

Detección de posibles zonas desertificadas usando serie y mapa de tendencia del NDVI estimado por sensor AVHRR de satélites NOAA (1982-2019)

 Han Xu^{*1,2} y Joel Rojas²

¹Instituto del Mar del Perú, Lima, Perú

²Universidad Nacional Mayor de San Marcos, Facultad de Ciencias Físicas, Lima, Perú

Recibido 23 Oct 2023 – Aceptado 20 Jul 2024 – Publicado 02 Ago 2024

Resumen

En este trabajo reportamos la detección de posibles zonas de desertificación a través de la serie y mapa de tendencia del NDVI y VCI del sensor AVHRR de la serie de satélites NOAA para el periodo de 1982 a 2019. Los datos utilizados fueron adquiridos del portal de CLASS/NOAA, de nivel 1b, tienen una resolución espacial de 1 km y temporal de 12 horas. Se ha desarrollado algoritmos de procesamiento para estimar el NDVI y VCI mensual. Se identificaron siete posibles zonas de desertificación elaborando series y mapas de tendencia decadal del VCI, en las cuales, cinco zonas se localizaron en la región costera, específicamente en los límites de zonas agrícolas, donde, las zonas de mayor tendencia decadal negativa fueron Piura (-0.29 dec^{-1}), Chiclayo (-0.36 dec^{-1}) y Chicama (-0.27 dec^{-1}) durante el periodo de 1997 a 2006 mientras que, en la región selva, la mayor tendencia negativa se registró en Huetupehu, distrito de Madre de Dios con valor de -0.25 dec^{-1} en el periodo de 2007 a 2018. 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 Huetupehu fueron por la expansión urbana.

Palabras clave: AVHRR, NDVI, VCI, tendencia, desertificación.

Detection of possible desertified areas using series and trend map of NDVI estimated by AVHRR sensor from NOAA satellites (1982-2019)

Abstract

In this research we report the detection of possible desertification zones through the series and trend map of NDVI and VCI from the AVHRR sensor of the NOAA satellite series for the period from 1982 to 2019. The data used were acquired from the CLASS/NOAA portal, level 1b, have a spatial resolution of 1 km and temporal resolution of 12 hours. Processing algorithms were developed to estimate monthly NDVI and VCI. Seven possible desertification zones were identified by elaborating series and decadal trend maps of the VCI, in which five zones were located in the coastal region, specifically in the limits of agricultural zones, where the zones with the highest negative decadal trend were Piura (-0.29 dec^{-1}), Chiclayo (-0.36 dec^{-1}) and Chicama (-0.27 dec^{-1}) during the period from 1997 to 2006 while, in the jungle region, the highest negative trend was recorded in Huetupehu, district of Madre de Dios with a value of -0.25 dec^{-1} in the period from 2007 to 2018. It is proposed that, among the possible desertified areas, the areas in the coastal region (Piura, Chiclayo, Chicama, Pisco and Majes) were generated by intensive agriculture while, the possible desertification of the areas of Pucallpa and Huetupehu were generated by urban expansion.

Keywords: AVHRR, NDVI, VCI, trend, desertification.

*hxu@imarpe.gob.pe

© Los autores. Este es un artículo de acceso abierto, distribuido bajo los términos de la licencia Creative Commons Atribución 4.0 Internacional (CC BY 4.0) que permite el uso, distribución y reproducción en cualquier medio, siempre que la obra original sea debidamente citada de su fuente original.



1. Introducción

La desertificación es un proceso de degradación del suelo causado por las variaciones climáticas ó 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 [1] y 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 [2].

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 [3]. Desde el decenio de 1970, la desertificación ha sido monitoreada mediante técnica de sensoramiento remoto [4]. 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 [5], [6], [7]. Los datos del sensor AVHRR (*Advanced Very High Resolution Radiometer*) de la serie de satélites NOAA (*National Oceanic and Atmospheric Administration*) han sido demostrado que es capaz de monitorear la dinámica del cambio de cobertura vegetal a escala global [8]. 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. En nivel global, en el año 1997, IGBP completó la primera colección de los datos del NDVI de 1km de resolución espacial a nivel global [9]. Asimismo, en las regiones de Canadá, norte de Estados Unidos, Groenlandia y Patagonia han construido la información histórica del NDVI del AVHRR/NOAA para su territorio nacional correspondiente [10], [11]. 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 [12].

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 [13], en la cual, los datos fueron obtenidos de distintas fuentes como IMARPE (Instituto del Mar del Perú), 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 y la 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 [14]. A partir del 2012, se relacionaba los índices de vegetación con la sequía y la desertificación en las investigaciones [15], [16], [17], [18], [19].

En este trabajo, se utilizó la metodología del procesamiento de los datos de nivel 1b de AVHRR para estimar los índices del NDVI y VCI (*Vegetation Condition Index*) mensual [20], [21], y el uso de la técnica de tendencia para la detección de posibles zonas de desertificación para el periodo de 1982 a 2019 [22].

1.1. Fundamento teórico

La calibración radiométrica para los canales 1, 2 y 3a del AVHRR consiste en establecer una relación lineal entre $\frac{\pi I}{F}$, el factor de reflectancia de la esfera de integración en laboratorio y la señal digital C del sensor AVHRR [23]:

$$\frac{\pi I}{F} = a + bC \quad (1)$$

donde, I es la radiancia de la esfera de integración ($Wm^{-2}sr^{-1}$) y F es la irradiancia espectral del Sol extraterrestre ($Wm^{-2}sr^{-1}$), C está representada por el número de recuentos. En la calibración de los canales 3b, 4 y 5 se utilizan la relación no lineal entre la radiancia y el conteo gráfico:

$$N_E = a_0 + a_1 C_E + a_2 C_E^2 \quad (2)$$

donde, N_E es la radiancia espectral cuya unidad es $mW/(m^2 sr cm^{-1})$, C_E es el número digital en 10 bits. a_0 , a_1 y a_2 son coeficientes de calibración para cada canal térmico. La temperatura del cuerpo negro equivalente T_E está dada por la siguiente ecuación:

$$T_E = \frac{\frac{c_2 \nu_c}{\ln[1 + \frac{c_1 \nu_c^3}{N_E}]} - A}{B} \quad (3)$$

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 para cada canal [23].

El módulo de la corrección atmosférica QUAC (*Quick Atmospheric Correction*) del software ENVI fue utilizado para los canales 1 y 2 del AVHRR, y se basa en la ecuación de radiancia estándar:

$$\rho_{TOA}(\lambda) = A(\lambda) + \frac{B(\lambda)}{1 - S(\lambda) \cdot M\rho(\lambda)} \cdot \rho(\lambda) + \frac{C(\lambda)}{1 - S(\lambda) \cdot M\rho(\lambda)} \cdot M\rho(\lambda) \quad (4)$$

donde, ρ_{TOA} es la reflectancia espectral (radiancia normalizada por el componente normal de la superficie del flujo del Sol) registrada por el sensor; ρ es la reflectancia del objeto en la superficie; $M\rho$ 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 [24]. $A(\lambda)$: cantidad de radiación no reflejada por el objeto sin embargo es registrada por el sensor a través del scattering y absorción en la atmósfera; $B(\lambda)$: radiación del Sol reflejada por objeto en la superficie y registrada por sensor; $C(\lambda)$: cantidad de radiación reflejada por los objetos vecinos y registrada por sensor (Figura 1). 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 ó cuando la visibilidad es alta, la ec. (5) se reduce a la ec. (5):

$$\rho_{TOA}(\lambda) = A(\lambda) + B(\lambda) \cdot \rho(\lambda) + C(\lambda) \cdot M_\rho(\lambda) \quad (5)$$

donde, se considera que $1/B$ es la pendiente y $(A + M_\rho)$ como el intercepto, y la desviación estándar espectral, ρ_{TOA} se expresa por la ec. (6):

$$\sigma_{\rho_{TOA}}(\lambda) = B(\lambda) \cdot \sigma_{\rho}(\lambda) \quad (6)$$

El intercepto $(A(\lambda) + C(\lambda)M_\rho)$ no contribuye a la desviación estándar por ser una constante en mayoría de los casos, de lo contrario, el algoritmo dividirá la escena en partes más pequeñas hasta que se cumplen los supuestos, es decir, se considera como un desplazamiento común para todos los píxeles de la imagen. En el módulo QUAC/ENVI, la pendiente $1/B$ está dado por la ec. (7):

$$\frac{1}{B} = \frac{\langle \rho_{end} \rangle_{lib}}{\langle (\rho_{TOA} - C(\lambda)\rho_{promedio}) \rangle_{end}} \quad (7)$$

donde, $\langle \rho_{end} \rangle_{lib}$ es el promedio de la reflectancia espectral de píxeles que representan un sólo objeto y cuyas firmas han sido registrados en la librería espectral del modelo, $\langle (\rho_{TOA} - C(\lambda)\rho_{promedio}) \rangle_{end}$ es el promedio de la reflectancia de los subpíxeles observado por el sensor. En la navegación del satélite, el vector de posición del satélite en la órbita consiste en resolver la ecuación de Kepler:

$$M_e = E - e \sin E \quad (8)$$

donde, M_e es la anomalía media, E es la anomalía excéntrica y e es la excentricidad, los parámetros orbitales son obtenidos mediante boletines de la órbita. Generalmente se utiliza el método de Newton para resolver la ecuación:

$$E_{i+1} = E_i - \frac{E_i - e \sin E_i - M_e}{1 - e \cos E_i} \quad (9)$$

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 [25]. Cuando se determina el vector de posición del satélite en la órbita, se lo transforma al sistema coordenado de la Tierra.

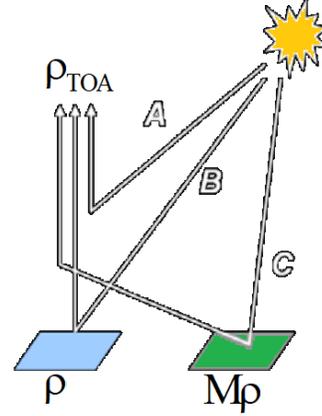


Figura 1: Los tres caminos de la radiación del Sol (adaptado de [24]).

Pearson y Miller observaron la diferencia de firmas espectrales de los suelos seco, húmedo y pasto luego propusieron el Índice RVI (*Ratio Vegetation Index*) para cuantificar estado de crecimiento de la vegetación [26] y se expresa por la ec.(10):

$$RVI = \frac{Ref_{NIR}}{Ref_{RED}} \quad (10)$$

donde, y Ref_{NIR} y Ref_{RED} son reflectancias correspondientes a los canales 2 y 1 respectivamente para el sensor AVHRR. Para la vegetación verde densa, a medida que la Ref_{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 [27]. En el 1974, Rouse propuso una fórmula para normalizar el RVI que denomina el NDVI [20] expresada por la ec.(11):

$$NDVI = \frac{RVI - 1}{RVI + 1} = \frac{Ref_{NIR} - Ref_{RED}}{Ref_{NIR} + Ref_{RED}} \quad (11)$$

El VCI (*Vegetation Condition Index*) fue propuesto por Kogan [21] que normaliza el NDVI del i-ésimo mes en la serie histórica del mismo mes como se expresa en ec. (12):

$$VCI_{i,j} = \frac{NDVI_{i,j} - NDVI_{i,min}}{NDVI_{i,max} - NDVI_{i,min}} \quad (12)$$

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 AVHRR ha sido ampliamente aceptado por su idoneidad para evaluar una serie de parámetros de estimación de índices de vegetación [28].

La prueba no paramétrica de MK (Mann y Kendall) determina si había una tendencia positiva o negativa de

la serie del NDVI para el periodo de estudio con su significación estadística [29], [30]. El estadístico S de prueba de MK se expresa por la ecuación (13):

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^n f(NDVI_j - NDVI_i) \quad (13)$$

donde, n es el número de meses del NDVI, $NDVI_j$ 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 ecuación (14):

$$f(NDVI_j - NDVI_i) = \begin{cases} +1, & \text{si } : NDVI_j - NDVI_i > 0 \\ 0, & \text{si } : NDVI_j - NDVI_i = 0 \\ -1, & \text{si } : NDVI_j - NDVI_i < 0 \end{cases} \quad (14)$$

Para una serie de n meses, se determinarán un total de $\frac{n(n-1)}{2}$ valores de la función de signo, si $n \leq 10$, el valor de S se encuentra en la tabla de probabilidad para MK [31] y cuya relación con el estadístico Z:

$$Z = \frac{S}{\frac{n(n-1)}{2}} \quad (15)$$

En caso general ($n > 10$), se calcula la varianza de S:

$$Var(S) = \frac{1}{18} [n(n-1)(2n+5) - \sum_{i=1}^m t_i(t_i-1)(2t_i+5)] \quad (16)$$

donde, m es número de grupos con valores idénticos, t_i es número de valores iguales en el i-ésimo grupo, si los valores no se repiten en el grupo, 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 ecuación (17):

$$Z_S = \begin{cases} \frac{S-1}{\sqrt{Var(S)}}, & \text{si } : S > 0 \\ 0, & \text{si } : S = 0 \\ \frac{S-1}{\sqrt{Var(S)}}, & \text{si } : S < 0 \end{cases} \quad (17)$$

Los valores positivos de Z_S indican las tendencias positivas, mientras los valores negativos evidencian las tendencias negativas.

1.2. 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 (Figura 2).

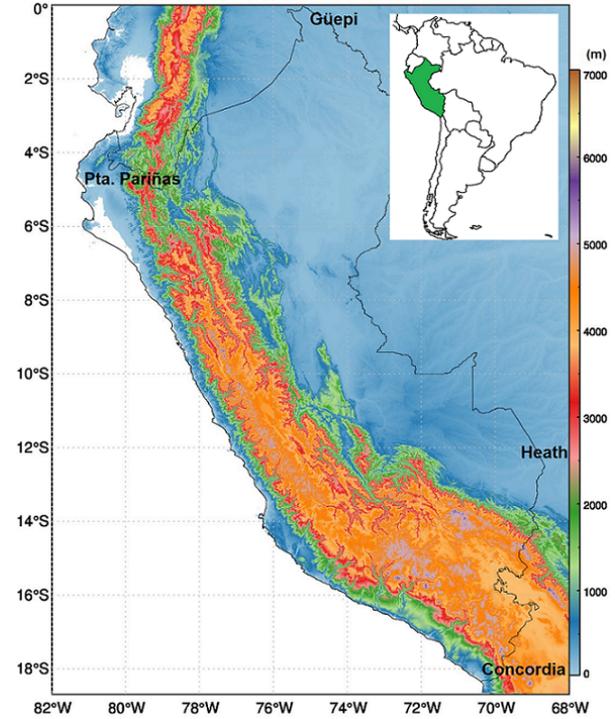


Figura 2: Área de estudio: Perú-América Sur. La imagen muestra el modelo de elevación digital del Perú con sus alturas, costeras, andinas y amazonia empleando el modelo Etopo 2022 de 15° de arcosegundos de resolución espacial. (Fuente: <https://www.ncei.noaa.gov/maps/grid-extract/>).

2. Materiales y métodos

2.1. Datos utilizados

Se recolectaron 15988 imágenes de los sensores AVHRR/2 y /3 a bordo de la serie de satélites NOAA para el periodo de estudio (Figura 3). La mayor parte de datos utilizados en este trabajo provienen de los satélites NOAA-09, -11, -14, -16, -18 y -19 que tienen mayor estabilidad y consistencia entre ellos. La estructura de los datos del AVHRR/3 contienen tres partes: ARS (Archive Retrieval System) en ascii, 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; Header Record tiene un tamaño de 15872 bytes y registra el tiempo de barrido y los parámetros orbitales del satélite; Data Record tiene un tamaño de 15872 x N bytes (N =

número de filas de la matriz de datos, número de columnas = 2048) que registran los datos crudos en formato binario de 10 bits entre los bytes 1265 y 14928 como se muestra en la Figura 4 [32].

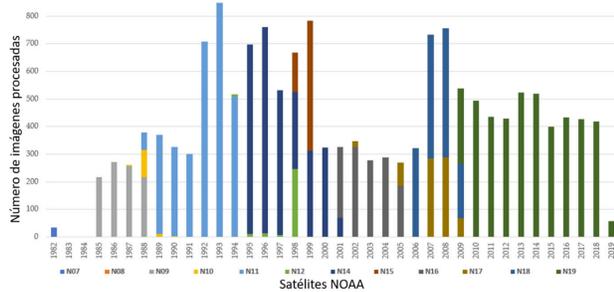


Figura 3: Número de imágenes utilizadas por año y por satélite.

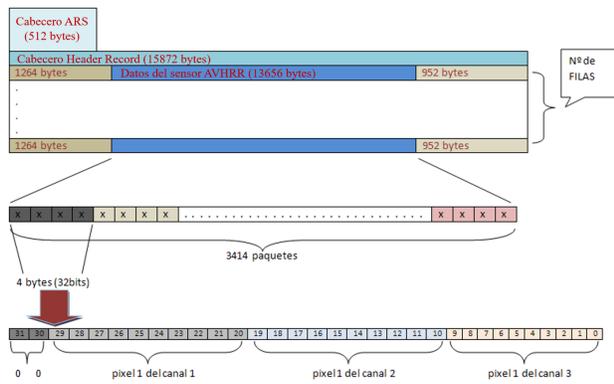


Figura 4: Estructura de un archivo LAC del sensor AVHRR/3 (adaptado de Goodrum) [33].

2.2. Metodología

La Figura 5 muestra el diagrama de flujo del procesamiento del AVHRR, donde, se realizó el cálculo de reflectancia de un pixel como ejemplo (Tabla 1), donde, los coeficientes de calibración están almacenados en archivo cabecero, para los canales 1, 2 y 3a tenemos dos coeficientes (a, b) para cada uno como se muestra en la ec. (1), y de las ecs. (2) y (3) observamos que son seis coeficientes (a_0, a_1, a_2, ν_c, A y B) que participan el cálculo de los canales 3b, 4 y 5 los coeficientes son 3. El cálculo final muestra resultados obtenidos usando el lenguaje de programación IDL y el software ENVI (celdas en color oscuro), se obtuvo los mismos valores (% Reflectancia) para los canales 1 y 2, y una ligera diferencia de temperatura (en grados Kelvin) en los canales 4 y 5 (en grados Kelvin), para el canal 3b, la diferencia fue de tres grados Kelvin.

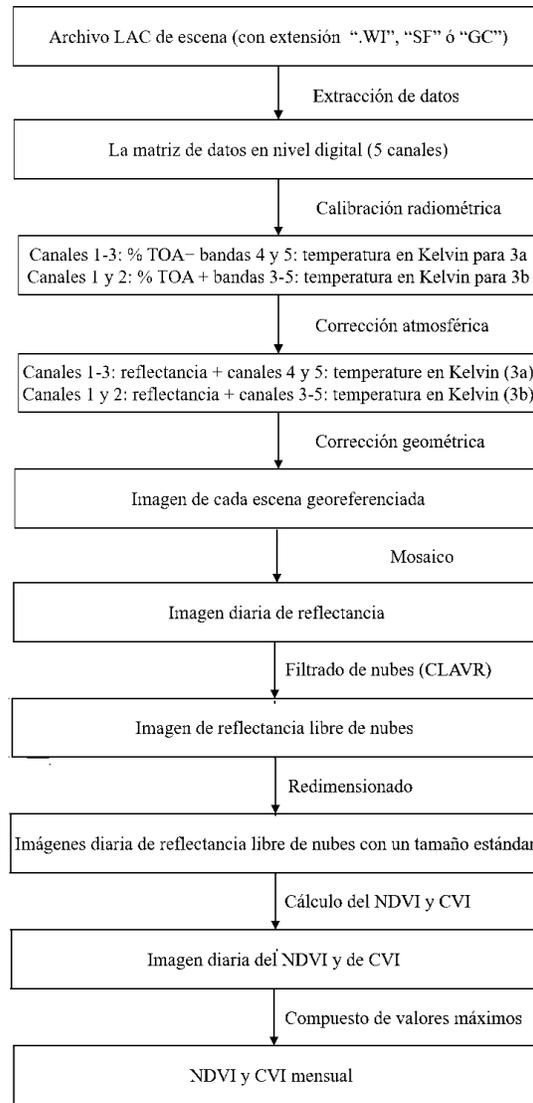


Figura 5: Diagrama de dispersión de temperatura estimada por IDL y ENVI.

Se realizó diagramas de dispersión para estos tres canales eligiendo un área de 50 x 50 pixeles de suelo (Figura 6a), mar (Figura 6b) y nubes (Figura 6c). Se observó una relación lineal de temperatura estimada por ambos métodos con muy alta correlación para cada canal espectral, donde los puntos se aproximan a la línea de identidad. Así mismo, la variación de temperatura distinta para los tipos de pixel, para el suelo, la temperatura de un área de 2500 km² varía de 289 a 311K, para el mar, esta variación es mínima en el mar (290~296K) y máxima en las nubes (215~302K).

Se calcularán y ordenarán los NDVI mensual para el periodo de enero del 1982 a abril del 2019 en orden de tiempo. Se calculará la serie de tiempo y su tendencia

Datos de entrada		Cálculo								Cálculo final	
Canal	DN	Coeficientes de calibración								% Reflectancia	
1	DN	Si DN > 497.5				Si DN ≤ 497.5				IDL	ENVI
		a	b	a	b						
	165	-2.118	0.05448	-55.25	0.1607				6.8712	6.8712	
2	133	Si DN > 500.3				Si DN ≤ 500.3				6.01007	6.01007
		a	b	a	b						
		-2.474	0.06379	-65.6	0.19						
	C_E	a_0	a_1	a_2	N_E	ν_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	

Tabla 1: Ejemplo del cálculo de un mismo pixel para cada canal espectral.

para los pixeles que tienen la idéntica posición de cada imagen mensual, los resultados se mostrarán en forma de mapa y de serie. Como se ilustra en la Figura 7, se obtuvo una serie de tendencia de -0.02 por década con un p-valor de 0.000, que representa una tendencia decreciente estadísticamente significativa durante el periodo de estudio. Por otro lado, se observa que no existe información disponible entre los periodos de 1982-1985, 1991 y 1995 debido a algunas fallas de los satélites correspondientes (NOAA-7, -8 y -13).

3. Resultados y discusión

La serie de tiempo del NDVI mensual del Perú y de las tres regiones de costa, sierra y selva muestran un patrón similar con una tendencia decadal ligeramente positiva (Figura 8). Para todo el litoral (Figura 8a), se observa que, el incremento del DNVi fue de manera progresiva en 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, la serie se muestra una periodicidad más notable que en otros dos periodos, el mismo comportamiento también se ilustra en la región de selva (Figura 8d), la cual representa un mayor rango de variación (+0.2 a +0.8 por década) del NDVI y un mayor incremento (+0.14 dec⁻¹).

El menor incremento (+0.05 dec⁻¹) fue registrado en la región de costa (Figura 8b), y en sierra se muestra claramente la variabilidad periódica durante toda la serie (Figura 8c). Se obtuvo un error no mayor a ±0.01 para las series consolidando las tendencias positivas para el periodo de estudio. La Figura 9a muestra el promedio del NDVI 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).

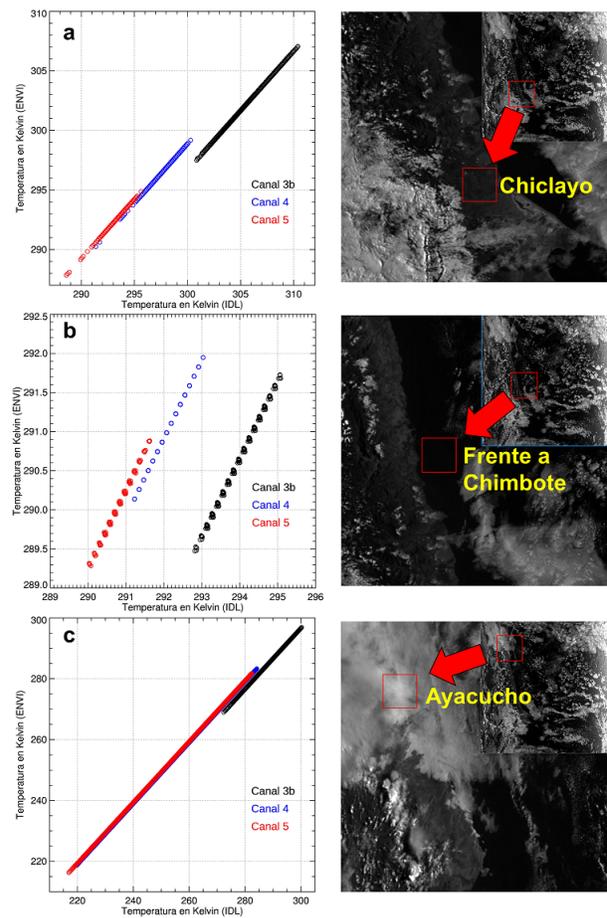


Figura 6: Diagrama de dispersión de temperatura estimada por IDL y ENVI.

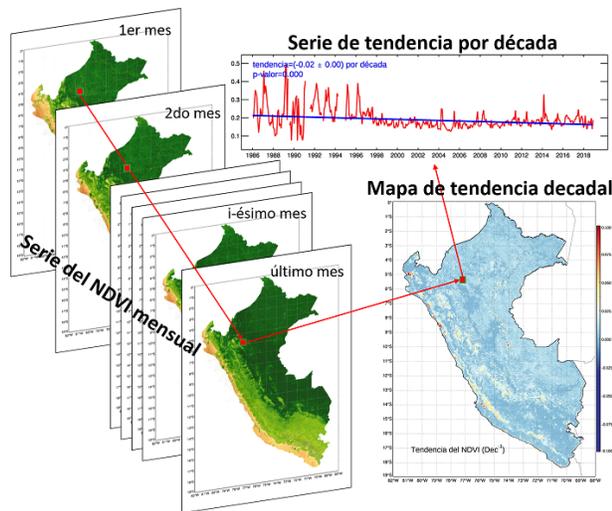


Figura 7: Secuencia del cálculo de la tendencia del NDVI.

La Figura 9b muestra la desviación estándar del NDVI estimada para el mismo periodo, y Figura 9c, mapa de ecorregiones, elaborado por Brack [33], al comparar ambas figuras, se observó las regiones con alta desviación han sido 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 [14].

En el mapa de tendencia del NDVI (Figura 10a), las zonas de color blanco son aquellos pixeles que no presentan ninguna tendencia significativa estadísticamente a través de la prueba de Mann-Kendall. Se registraron tendencias ligeramente positivas ($+0.05 \text{ dec}^{-1}$) en la mayoría del territorio, específicamente, en la selva alta y puna ($+0.1 \text{ dec}^{-1}$), mientras que, las tendencias negativas fueron registrados en las zonas costeras y zonas de la selva como se presentó en color verde. De manera similar, se elaboró un mapa de tendencia del VCI (Figura 10b), en la cual se evidenció las mismas regiones de tendencias negativas: 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. Estas siete regiones fueron propuestas como posibles zonas de desertificación.

El área, la tendencia, el error y el p-valor de las posibles zonas desertificadas se describen en la Tabla 2, donde, la tendencia del NDVI no fue significativa en la zona de sur de ciudad de Piura, mientras que, la tendencia del VCI es significativo con valor negativo para la misma zona. En las zonas del distrito de Majes de Arequipa y Chicama se registraron mayores áreas con tendencias negativas de los índices de vegetación (244 y 218 km^2 respectivamente), mientras que en la ciudad de Pucallpa, la posible zona desertificada fue mucho menor (26 km^2).

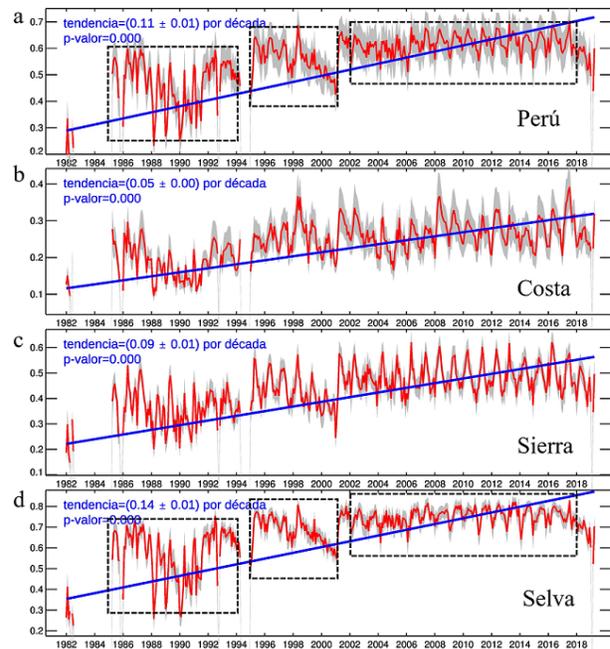


Figura 8: Serie de tiempo del NDVI mensual para todo el periodo de estudio.

Las zonas de Piura, Chiclayo, Chicama, Pisco y Majes se localizaron en los límites de zonas agrícolas, entre ellos, en las dos zona de mayor tendencia negativa (Chiclayo y Chicama) se registraron mayores áreas supuestamente afectadas por desertificación y se observó mayor área agrícola en ambas zonas, se concluye que, es posible que la desertificación está presentada como una consecuencia de la agricultura intensiva.

En las zonas de Pucallpa y Huepetuhe, la posible causa de la supuesta desertificación está relacionado más con la expansión urbana. 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.

En la Figura se muestran las tendencias por tres etapas: de 1986-1996, de 1997-2006 y de 2007-2018 (Figura 11). De 1986 a 1996, se registraron tendencias positivas del VCI en las zonas de Piura, Pisco, Pucallpa y Huepetuhe, donde los mayores valores fueron en la región de la selva con Pucallpa de $+0.11 \text{ dec}^{-1}$ y Huepetuhe de $+0.13 \text{ dec}^{-1}$, 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).

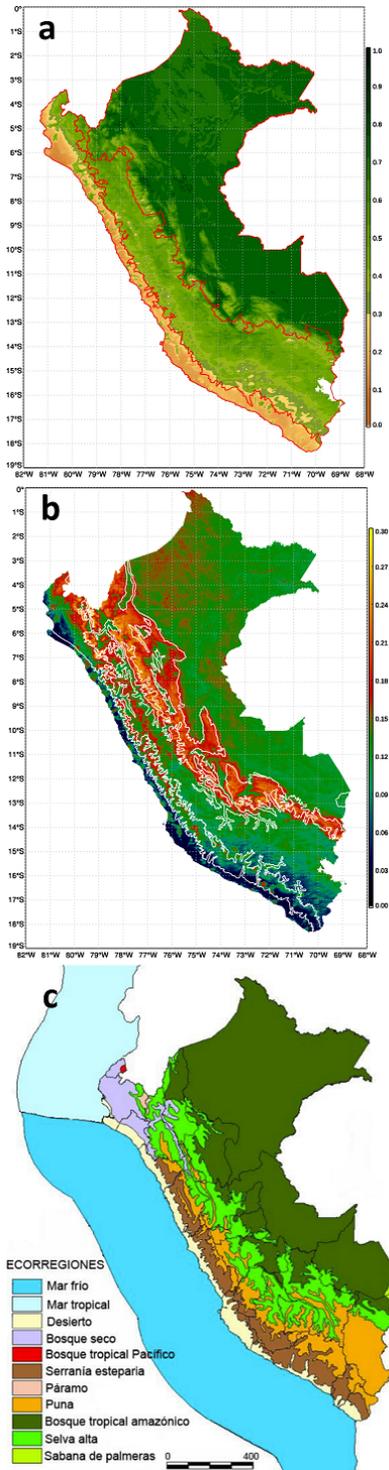


Figura 9: (a) NDVI/AVHRR promedio, (b) desviación estándar del NDVI/AVHRR para el periodo 1986-2018, (c) ecorregiones propuestas por Brack [33]. (Fuente: <https://www.geogpsperu.com>).

De 1997 a 2006, las tendencias fueron significativas excepto la zona Huetuque que tuvo una tendencia positiva de $+0.08 \text{ dec}^{-1}$ 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.

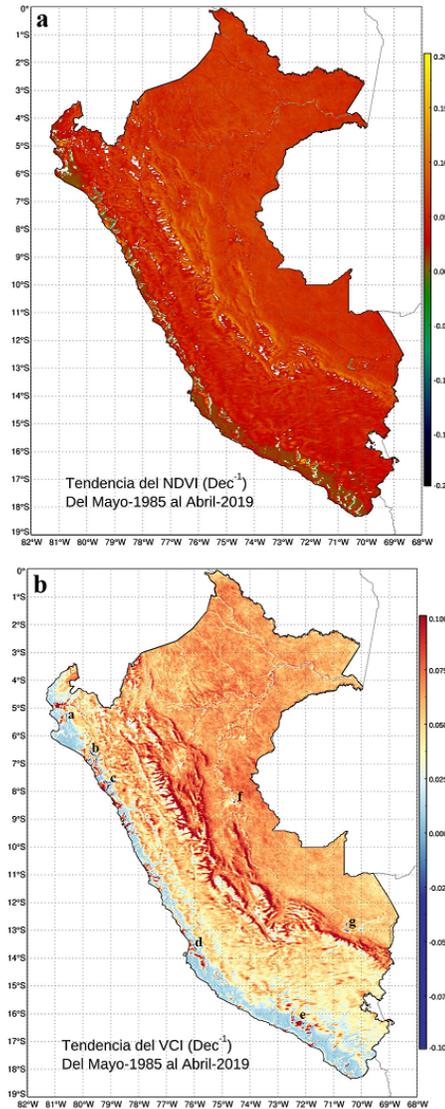


Figura 10: Mapa de tendencia del (a) NDVI (dec^{-1}), (b) del VCI (dec^{-1}) y (c) ecorregiones propuestas por Brack.

De 2007 a 2018, se registraron tendencias positivas en las zonas de la costa mostrando un ligero proceso de recuperación de área del NDVI, 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 Huetpetuhe, la tendencia alcanzó a -0.25 dec^{-1} . 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 $+0.08 \text{ dec}^{-1}$), los departamentos de la costa tienen tendencias no mayor a $+0.09 \text{ dec}^{-1}$ acepción de Arequipa y Moquegua ($+0.1 \text{ dec}^{-1}$). En las regiones de sierra y selva se registraron mayores tendencias positivas de $+0.1$ al $+0.12 \text{ dec}^{-1}$ (Figura 12).

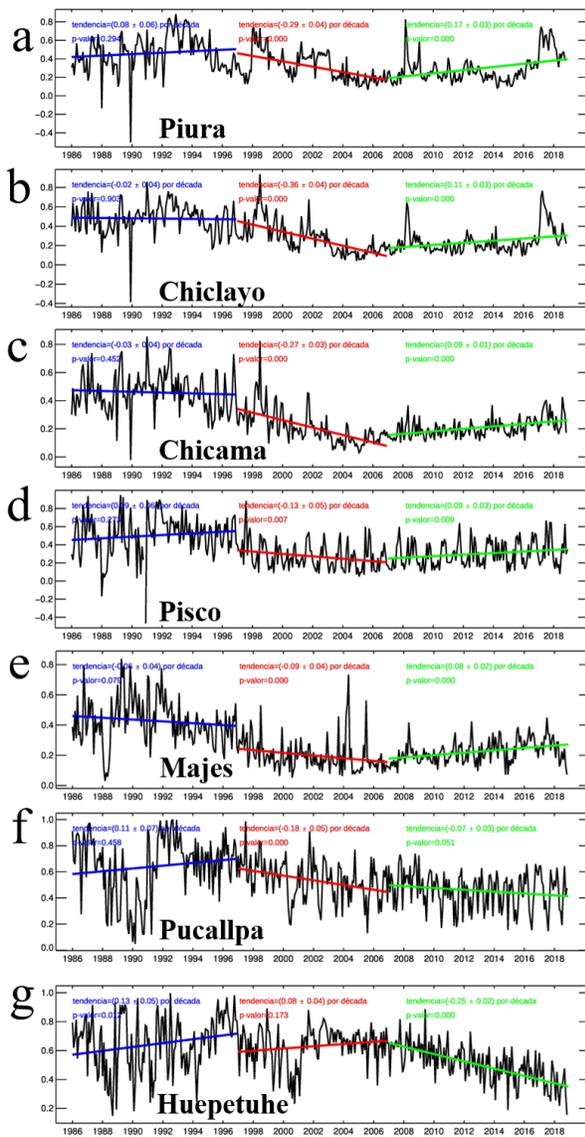


Figura 11: Serie de tendencia de las posibles zonas desérticas por periodos.

4. Conclusiones

El uso de las imágenes AVHRR nos permite monitorear el cambio de cobertura vegetal con un periodo de 37 años, lo cual es adecuado para estudiar la tendencia decadal de vegetación a escala regional.

De acuerdo de la serie mensual del NDVI, 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}).

En las regiones de selva alta, páramo, bosque tropical páncico, 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.

Las tendencias del NDVI y VCI nos permiten conocer el estado de vegetación de periodo más reciente con respecto a la serie histórica y pronosticar su comportamiento en los próximos meses. De acuerdo de la serie y el mapa de tendencia por departamentos, la región costa (de Tumbes a ICA) es de menor tendencia del VCI, en la cual, los departamentos de costa norte tienen valores mínimos de la tendencia (de $+0.07$ a $+0.08 \text{ dec}^{-1}$).

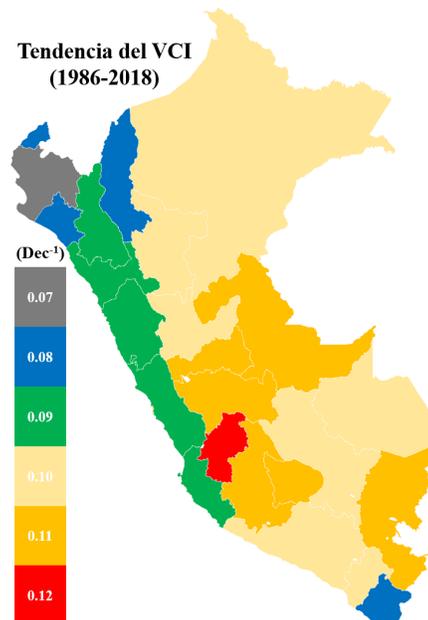


Figura 12: Mapa de tendencia por departamentos.

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.

Parámetro	Zonas	Área (km ²)	Tendencia	Error	p-valor (sig.)
NDVI (dec ⁻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 (dec ⁻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

Tabla 2: Área, tendencia, error y p-valor de los índices de NDVI y VCI para las zonas identificadas como posibles zonas de desertificación.

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 observa 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.

Referencias

- [1] MINAM. 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*, Lima-Perú. <https://repositoriodigital.minam.gob.pe/handle/123456789/200?show=full> (2011).
- [2] Naciones Unidas. Report of the United Nations Conference on Desertification. *Nairobi*, 29, pp. 139. <https://digitallibrary.un.org/record/733000> (1977).
- [3] P. Paylore and W. G. McGinnies. 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> (1969).
- [4] C. L. Zhang, Q. Li, Y. P. Shen, N. Zhou, X. S. Wang, J. Li and W. R. Jia. Monitoring of Aeolian desertification on the Qinghai - Tibet plateau from the 1970s to 2015 using Landsat images. *ELSEVIRE*, Vol. 619-620, 1648-1659 (2018), doi: <https://doi.org/10.1016/j.scitotenv.2017.10.137>.
- [5] J. P. Ormsby, B. J. Choudhury and M. Owe. Vegetation spatial variability and its effect on vegetation indices. *Int. J. of Remote Sensing*, 8:9, 1301-1306 (1987), doi: <https://doi.org/10.1080/01431168708954775>.
- [6] C. J. Tucker, H. E., Dregne and W. W. Newcomb. Expansion and contraction of the Sahara desert from 1980 to 1990. *Science*, Vol. 253, No. 5017, 299-301. <https://api.semanticscholar.org/CorpusID:2961273> (1991).
- [7] L. Hutchison. 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> (2004).

- [8] R. S. Defries and J. R. G. Townshend. NDVI – derived land cover classification at a global scale. *Int. J. of Remote Sensing*, 15:17, 3567-3586 (1994). <https://doi.org/10.1080/01431169408954345> .
- [9] D. Ehrlich, J. E. Estes and A. Singh. 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> (1994).
- [10] X. W. Chen, R. Tateishi and C. Y. Wang. Development of a 1-km landcover dataset of China using AVHRR data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54, 305-316 (1999), doi:[https://doi.org/10.1016/S0924-2716\(99\)00027-1](https://doi.org/10.1016/S0924-2716(99)00027-1).
- [11] F. M. A. Fontana, N. C. Coops, K. V. Khlopenkov, A. P. Trishchenko, M. Riffler and M. A. Wulder. 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> (2012).
- [12] J. J. Gaitán, D. Bran, G. Oliva, G., Ciari, V. Nakamatsu, J. Salomone, D. Ferrante, G. Buono, V. Massara, G. Humano, D. Celdrán, W. Opazo, and F. T. Maestre. 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> (2013).
- [13] J. Rojas, J. Eche, P. Tito, A. Lauro, O. Fashé, J. Casanova, A. Calle y A. Romo. Detección de la salinidad en los suelos de cultivos de algodón usando imágenes de satélite en la costa norte del Perú. *Rev. Inv. Fis.*, 3(1), 41-47. <https://revistasinvestigacion.unmsm.edu.pe/index.php/fisica/article/view/8613/7459> (2012).
- [14] J. Rojas, E. Rufasto, J. Eche and F. Carrillo. 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 Sensoriamento 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> (2009).
- [15] R. R. Badaracco. 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*, UNMSM, Lima - Perú. https://cybertesis.unmsm.edu.pe/bitstream/handle/20.500.12672/3071/Badaracco_mr.pdf?sequence=1&isAllowed=y (2012).
- [16] H. Xu. Modelo Físico de la corrección atmosférica en las imágenes de satélite. *Tesis de Licenciado en Física*, UNMSM, Lima -Perú. <https://cybertesis.unmsm.edu.pe/handle/20.500.12672/9848> (2014).
- [17] R. Soca. 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*, UNMSM, Lima - Perú. <https://cybertesis.unmsm.edu.pe/handle/20.500.12672/5968> (2015).
- [18] J. Aguilar. 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 – 2012. *Tesis de Maestría en Física mención Geofísica*, UNMSM, Lima -Perú. https://cybertesis.unmsm.edu.pe/bitstream/handle/20.500.12672/9989/Aguilar_lj.pdf?sequence=3&isAllowed=y (2015).
- [19] G. Carbajal. 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*, UNMSM, Lima - Perú. https://cybertesis.unmsm.edu.pe/bitstream/handle/20.500.12672/7235/Carbajal_dg.pdf?sequence=3&isAllowed=y (2017).
- [20] J. W. Rouse, R. H. Haas, J. A. Schell and D. W. Deering. 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> (1974).
- [21] F. N. Kogan. Application of vegetation index and brightness temperature for drought detection. *Adv. Space Res.*, Vol. 15, No. 11 pp: 91-100. <https://www.sciencedirect.com/science/article/abs/pii/02731179500079T?via%3Dihub> (1995).
- [22] H. Xu. Estimación del índice de vegetación procedente del sensor AVHRR transportado por la serie de satélites NOAA (1982-2012) y su aplicación como

- un indicador de la desertificación en el Perú. *Tesis de Maestría en Física mención Geofísica*, UNMSM, Lima -Perú. (En revisión) (2023).
- [23] P. Mittaz and R. Harris. 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 (2009).
- [24] L. S. Bernstein, S. M. Adler-Golden, R. L. Sundberg, R. Y. Levine, T. C. Perkins, A. Berk, A. J. Ratkowski, G. Felde and M. L. Hoke. 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> (2005).
- [25] H. D. Curtis. Orbital mechanics for engineering students. *Elsevier Butterworth-Heinemann*. (3th ed.), pp: 673 (2005), doi: <http://www.nssc.ac.cn/wxzygx/weixin/201607/P020160718380095698873.pdf>.
- [26] R. L. Pearson and L. D. Miller. 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 (1972).
- [27] R. D. Jackson and R. A. Huete. Interpreting vegetation indices. *Preventive Veterinary Medicine*, Vol. 11, 185-200. <https://www.sciencedirect.com/science/article/abs/pii/S0167587705800042> (1991).
- [28] D. Dutta, A. Kundu, N. R. Patel, S. K. Saha and A. R. Siddiqui. 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> (2015).
- [29] H. B. Mann. Nonparametric tests against trend. *Econometrica*, Vol. 18, Issue 1, pp: 53-63. http://danida.vnu.edu.vn/cpis/files/Refs/PCAs/Mann_1945_NONPARAMETRIC%20TESTS%20AGAINST%20TREND.pdf (1945).
- [30] M. G. Kendall. Rank correlation methods. *Griffin London*, (4th ed.) pp: 202. <https://www.abebooks.com/9780852641996/Rank-correlation-methods-Kendall-Maurice-0852641990/plp> (1970).
- [31] R. O. Gilbert. 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> (1987).
- [32] G. Goodrum, K. B. Kidwell and W. Winston. NOAA KLM user's guide, NASA. 1, pp: 182. <https://ww1.ncdc.noaa.gov/pub/data/satellite/publications/podguides/N-15%20thru%20N-19/pdf/> (2001).
- [33] A. Brack. Ecología de un país complejo, en gran geografía del Perú: naturaleza y hombre. *Edit. Manfer-Mejia Baca*, tomo II, 145-319, España. <https://civ.uap.edu.pe/cgi-bin/koha/opac-detail.pl?biblionumber=5218> (1986).