHRR\'
vartmp = read_tiff(carpeta + 'Area_Peru.tif', geotiff = geotags) ; imagen de referencia

; dimensión de la imagen de referencia
nc=(size(vartmp))[2]
nf=(size(vartmp))[3]

; definir los límites estándares
LONini0 = -82.0d
LATini0 =  0.5d
LONfin0 = -68.0d
LATfin0 = -19.0d
 cd, carpeta
 lista = findfile('Escena*_cal.tif')

; Extraer los límites de cada imagen.
 for n  = 0, n_elements(lista)-1 do begin
   filename= carpeta+lista[n]
   outname=strmid(lista[n],0, strpos(lista[n],'.',/REVERSE_SEARCH))+'_res.tif'
   data = read_tiff(carpeta+lista[n], geotiff = geotags1)
   res    = (geotags1.MODELPIXELSCALETAG)[0]
   LATini = (geotags1.MODELTIEPOINTTAG)[4]
   LONini = (geotags1.MODELTIEPOINTTAG)[3]
   n_cols = (size(data))[2]
   n_fils = (size(data))[3]
   LONfin=LONini+n_cols*res
   LATfin=LATini-n_fils*res
```

```
; los cinco canales
 c1=reform(data[0,*,*])
 c2=reform(data[1,*,*])
 c3=reform(data[2,*,*])
 c4=reform(data[3,*,*])
 c5=reform(data[4,*,*])
 zuo=round(abs(lonini-lonini0)/res) ; N° pixeles en parte izquierda
 shang=round(abs(latini-latini0)/res) ; N° pixeles en parte superior
 you=round(abs(lonfin-lonfin0)/res) ; N° pixeles en parte derecha
 xia=round(abs(latfin-latfin0)/res) ; N° pixeles en parte inferior

; si la diferencia de N° pixeles en el límite superior es menor que 1 pixel, entonces:
 if shang le 1 then begin
  print,"Limite superior correcto !  "
 endif else begin
  if round((latini-latini0)/res) gt 1 then begin
   print,"Limite superior se mueve hacia al sur !  "
   c1=c1[*,round(abs(latini-latini0)/res):(size(c1))[2]-1]
   c2=c2[*,round(abs(latini-latini0)/res):(size(c2))[2]-1]
   c3=c3[*,round(abs(latini-latini0)/res):(size(c3))[2]-1]
   c4=c4[*,round(abs(latini-latini0)/res):(size(c4))[2]-1]
   c5=c5[*,round(abs(latini-latini0)/res):(size(c5))[2]-1]    endif
  if round((latini-latini0)/res) lt -1 then begin
   print,"Limite superior se mueve hacia al norte !  "
   c1=[[fltarr((size(c1))[1],round(abs(latini-latini0)/res))],[c1]]
   c2=[[fltarr((size(c2))[1],round(abs(latini-latini0)/res))],[c2]]
   c3=[[fltarr((size(c3))[1],round(abs(latini-latini0)/res))],[c3]]
   c4=[[fltarr((size(c4))[1],round(abs(latini-latini0)/res))],[c4]]
   c5=[[fltarr((size(c5))[1],round(abs(latini-latini0)/res))],[c5]]
  endif
 endelse

; si la diferencia de N° pixeles en el límite inferior es menor que 1 pixel, entonces:
```

```
if xia le 1 then begin
  print,"Limite inferior correcto !  "
endif else begin
  if round((latfin-latfin0)/res) gt 1 then begin
    print,"Limite inferior se mueve hacia al sur !  "
    c1=[[c1],[fltarr((size(c1))[1],round(abs(latfin-latfin0)/res))]]
    c2=[[c2],[fltarr((size(c2))[1],round(abs(latfin-latfin0)/res))]]
    c3=[[c3],[fltarr((size(c3))[1],round(abs(latfin-latfin0)/res))]]
    c4=[[c4],[fltarr((size(c4))[1],round(abs(latfin-latfin0)/res))]]
    c5=[[c5],[fltarr((size(c5))[1],round(abs(latfin-latfin0)/res))]]
  endif
  if round((latfin-latfin0)/res) lt -2 then begin
    print,"Limite inferior se mueve hacia al norte !  "
    c1=c1[*,0:(size(c1))[2]-round(abs(latfin-latfin0)/res)]
    c2=c2[*,0:(size(c2))[2]-round(abs(latfin-latfin0)/res)]
    c3=c3[*,0:(size(c3))[2]-round(abs(latfin-latfin0)/res)]
    c4=c4[*,0:(size(c4))[2]-round(abs(latfin-latfin0)/res)]
    c5=c5[*,0:(size(c5))[2]-round(abs(latfin-latfin0)/res)]
  endif
endelse

; si la diferencia de N° pixeles en el límite oeste es menor que 1 pixel, entonces:
if zuo le 1 then begin
  print,"Limite izquierdo correcto !  "
endif else begin
  if round((lonini-lonini0)/res) gt 1 then begin
    print,"Limite izquierdo se mueve hacia al oeste !  "
    c1=[fltarr(round(abs(lonini-lonini0)/res),(size(c1))[2]),c1]
    c2=[fltarr(round(abs(lonini-lonini0)/res),(size(c2))[2]),c2]
    c3=[fltarr(round(abs(lonini-lonini0)/res),(size(c3))[2]),c3]
    c4=[fltarr(round(abs(lonini-lonini0)/res),(size(c4))[2]),c4]
    c5=[fltarr(round(abs(lonini-lonini0)/res),(size(c5))[2]),c5]
  endif
```

```
  if round((lonini-lonini0)/res) lt -1 then begin
    print,"Limite izquierdo se mueve hacia al este !  "
    c1=c1[round(abs(lonini-lonini0)/res)-1:(size(c1))[1]-1,*]
    c2=c2[round(abs(lonini-lonini0)/res)-1:(size(c2))[1]-1,*]
    c3=c3[round(abs(lonini-lonini0)/res)-1:(size(c3))[1]-1,*]
    c4=c4[round(abs(lonini-lonini0)/res)-1:(size(c4))[1]-1,*]
    c5=c5[round(abs(lonini-lonini0)/res)-1:(size(c5))[1]-1,*]
  endif
 endelse

; si la diferencia de N° pixeles en el límite este es menor que 1 pixel, entonces:
 if you le 1 then begin
   print,"Limite derecha correcto !  "
 endif else begin
   if round((lonfin-lonfin0)/res) gt 1 then begin
     print,"Limite derecha se mueve hacia al oeste !  "
     c1=c1[0:(size(c1))[1]-1-round(abs(lonfin-lonfin0)/res),*]
     c2=c2[0:(size(c2))[1]-1-round(abs(lonfin-lonfin0)/res),*]
     c3=c3[0:(size(c3))[1]-1-round(abs(lonfin-lonfin0)/res),*]
     c4=c4[0:(size(c4))[1]-1-round(abs(lonfin-lonfin0)/res),*]
     c5=c5[0:(size(c5))[1]-1-round(abs(lonfin-lonfin0)/res),*]
   endif
   if round((lonfin-lonfin0)/res) lt -2 then begin
     print,"Limite derecha se mueve hacia al este !  "
     c1=[c1,fltarr(round(abs(lonfin-lonfin0)/res),(size(c1))[2])]
     c2=[c2,fltarr(round(abs(lonfin-lonfin0)/res),(size(c2))[2])]
     c3=[c3,fltarr(round(abs(lonfin-lonfin0)/res),(size(c3))[2])]
     c4=[c4,fltarr(round(abs(lonfin-lonfin0)/res),(size(c4))[2])]
     c5=[c5,fltarr(round(abs(lonfin-lonfin0)/res),(size(c5))[2])]
   endif
 endelse
 c1 = congrid(c1,nc,nf)
 c2 = congrid(c2,nc,nf)
```

```
  c3 = congrid(c3,nc,nf)
  c4 = congrid(c4,nc,nf)
  c5 = congrid(c5,nc,nf)
  c1[where(c1 eq -10.)] = 0.
  c2[where(c2 eq -10.)] = 0.
  c3[where(c3 eq -10.)] = 0.
  c4[where(c4 eq -10.)] = 0.
  c5[where(c5 eq -10.)] = 0.
  datos=fltarr(5,(size(c1))[1],(size(c1))[2])
  datos[0,*,*]=c1
  datos[1,*,*]=c2
  datos[2,*,*]=c3
  datos[3,*,*]=c4
  datos[4,*,*]=c5
  file_delete, filename
  write_tiff, outname, datos, /float,geotiff = geotags
endfor
end
```