



Machine Learning para la Clasificación y Análisis de los Índices de Biomasa y su relación con el Cambio Climático, Desierto de Atacama

Machine Learning for the Classification and Analysis of Biomass Indices and their relationship with Climate Change, Atacama Desert

Santos Gómez^{1,2}; Edwin Pino-Vargas^{2*}; Germán Huayna²; Jorge Espinoza-Molina³; Karina Acosta-Caipa³; Fredy Cabrera-Olivera⁴

1 Universidad Nacional del Santa, Programa Doctoral Ingeniería Civil, Av. Pacífico 508, Nuevo Chimbote, Ancash, Perú.

2 Universidad Nacional Jorge Basadre Grohmann, Departamento Ingeniería Civil, Av. Miraflores s/n, Tacna, Perú.

3 Universidad Nacional Jorge Basadre Grohmann, Departamento Arquitectura, Av. Miraflores s/n, Tacna, Perú.

4 Universidad Nacional Jorge Basadre Grohmann, Departamento Ingeniería Geológica-Geotecnia, Av. Miraflores s/n, Tacna, Perú

*Autor corresponsal: epinov@unjbg.edu.pe (E. Pino-Vargas).

ID ORCID de los autores

S. Gómez: <https://orcid.org/0000-0001-8066-9908>

G. Huayna: <https://orcid.org/0000-0002-4518-1023>

K. Acosta: <http://orcid.org/0000-0003-1872-9062>

E. Pino: <http://orcid.org/0000-0001-7432-4364>

J. Espinoza: <https://orcid.org/0000-0003-2236-8335>

F. Cabrera: <https://orcid.org/0000-0003-1429-8728>

RESUMEN

En este trabajo usamos Machine Learning (Random Forest) como herramienta para clasificar la biomasa y calcular los índices de vegetación buscando identificar las características de la cobertura vegetal en la cabecera del desierto Atacama. Se busca establecer la correlación entre los índices de vegetación y la precipitación, a fin de conocer su confiabilidad sobre la climatología en esta región. Fue importante el análisis geoespacial basado en Google Earth Engine (GEE) y el procesamiento de imágenes Landsat 5 ETM y Landsat 8 OLI/TIRS, para el período 1985 - 2022, lo que permitió caracterizar el cambio climático. El NDVI, SAVI, GVI y RVI han sido probados y validados en sistemas áridos. El NDVI responde positivamente a la precipitación en temporada húmeda y en forma débil en la temporada de lluvias invernales. Se confirma que el NDVI alto corresponde al verano, después de una sequía prolongada. Hacia los años 2020 y 2022, se registra un aumento de cobertura vegetal en lugares de mayor temperatura, evidenciando cambio climático y reflejado en los índices de biomasa.

Palabras clave: Cambio climático; índices de biomasa; Desierto Atacama; Machine Learning.

ABSTRACT

In this work we use Machine Learning (Random Forest) as a tool to classify biomass and calculate vegetation indices seeking to identify the characteristics of the vegetation cover at the head of the Atacama Desert. The aim is to establish the correlation between vegetation indices and precipitation, in order to know their reliability on the climatology in this region. The geospatial analysis based on Google Earth Engine (GEE) and the processing of Landsat 5 ETM and Landsat 8 OLI/TIRS images was important, for the period 1985 - 2022, which made it possible to characterize climate change. The NDVI, SAVI, GVI and RVI have been tested and validated in arid systems. The NDVI responds positively to precipitation in the wet season and weakly in the winter rainy season. It is confirmed that the high NDVI corresponds to summer, after a prolonged drought. Towards the years 2020 and 2022, an increase in vegetation cover is recorded in places with higher temperatures, evidencing climate change and reflected in biomass indices.

Keywords: Climate change; biomass indices; Atacama Desert; Machine Learning.

Recibido: 22-11-2023.

Aceptado: 10-03-2024.



Esta obra está publicada bajo la licencia [CC BY 4.0](https://creativecommons.org/licenses/by/4.0/)

INTRODUCCIÓN

La población mundial creciente continuará afectando el medio ambiente generando grandes impactos en los ecosistemas, especialmente en las zonas costeras (Malanson & Alftine, 2016), las regiones áridas tienen un clima y un entorno ecológico frágil y sensible (Wang & Qin, 2017; Wardropper & Rissman, 2019; West et al., 2017; Zhang, 2000). Los ecosistemas terrestres áridos tienen una función muy importante en los procesos biofísicos al reflejar y absorber la radiación solar y mantener el equilibrio de los componentes atmosféricos (Bawden, 2017; Gaur & Squires, 2017b, 2017a; Sidahmed, 2017). El desierto de Atacama es uno de los principales desiertos hiperáridos del mundo (Stein et al., 2013). La región tiene un clima hiperárido, se encuentra en el extremo sur de Perú y norte de Chile, caracterizada por su extrema aridez (Pino-Vargas & Ascencios-Templo, 2021; Pino-Vargas & Huayna, 2022; Pino et al., 2018; Pino, 2019; Pino et al., 2019, 2020; Pino, 2021; Pino & Chávarri, 2022; Vera et al., 2021), esta se atribuye a su ubicación subtropical (Garreaud et al., 2003; Garreaud et al., 2010).

La inteligencia artificial (IA) y las tecnologías de comunicación de datos nos dan una amplia gama de oportunidades en la investigación científica (Kua et al., 2021; Pino-Vargas et al., 2022). Por su parte el Machine Learning (ML), es una disciplina del campo de la IA, que usando algoritmos permite identificar patrones en datos masivos y generar predicciones (Wiemken & Kelley, 2020; Zhang et al., 2019).

Se ha confirmado la utilidad de los índices de vegetación para expresar la variabilidad de esta en condiciones climáticas semiáridas (Bagherzadeh et al., 2020; Martínez & Labib, 2023). Utilizando los Índices de Vegetación por Diferencia Normalizada

(NDVI) e Índice de Vegetación Ajustado al Suelo (SAVI), es posible identificar el comportamiento temporal de la vegetación en las cuencas (Alves et al., 2019). Las tendencias interanuales de la vegetación a escala global se analizan utilizando imágenes satelitales e índices de vegetación en áreas desérticas (Kawabata et al., 2001). La cobertura vegetal, la disponibilidad de humedad de la superficie y la temperatura de la superficie radiante constituyen variables microclimáticas derivables de imágenes satelitales multiespectrales (Carlson & Arthur, 2000). El NDVI, representa con alta precisión la variabilidad temporal de la biomasa (Yang et al., 2024; Richards et al., 2023).

La información de los satélites Landsat y Sentinel se pueden usar para detectar cambios en el uso de la tierra y el agua (Xiang et al., 2023; Yang et al., 2024), asimismo, podemos evaluar los impactos potenciales del cambio climático mediante el estudio de la temperatura máxima promedio anual y la precipitación (Hashim et al., 2019). El acelerado desarrollo de los sistemas de detección remota, la mecatrónica, el análisis de big data y la IA ha revolucionado la ciencia al permitir una gestión de procesos más precisa, eficiente y rentable (Kakarla et al., 2022; Singh et al., 2022).

En este sentido, buscamos identificar el efecto de las condiciones climáticas cambiantes sobre los índices de vegetación, en la zona de estudio para el período 1985 a 2022; utilizando índices de vegetación como el NDVI y el SAVI. Asimismo, previo al cálculo de los índices de biomasa se busca realizar un proceso de clasificación de biomasa usando ML, específicamente el clasificador Random Forest (RF).

METODOLOGÍA

2.1. Descripción del área de estudio

La región de estudio, se encuentra ubicada al sur de Perú y norte de Chile (Figura 1), pertenece a la

cabecera del Desierto de Atacama, caracterizado como el más árido del mundo (Houston & Hartley, 2003; Ritter et al., 2019).




Figura 1. Mapa de ubicación de la zona de estudio.

La región andina corresponde al sector centro-oeste del Altiplano, en el que la precipitación acumulada anual es relativamente baja (300 – 700 mm/año) y la variabilidad temporal es muy marcada con períodos húmedos de diciembre a marzo y muy secos de abril a noviembre (Garreaud et al., 2003; Garreaud et al., 2010; Ritter et al., 2019). La región costera presenta un clima desértico; con precipitaciones anuales escasas y hasta nulas (Chucuya et al., 2022; Condori-Tintaya et al., 2022; Gomez-Tunque et al., 2023; Machaca-Pillaca et al., 2022; Pocco et al., 2023). El clima en la región costera de Tacna es templado, desértico y con amplitud térmica moderada (Condori-Tintaya et al., 2022). La media anual de temperatura máxima y mínima (periodo 1950-2019) es 23,6 °C y 12,7 °C, respectivamente (Chucuya et al., 2022).

2.2. Obtención y procesamiento de imágenes satelitales

Este trabajo se realizó utilizando imágenes multi-espectrales de los sensores ETM (Enhanced Thematic Mapper Plus) y OLI (Operational Land Imager), tienen una resolución espacial de 30 m. para espectros de onda corta visible e infrarroja, y una resolución temporal de 16 días (Alvino et al., 2020); se adquirieron del portal del USGS (Servicio Geológico de los Estados Unidos), específicamente de la plataforma Google Earth Engine, que combina un catálogo de varios petabytes de imágenes satelitales y conjuntos de datos geoespaciales con capacidades de análisis a escala planetaria y lo pone a disposición de científicos, investigadores y desarrolladores para detectar cambios, mapear tendencias y cuantificar diferencias en la superficie de la Tierra (Ariza et al., 2014; Nieto et al., 2019). La selección se realizó en base a la nubosidad y luego se estimaron los índices de vegetación utilizando imágenes hasta 10% de cobertura de nubes.

En este trabajo, se utilizó imágenes del repositorio GEE, LANDSAT LT05/C01/T1_SR y LC08/C01/T1_SR. A continuación, se evaluó por medio de composiciones anuales medias de imágenes obtenidas entre el 1 de enero y el 31 de diciembre de cada año en los años

1985 a 2020 cada 5 años y el año 2022, las cuales se encuentran corregidas radiométrica y geométrica-mente; finalmente, se evalúa el área de estudio para calcular los índices de vegetación usando las respectivas ecuaciones (Figura 2). Se utilizaron índices NDVI, EVI, RVI, GVI y SAVI; cada uno de ellos tiene características especiales que los diferencian entre sí, por lo tanto, procedimos al análisis del efecto temporal del cambio climático usando estos índices (Bagherzadeh et al., 2020).

Las temperaturas se descargaron de la colección de imágenes del repositorio GEE del centro europeo de previsiones meteorológicas a plazo medio (ECMWF climate reanalysis), ERA5-Land, con resolución espacial de 0,1 grados de arco (Muñoz-Sabater et al., 2021), y las precipitaciones del repositorio GEE, TerraClimate: Monthly Climate and Climatic Water Balance for Global Terrestrial Surfaces, University of Idaho, con una con resolución espacial de 2,5 arc minutos (Abatzoglou et al., 2018).

En el procesamiento de las imágenes, se generó 16.370 grillas aleatorias, separados a 1 km entre ellas, lo que permitió cubrir el total del área de estudio. Los datos originales fueron filtrados y se eliminaron los valores extremos atípicos.

2.3. Clasificación de biomasa usando ML

El ML agrupa varias estrategias con el propósito de usar algoritmos para extraer información de los datos para la explicación, clasificación o predicción (Wiemken & Kelley, 2020). Surge en la década de los cincuenta para emular computacionalmente, elementos del proceso cognitivo humano a través de reconcomiendo de patrones y procesos de toma de decisión (Jiang et al., 2017; Wiemken & Kelley, 2020). El primer algoritmo para bosques de decisión aleatoria (RF) fue creado por Ho (1995) y la extensión del algoritmo fue desarrollada por Breiman (2001) (Wiemken & Kelley, 2020). El uso de esta herramienta es una de las técnicas más eficientes y se utiliza ampliamente por el balance que ofrece entre su complejidad y los resultados obtenidos (Munir et al., 2022; Vergni & Todisco, 2023).

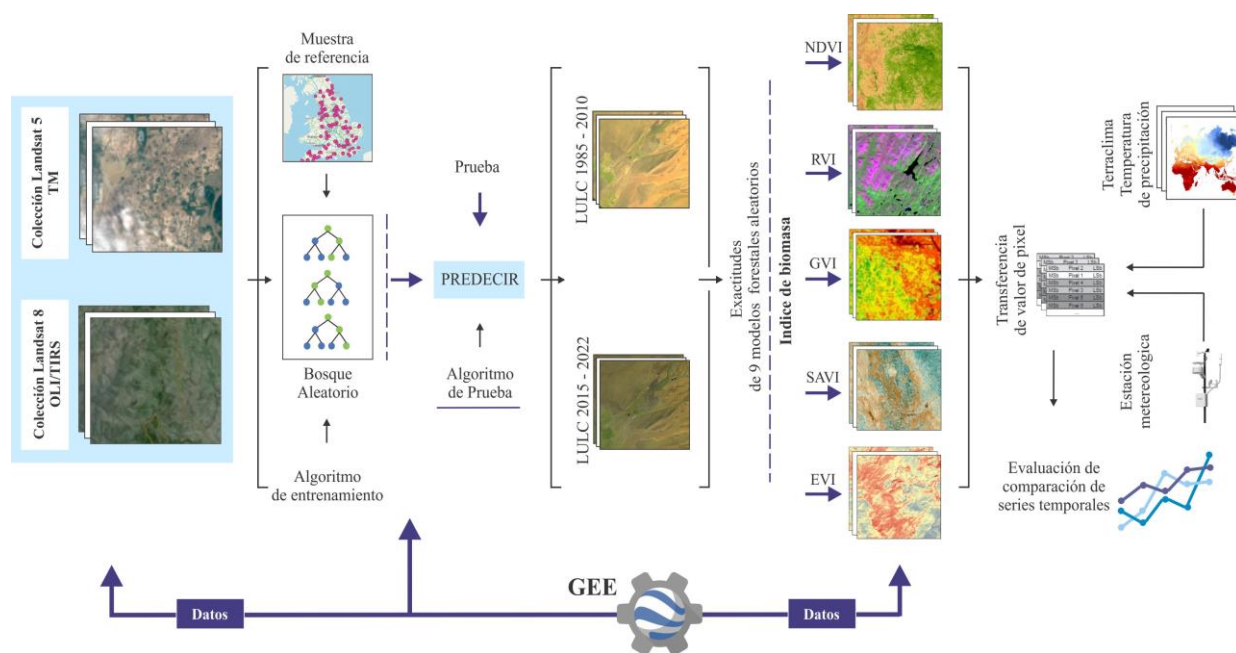


Figura 2. Esquema metodológico con Landsat 5 y 8 en GEE (1985-2022).

2.4. Índices de biomasa

Son combinaciones algebraicas de varias bandas espectrales, diseñadas para resaltar el vigor y las propiedades de la vegetación (biomasa del dosel, radiación absorbida, contenido de clorofila, otros) (Bagherzadeh et al., 2020). Los índices de vegetación o biomasa pueden ser calculados en base a las imágenes Landsat, Sentinel u otras; considerando efectos atmosféricos y ajustados al suelo (Wiemken & Kelley, 2020). En la Tabla 1, se muestran los índices de vegetación utilizados.

2.4.1. Índice de Vegetación por Diferencia Normalizada (NDVI)

El NDVI (Normalized Difference Vegetation Index), se obtiene usando la reflectancia del infrarrojo cercano (NIR) y la reflectancia de la parte roja visible (RED) (Rouse et al., 1973); es un índice usado para estimar la cantidad, calidad y desarrollo de la vegetación, por medio de sensores remotos instalados comúnmente desde una plataforma espacial. Sus valores fluctúan entre -1 y 1, valores por encima de 0,1 indican presencia de vegetación, y cuanto más alto sea el valor de este índice, las condiciones de vigor son mejores (Aboutalebi et al., 2018).

2.4.2. Índice de vegetación mejorada (EVI)

El EVI (Enhanced Vegetation Index), fue desarrollado para optimizar la señal de la vegetación con una sensibilidad mejorada en regiones de alta biomasa y un mejor monitoreo de la vegetación mediante un desacoplamiento de la señal de fondo del dosel y una reducción de las influencias atmosféricas (Huete et al., 2002). Donde (NIR), (RED) y (BLUE) son reflectancias de superficie corregidas atmosféricamente o parcialmente corregidas por atmósfera (Rayleigh y absorción de ozono), L es el ajuste de fondo de la marquesina que trata la transferencia radiante roja, NIR diferencial no lineal a través de una marquesina, y C1, C2 son los coeficientes del término de resistencia

a aerosoles, que utiliza la banda azul para corregir las influencias de aerosoles en la banda roja; los coeficientes adoptados en el algoritmo LANDSAT-EVI son; L = 1, C1 = 6, C2 = 7,5 y G (factor de ganancia) = 2,5 (Huete et al., 2002).

2.4.3. Índice de relación simple (RVI)

Pearson & Miller (1972) proponen este índice, considerados como los pioneros en la historia de los índices de vegetación al proponer el primer índice, el RVI (Ratio Vegetation Index), es el cociente entre las reflectividades del infrarrojo cercano (NIR) y la banda del rojo (RED), basado en la diferencia espectral en la vegetación en las longitudes de onda del rojo y del infrarrojo cercano, el rango de valores es de 0 a más de 30, la vegetación sana generalmente se encuentra entre valores de 2 a 8 (Gupta, 1992).

2.4.4. Índice de vegetación verde (GVI)

El GVI (Green Vegetation Index) o índice de vegetación verde, fue propuesto por Kauth & Thomas (1976), es el cociente entre la reflectividad del infrarrojo cercano y de la banda verde. También se conoce como el índice de vegetación verde Landsat TM. Fue diseñado originalmente para usarse con Landsat TM, pero también funciona con las bandas correspondientes de Landsat ETM + y Landsat 8 (Sripada et al., 2005).

2.4.5. Índice de vegetación ajustado al suelo (SAVI)

El SAVI (Soil Adjusted Vegetation Index), se utiliza para corregir el NDVI por la influencia del brillo del suelo en áreas donde la cobertura vegetativa es baja (Huete, 1988). Este índice fue derivado de la reflectancia de la superficie del Landsat; se calcula como una relación entre los valores RED y NIR con un factor de corrección de la luminosidad del suelo (L) definido en 0,5 para acomodar la mayoría de los tipos de cobertura del suelo (Alvino et al., 2020; Benabdellouahab et al., 2015) y sus valores fluctúan entre -1 y 1.

Tabla 1
Índices de biomasa utilizados

Índice	Descripción	Ecuación	Referencia
NDVI	Índice de vegetación por diferencia normalizada	$NDVI = \frac{NIR - RED}{NIR + RED}$	Rouse et al. (1973)
EVI	Índice de vegetación ajustada	$EVI = G \frac{NIR - RED}{(NIR + C1RED - C2BLUE) + L}$	(Huete et al., 2002)
RVI	Índice relación simple	$RVI = \frac{NIR}{RED}$	Pearson & Miller (1972)
GVI	Índice de vegetación verde	$GVI = \frac{NIR}{BLUE}$	Kauth & Thomas (1976)
SAVI	Índice de vegetación ajustado al suelo	$SAVI = \left[\frac{NIR - RED}{NIR + RED + L} \right] (1 + L)$	Huete (1988)

RESULTADOS Y DISCUSIÓN

Los índices de biomasa han sido utilizados con mucha frecuencia por los investigadores en el mundo, y se han reportado múltiples fuentes de variación en sus resultados, a pesar de esto, no se presentaron diferencias significativas. En la Figura 3 se observa la clasificación de la distribución de la biomasa como resultados de la aplicación RF. Los índices multitemporales presentan una correlación importante entre la topografía y la cobertura vegetal,

presentándose esta última con mayor evidencia de conservación en las zonas de mayor altitud. La Tabla 1 (Ver Material Suplementar), muestra la evaluación de la precisión del uso y la cobertura del suelo usando RF para el período 1985-2022. Se obtuvieron valores para el Kappa Coefficient (k) superiores a 0,96 en todos los casos. Según Alencar da Silva et al. (2019), la vegetación de menor densidad es la más abundante en el área de la cuenca.

El análisis anual de la variación media de los índices de biomasa evidencia una ciclicidad de los valores estadísticos, la fracción de vegetación y la visualización de los mapas. En la Figura MS1 a MS5, se muestra los

resultados espaciales de los índices de biomasa calculados. En la Figura 4, se muestra como referencia representativa la variación espaciotemporal del NDVI para el período de análisis establecido.




Figura 3. Clasificación de biomasa usando RF, suelo desnudo, área de biomasa, superficies de agua y áreas de glaciares (1985 a 2022).




Figura 4. Variabilidad espaciotemporal de NDVI en Tacna usando Landsat 5 y Landsat 8.

Los datos analizados muestran una variabilidad muy marcada en el año 2020 entre abril a diciembre, en toda la región Tacna; asimismo se ha identificado un incremento de vegetación cíclico de 5 años, siendo notorio en las áreas de la zona media y alta, y en la zona baja existen áreas recientes como las Lomas de Sama y el Cerro Arunta. A excepción de esto, en el acuífero Caplina donde el índice de vegetación históricamente es alto, siendo su incremento más marcado en los últimos años (Pino-Vargas & Ascencios, 2022; Pino-Vargas & Huayna, 2022). En la Figura 5 se observa la alta correlación entre los índices NDVI, EVI, RVI, GVI y SAVI. En la Figure MS6 (Ver material suplementar) se muestra la variación de los índices de biomasa para el período 1985 a 2022.

3.1. Análisis de Correlación

La Figura 5 evidencia la baja dispersión en el período de análisis 1985 a 2022, siendo buena la correlación entre el NDVI con los índices EVI, RVI, GVI, SAVI. Esto representa el grado de relación lineal existente entre los índices respecto al NDVI, esto se repite en los años otros períodos analizados; las relaciones gráficas NDVI-SAVI, NDVI-RVI y NDVI-GVI arrojan una relación directa y positiva (Tabla 2, Coeficiente de correlación simple (CCS), Coeficiente de determinación (r^2) y Numero de observaciones (No)).

Tabla 2
Estadísticas de la regresión

	NDVI-EVI	NDVI-RVI	NDVI-GVI	NDVI-SAVI
1985				
CCS	0,890996	0,959970	0,926132	0,999023
r^2	0,793873	0,921542	0,857720	0,998046
No	16347	16347	16347	16347
1990				
CCS	0,828359	0,968207	0,920161	1
r^2	0,686178	0,937424	0,846696	1
No	16347	16347	16347	16347
1995				
CCS	0,837051	0,968440	0,9175840	0,999999
r^2	0,700654	0,937876	0,841960	0,999998
No	16347	16347	16347	16347
2000				
CCS	0,912739	0,963492	0,946857	0,999999
r^2	0,833092	0,928316	0,896538	0,999998
No	16347	16347	16347	16347
2010				
CCS	0,920402	0,953167	0,878890	0,998519
r^2	0,847139	0,908527	0,772447	0,997040
No	16347	16347	16347	16347
2020				
CCS	0,816205	0,947827	0,930274	0,999248
r^2	0,666190	0,898376	0,865409	0,998496
No	16347	16347	16347	16347
2022				
CCS	0,816205	0,947827	0,930274	0,999248
r^2	0,666190	0,898376	0,865409	0,998496
No	16347	16347	16347	16347

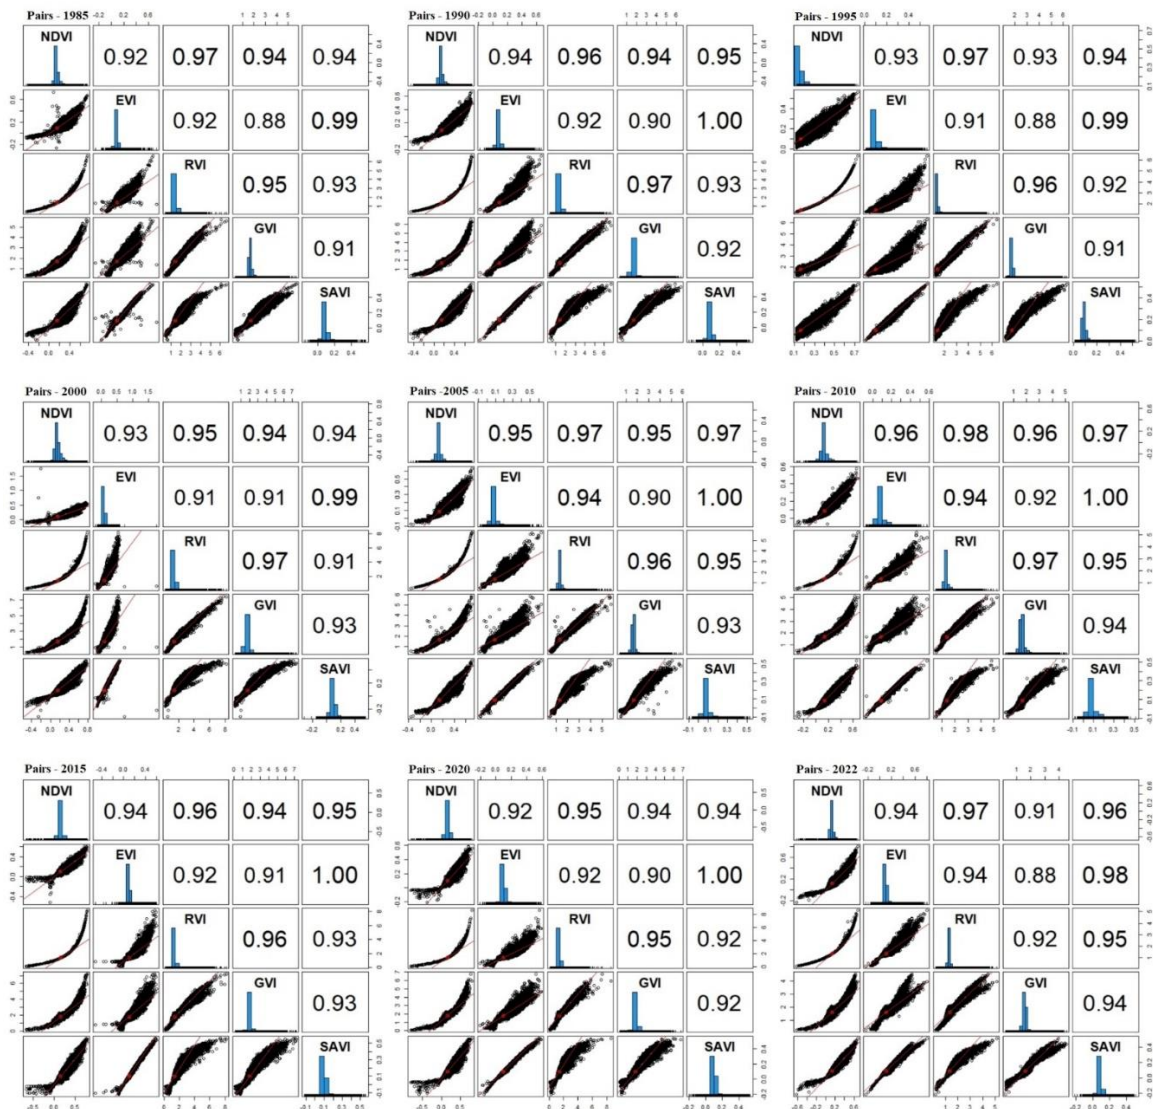


Figura 5. Correlación entre las variables evaluadas.

Para el año 2022 se tiene una correlación fuerte de 0,82 entre NDVI y EVI. Los demás índices respecto al NDVI arrojaron una relación muy fuerte superior a 0,90 respecto al NDVI. Asimismo, el coeficiente de determinación r^2 entre el NDVI y los demás índices, de igual manera indican buen ajuste.

3.2. Análisis de regresión

El NDVI (en función de los índices EVI, RVI, GVI y SAVI), y sus respectivos estadísticos de su obtención se muestran en la Tabla 3.

3.3. El NDVI, temperatura y precipitación

En la zona baja de la región de estudio en el año 2010 presentó altos registros de temperaturas y baja precipitación (Tabla 4, Figura 6), y una inversa respecto a la humedad relativa del aire; asimismo, las áreas calientes, coinciden con las menos lluviosas (Figura 7, Figura 8). En la parte media, las temperaturas fluctúan entre los 18 a 22 °C y las precipitaciones entre los 150 a 240 mm por año, es la zona donde se presenta la mayor cobertura vegetal.

Tabla 3
Estadísticos de las correlaciones y sus ecuaciones para el año 2022

Y	X	Covarianza	Media (Y)	Media (X)	Varianza (Y)	Varianza (X)	Ecuación de regresión
NDVI	EVI	0,00561	0,21664	0,11418	0,01478	0,00320	$Y = 0,3798 X + 0,0318$
NDVI	RVI	0,0076	1,26644	0,11418	0,02028	0,00320	$Y = 0,3766 X - 0,3628$
NDVI	GVI	0,01126	1,63485	0,11418	0,04570	0,00320	$Y = 0,2460 X - 0,2881$
NDVI	SAVI	0,00480	0,17124	0,11418	0,00720	0,00320	$Y = 0,6661 X - 0,0001$

Tabla 4
Estadística de temperaturas máximas en el período 1985 a 2022

Temperatura máxima (°C)	1985	1990	1995	2000	2010	2020	2022
Mínimo	6,391	7,553	8,515	7,156	9,540	8,640	8,654
Promedio	20,076	21,110	21,883	21,466	22,171	21,401	21,501
Máximo	30,733	30,931	30,795	29,993	31,654	30,900	30,919
Desviación estándar	7,347	7,698	6,820	6,973	7,359	6,590	6,690
Varianza	53,985	59,262	46,516	48,634	54,165	44,660	44,761

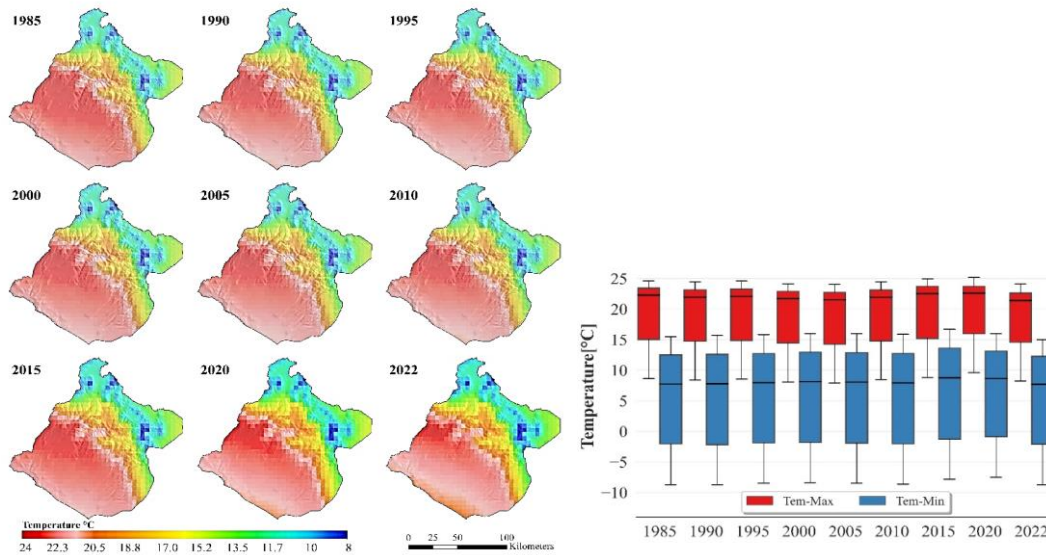


Figura 6. Variabilidad temporal de máximas temperaturas en el período 1985 a 2022.

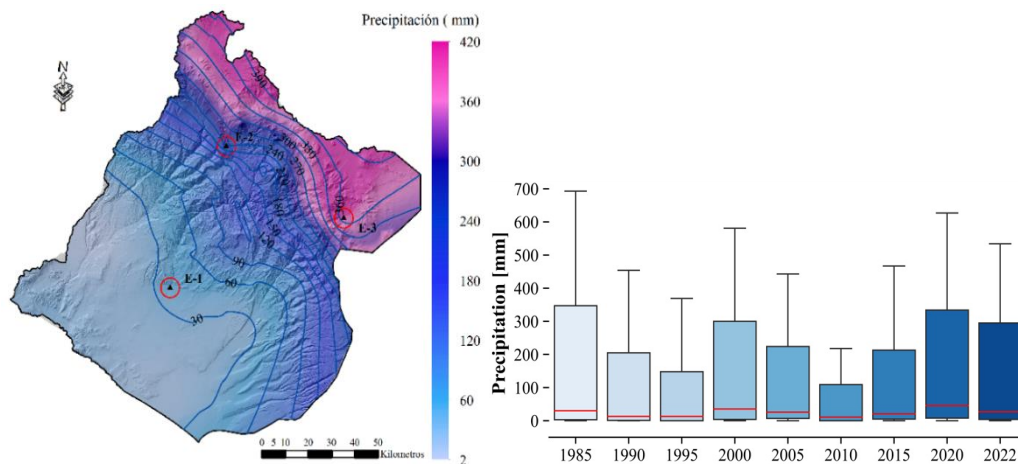


Figura 7. Isoyetas de precipitación anual 2020. Boxplot multitemporal de precipitación acumulada anual.




Figura 8. Histogramas de precipitación con curvas de NDVI y temperaturas máximas en series temporales de la parte baja, parte media y alta de Tacna.

Se obtuvo la regresión entre NDVI en meses lluviosos y precipitaciones acumuladas anuales del año 1985 hasta el 2020 de tres estaciones pluviométricas representativas parte baja, media y alta, aplicando la correlación de Pearson (Figura 9), se observa que, en las estaciones pluviométricas de Candarave y Pucarani, presentan una tendencia positiva baja para el mismo periodo analizado $r^2 = 0,3$ para una precipitación media de 210 mm. Asimismo, se observa que las otras estaciones no presentan tendencias significativas. La mayor densidad de cobertura vegetal y valores más elevados de NDVI coincide con la zona media y alta,

donde se registran las precipitaciones más altas entre noviembre y marzo, lo que indica que la pluviometría es un factor condicionante para su distribución y conservación. La curva del NDVI sigue el modelo estacional regional de precipitaciones (Figura 10, Figura 11), definido en una estación húmeda estival, con predominio de valores elevados de NDVI, y una estación seca invernal, con predominio de valores bajos de NDVI, similitud importante se observa en procesos estacionales de cobertura vegetal en la zona de la parte media y alta.




Figura 9. Correlación Precipitación y NDVI. Izquierda estación Candarave, derecha estación Pucarani.




Figura 10. Comportamiento temporal de la precipitación, estación Candarave parte media, período 1985 a 2022.




Figura 11. Comportamiento temporal de la precipitación, estación Paucarani parte alta, período 1985 a 2022.

Tomado como base el perfil longitudinal de NDVI de la región de estudio (Figura 12), para el año 2020, se observa un marcado incremento de la cobertura vegetal y un incremento del NDVI con respecto a los años 2010 y 2020. Asimismo, se observa que la cobertura vegetal se extiende hacia la parte baja elevaciones del orden de los 1100 msnm. Asimismo, los índices del año 2010 son

menores al 2000 en la parte media y alta producto de las menores precipitaciones. Las evidencias de cambio climático son visibles, el efecto del cambio climático en esta región, considerada como una de las más secas del mundo según las evidencias encontradas y registradas, puede darse como favorable o desfavorable para la disponibilidad hídrica (Pino & Chávarri, 2022).

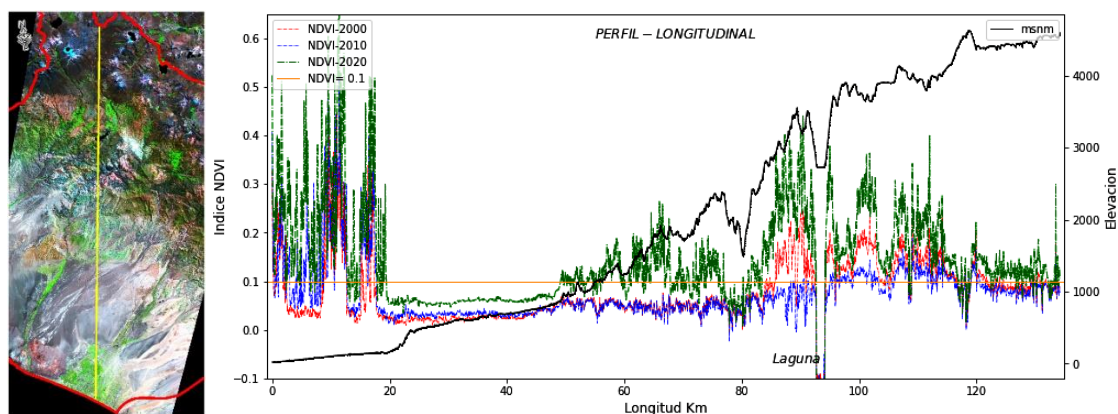


Figura 12. Perfil NDVI versus elevaciones para la región de estudio.

CONCLUSIONES

Haciendo una comparación del NDVI, con el SAVI, GVI, RVI y EVI, bajo condiciones de aridez e hiperaridez, al sur Perú y norte de Chile, y específicamente en el entorno de las condiciones especiales que impone el Desierto de Atacama, se obtuvo similitud entre las variaciones espaciotemporales del NDVI y SAVI. Por su lado, existen diferencias estadísticas entre el EVI y el NDVI. Se puede afirmar que el NDVI, SAVI, GVI y RVI son más eficientes para identificar las condiciones climáticas cambiantes de esta región.

El NDVI responde en forma directa a las lluvias, en el período de verano; asimismo, no refleja respuesta de la vegetación en la temporada de lluvias invernales,

estas respuestas fueron muy débiles y amplias. Los valores más altos de NDVI se obtuvieron en la estación de verano a continuación de un proceso de sequías extensas.

En los períodos de tiempo más recientes se registra un aumento de vegetación en lugares de mayor temperatura, esto se puede atribuir a las precipitaciones estacionales que se generan con mayor frecuencia en lugares donde no estas no existían. Estas alteraciones son evidencias resultantes del cambio climático en la región y se ven identificadas en el comportamiento de los índices de biomasa.

AGRADECIMIENTOS

Se agradece a la Universidad Nacional Jorge Basadre Grohmann. Este trabajo se realizó en el marco del proyecto de investigación "Uso de

Sensores Remotos para Mejorar la Gestión del Riego en Olivo (*Olea europaea* L.), y Enfrentar el Cambio Climático en Zonas Áridas".

REFERENCIAS BIBLIOGRÁFICAS

- Abatzoglou, J. T., Dobrowski, S. Z., Parks, S. A., & Hegewisch, K. C. (2018). TerraClimate, a high-resolution global dataset of monthly climate and climatic water balance from 1958–2015. *Scientific Data*, 5(1), 170191. <https://doi.org/10.1038/sdata.2017.191>
- Aboutaleb, M., Torres-Rua, A. F., McKee, M., Kustas, W., Nieto, H., & Coopmans, C. (2018). Behavior of vegetation/soil indices in shaded and sunlit pixels and evaluation of different shadow compensation methods using UAV high-resolution imagery over vineyards. *Proceedings of Spie the International Society for Optical Engineering*, 10664, 6. <https://doi.org/10.1117/12.2305883>
- Alves, K. M. A. da S., D'ávila, M. C. P., Nóbrega, R. S., & Albarran, D. O. (2019). Spatial and temporal variability of vegetation cover in the moxotó watershed, Pernambuco, Brasil. *Diálogo Andino*, 58, 139–150. <https://doi.org/10.4067/S0719-26812019000100139>
- Alvino, F. C. G., Aleman, C. C., Filgueiras, R., Althoff, D., & da Cunha, F. F. (2020). VEGETATION INDICES FOR IRRIGATED CORN MONITORING. *Engenharia Agrícola*, 40(3), 322–333. <https://doi.org/10.1590/1809-4430-eng.agric.v40n3p322-333/2020>
- Ariza, A., & Ramirez, H. M. (2014). Modelo Batimétrico derivado de imágenes Landsat ETM+ en zonas de arrecifes tropicales. *Revista Cartográfica*, (90), 43+.
- Bagherzadeh, A., Hoseini, A. V., & Totmaj, L. H. (2020). The effects of climate change on normalized difference vegetation index (NDVI) in the Northeast of Iran. *Modeling Earth Systems and Environment*, 6(2), 671–683. <https://doi.org/10.1007/s40808-020-00724-x>
- Bawden, R. (2017). Global change and its consequences for the world's arid lands. In *Climate Variability Impacts on Land Use and Livelihoods in Drylands* (pp. 59–71). Springer International Publishing. https://doi.org/10.1007/978-3-319-56681-8_3
- Benabdelouahab, T., Balaghi, R., Hadria, R., Lionboui, H., Minet, J., & Tychon, B. (2015). Monitoring surface water content using visible and short-wave infrared SPOT-5 data of wheat plots in irrigated semi-arid regions. *International Journal of Remote Sensing*, 36(15), 4018–4036. <https://doi.org/10.1080/01431161.2015.1072650>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324/METRICS>
- Carlson, T. N., & Traci Arthur, S. (2000). The impact of land use — land cover changes due to urbanization on surface microclimate and hydrology: a satellite perspective. *Global and Planetary Change*, 25(1–2), 49–65. [https://doi.org/10.1016/S0921-8181\(00\)00021-7](https://doi.org/10.1016/S0921-8181(00)00021-7)
- Chucuya, S., Vera, A., Pino-Vargas, E., Steenken, A., Mählknecht, J., & Montalván, I. (2022). Hydrogeochemical Characterization and Identification of Factors Influencing Groundwater Quality in Coastal Aquifers, Case: La Yarada, Tacna, Peru. *International Journal of Environmental Research and Public Health*, 19(5), 2815. <https://doi.org/10.3390/ijerph19052815>
- Condori-Tintaya, F., Pino-Vargas, E., & Tacora-Villegas, P. (2022). Pérdida de suelos por erosión hídrica en laderas semiáridas de la subcuenca Cairani-Camilaca, Perú. *Idesia*, 40(2), 7–15. <https://doi.org/10.4067/S0718-34292022000200007>

- da Silva Alves, K. M. A., D'ávila, M. C. P., Nóbrega, R. S., & Albarran, D. O. (2019). Variabilidad espacial y temporal de la cobertura vegetal de los años 1984 a 2011 en la cuenca hidrográfica del río Moxotó, Pernambuco, Brasil. *Diálogo Andino*, 58, 139–150. <https://doi.org/10.4067/S0719-26812019000100139>
- Garreaud, R. D., Molina, A., & Farias, M. (2010). Andean uplift, ocean cooling and Atacama hyperaridity: A climate modeling perspective. *Earth and Planetary Science Letters*, 292(1–2), 39–50. <https://doi.org/10.1016/j.epsl.2010.01.017>
- Garreaud, R., Vuille, M., & Clement, A. C. (2003). The climate of the Altiplano: observed current conditions and mechanisms of past changes. *Palaeogeography, Palaeoclimatology, Palaeoecology*, 194(1–3), 5–22. [https://doi.org/10.1016/S0031-0182\(03\)00269-4](https://doi.org/10.1016/S0031-0182(03)00269-4)
- Gaur, M. K., & Squires, V. R. (2017a). *Climate variability impacts on land use and livelihoods in drylands*. In *Climate Variability Impacts on Land Use and Livelihoods in Drylands*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-56681-8>
- Gaur, M. K., & Squires, V. R. (2017b). *Geographic extent and characteristics of the world's arid zones and their peoples*. In *Climate Variability Impacts on Land Use and Livelihoods in Drylands*. Springer International Publishing. https://doi.org/10.1007/978-3-319-56681-8_1
- Gomez-Tunque, K. R., Ingol-Blanco, E., Mejía-Marcacuzco, A., Chávarri-Velarde, E., & Pino-Vargas, E. (2023). Deep Neural Networks for ENSO Prediction in the Niño 3.4 and Niño 1+2 Regions. *World Environmental and Water Resources Congress 2023*, 307–316. <https://doi.org/10.1061/9780784484852.030>
- Gupta, R. K. (1992). NOAA/AVHRR vegetation indices and agriculture-meteorology processes. *Advances in Space Research*, 12(7), 87–90. [https://doi.org/10.1016/0273-1177\(92\)90201-8](https://doi.org/10.1016/0273-1177(92)90201-8)
- Hashim, B. M., Sultan, M. A., Attyia, M. N., Al Maliki, A. A., & Al-Ansari, N. (2019). Change detection and impact of climate changes to Iraqi southern marshes using Landsat 2 MSS, Landsat 8 OLI and Sentinel 2 MSI data and GIS applications. *Applied Sciences (Switzerland)*, 9(10). <https://doi.org/10.3390/app9102016>
- Tin Kam Ho (1995). Random decision forests. *Proceedings of 3rd International Conference on Document Analysis and Recognition, Montreal, QC, Canada*, doi: 10.1109/ICDAR.1995.598994.
- Houston, J., & Hartley, A. J. (2003). The central Andean west-slope rainshadow and its potential contribution to the origin of hyper-aridity in the Atacama Desert. *International Journal of Climatology*, 23(12), 1453–1464. <https://doi.org/10.1002/joc.938>
- Huete, A. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Huete, A., Didan, K., Miura, T., Rodriguez, E., Gao, X., & Ferreira, L. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1–2), 195–213. [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2)
- Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., Wang, Y., Dong, Q., Shen, H., & Wang, Y. (2017). Artificial intelligence in healthcare: past, present and future. *Stroke and Vascular Neurology*, 2(4), 230–243. <https://doi.org/10.1136/svn-2017-000101>
- Kakarla, S. C., Zhu, Z., Ampatzidis, Y., Fountas, S., Ehsani, R., & Pardalos, P. (2022). Editorial: Artificial Intelligence Applications in Specialty Crops. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.866724>
- Kauth, R. and Thomas, G. (1976). The Tasseled Cap-A Descripción gráfica del desarrollo espectral-temporal de los cultivos agrícolas según lo visto por Landsat. *Simposio LARS 1976 de Procesamiento Mecánico de Datos de Detección Remota, West Lafayette, IN: Purdue University, 4B41-4B51*.
- Kawabata, A., Ichii, K., & Yamaguchi, Y. (2001). Global monitoring of interannual changes in vegetation activities using NDVI and its relationships to temperature and precipitation. *International Journal of Remote Sensing*, 22(7), 1377–1382. <https://doi.org/10.1080/01431160119381>
- Kua, J., Loke, S. W., Arora, C., Fernando, N., & Ranaweera, C. (2021). Internet of Things in Space: A Review of Opportunities and Challenges from Satellite-Aided Computing to Digitally-Enhanced Space Living. *Sensors*, 21(23), 8117. <https://doi.org/10.3390/s21238117>
- Machaca-Pillaca, R., Pino-Vargas, E., Ramos-Fernández, L., Quille-Mamani, J., & Torres-Rúa, A. (2022). Estimación de la evapotranspiración con fines de riego en tiempo real de un olivar a partir de imágenes de un dron en zonas áridas, caso La Yarada, Tacna, Perú. *Idesia*, 40(2), 55–65. <https://doi.org/10.4067/S0718-34292022000200055>
- Malanson, G. P., & Alftine, K. J. (2016). Ecological Impacts of Climate Change. In *Biological and Environmental Hazards, Risks, and Disasters* (397–426). <https://doi.org/10.1016/B978-0-12-394847-2.00022-X>
- Martinez, Alex de la Iglesia, and S. M. Labib. 2023. Demystifying Normalized Difference Vegetation Index (NDVI) for Greenness Exposure Assessments and Policy Interventions in Urban Greening. *Environmental Research* 220(115155). doi: 10.1016/j.envres.2022.115155.
- Munir, S., Seminar, K. B., Sudradjat, Sukoco, H., & Buono, A. (2022). The Use of Random Forest Regression for Estimating Leaf Nitrogen Content of Oil Palm Based on Sentinel 1-A Imagery. *Information*, 14(1), 10. <https://doi.org/10.3390/info14010010>
- Muñoz-Sabater, J., Dutra, E., Agustí-Panareda, A., Albergel, C., Arduini, G., Balsamo, G., Boussetta, S., Chouga, M., Harrigan, S., Hersbach, H., Martens, B., Miralles, D. G., Piles, M., Rodríguez-Fernández, N. J., Zsoter, E., Buontempo, C., & Thépaut, J.-N. (2021). ERA5-Land: a state-of-the-art global reanalysis dataset for land applications. *Earth System Science Data*, 13(9), 4349–4383. <https://doi.org/10.5194/essd-13-4349-2021>
- Nieto, H., Kustas, W. P., Torres-Rúa, A., Alfieri, J. G., Gao, F., Anderson, M. C., White, W. A., Song, L., Alsina, M. del M., Prueger, J. H., McKee, M., Elarab, M., & McKee, L. G. (2019). Evaluation of TSEB turbulent fluxes using different methods for the retrieval of soil and canopy component temperatures from UAV thermal and multispectral imagery. *Irrigation Science*, 37(3), 389–406. <https://doi.org/10.1007/s00271-018-0585-9>
- Pearson, R. L. and Miller, L. D. (1972). Remote mapping of standing crop biomass for estimation of the productivity of the short-grass Prairie, Pawnee National Grassland, Colorado. *8th International Symposium on Remote Sensing of Environment*, 1357–1381.
- Pino-Vargas, & Ascencios-Templo, D. (2021). La implementación de veda como una herramienta para controlar la degradación del acuífero costero La Yarada, Tacna, Perú. *Diálogo Andino*, 66, 489–496. <https://doi.org/10.4067/S0719-26812021000300489>
- Pino-Vargas, E., Chávarri-Velarde, E., Ingol-Blanco, E., Mejía, F., Cruz, A., & Vera, A. (2022). Impacts of Climate Change and Variability on Precipitation and Maximum Flows in Devil's Creek, Tacna, Peru. *Hydrology*, 9(1), 10. <https://doi.org/10.3390/hydrology9010010>
- Pino-Vargas, E., Espinoza-Molina, J., Chávarri-Velarde, E., Quille-Mamani, J., & Ingol-Blanco, E. (2023). Impacts of Groundwater Management Policies in the Caplina Aquifer, Atacama Desert. *Water*, 15(14), 2610. <https://doi.org/10.3390/w15142610>
- Pino-Vargas, E. M., & Ascencios, D. R. (2022). Sostenibilidad del cultivo de olivo bajo un enfoque climatológico en una región árida, cabecera del desierto de Atacama. *Ciencia y Tecnología Agropecuaria*, 23(3). https://doi.org/10.21930/rcta.vol23_num3_art:2652
- Pino-Vargas, E. M., & Huayna, G. (2022). Spatial and temporal evolution of olive cultivation due to pest attack, using remote sensing and satellite image processing. *Scientia Agropecuaria*, 13(2), 149–157. <https://doi.org/10.17268/sci.agropecu.2022.013>
- Pino-Vargas, Taya-Acosta, E., Ingol-Blanco, E., & Torres-Rúa, A. (2022). Deep Machine Learning for Forecasting Daily Potential Evapotranspiration in Arid Regions, Case: Atacama Desert Header. *Agriculture*, 12(12), 1971. <https://doi.org/10.3390/AGRICULTURE12121971>
- Pino, E. (2019). El acuífero costero La Yarada, después de 100 años de explotación como sustento de una agricultura en zonas áridas: una revisión histórica. *Idesia*, 37(3), 39–45. <https://doi.org/10.4067/S0718-34292019000300039>
- Pino, E. (2021). Conflictos por el uso del agua en una región árida: caso Tacna, Perú. *Diálogo Andino*, 65, 405–415. <https://doi.org/10.4067/S0719-26812021000200405>
- Pino, E., & Chávarri, E. (2022). Evidencias de cambio climático en la región hiperárida de la Costa sur de Perú, cabecera del Desierto de Atacama. *Tecnología y Ciencias Del Agua*, 13(1), 1–34. <https://doi.org/10.24850/j-tyca-2022-01-08>
- Pino, E., Chávarri V., E., & Ramos F., L. (2018). Governability and governance crisis its implications in the inadequate use of groundwater, case coastal aquifer of La Yarada, Tacna, Perú. *Idesia*, 36(3), 77–85. <https://doi.org/10.4067/S0718-34292018005001301>
- Pino, E., Montalván, I., Vera, A., & Ramos, L. (2019). La conductancia estomática y su relación con la temperatura

- foliar y humedad del suelo en el cultivo del olivo (*Olea europaea* L.), en periodo de maduración de frutos, en zonas áridas. La Yarada, Tacna, Perú. *Idesia*, 37(4), 55-64. <https://doi.org/10.4067/S0718-34292019000400055>
- Pino, E., Ramos, L., Mejía, J., Chávarri, E., & Ascencios, D. (2020). Medidas de mitigación para el acuífero costero La Yarada, un sistema sobreexplotado en zonas áridas. *Idesia*, 38(3), 21-31. <https://doi.org/10.4067/S0718-34292020000300021>
- Pocco, V., Chucuya, S., Huayna, G., Ingol-Blanco, E., & Pino-Vargas, E. (2023). A Multi-Criteria Decision-Making Technique Using Remote Sensors to Evaluate the Potential of Groundwater in the Arid Zone Basin of the Atacama Desert. *Water*, 15(7), 1344. <https://doi.org/10.3390/w15071344>
- Richards, David F., Adam M. Milewski, Steffan Becker, Yonesha Donaldson, Lea J. Davidson, Fabian J. Zowam, Jay Mrazek, and Michael Durham (2023). Evaluation and Analysis of Remote Sensing-Based Approach for Salt Marsh Monitoring. *Remote Sensing* 16(1):2. doi: 10.3390/rs16010002.
- Ritter, B., Wennrich, V., Medialdea, A., Brill, D., King, G., Schneiderwind, S., Niemann, K., Fernández-Galego, E., Diederich, J., Rolf, C., Bao, R., Melles, M., & Dunai, T. J. (2019). Climatic fluctuations in the hyperarid core of the Atacama Desert during the past 215 ka. *Scientific Reports*, 9(1), 1-13. <https://doi.org/10.1038/s41598-019-41743-8>
- Rouse, J. W., Hass, R. H., Schell, J. A., & Deering, D. W. (1973). Monitoring vegetation systems in the great plains with ERTS. *In Proceedings of the Third ERTS Symposium; NASA: Washington, DC, USA*, 1, 309-317
- Sidahmed, A. E. (2017). Recent trends in drylands and future scope for advancement. In *Climate Variability Impacts on Land Use and Livelihoods in Drylands*. Springer International Publishing. https://doi.org/10.1007/978-3-319-56681-8_2
- Singh, R. K., Kumar, P., Kumar, M., Tyagi, K., & Jain, H. (2022). Artificial Machine Learning-Based Classification of Land Cover and Crop Types Using Sentinel-2A Imagery. *In Sustainable Agriculture Systems and Technologies* (326-336). Wiley. <https://doi.org/10.1002/9781119808565.ch16>
- Sripada, R. P., Heiniger, R. W., White, J. G., & Weisz, R. (2005). Aerial color infrared photography for determining late-season nitrogen requirements in corn. *Agronomy Journal*, 97(5), 1443-1451. <https://doi.org/10.2134/agronj2004.0314>
- Stein, B. A., Staudt, A., Cross, M. S., Dubois, N. S., Enquist, C., Griffis, R., Hansen, L. J., Hellmann, J. J., Lawler, J. J., Nelson, E. J., & Parris, A. (2013). Preparing for and managing change: climate adaptation for biodiversity and ecosystems. *Frontiers in Ecology and the Environment*, 11(9), 502-510. <https://doi.org/10.1890/120277>
- Vera, A., Pino-Vargas, E., Verma, M. P., Chucuya, S., Chávarri, E., Canales, M., Torres-Martínez, J. A., Mora, A., & Mählknecht, J. (2021). Hydrodynamics, Hydrochemistry, and Stable Isotope Geochemistry to Assess Temporal Behavior of Seawater Intrusion in the La Yarada Aquifer in the Vicinity of Atacama Desert, Tacna, Peru. *Water*, 13(22), 3161. <https://doi.org/10.3390/w13223161>
- Vergni, L., & Todisco, F. (2023). A Random Forest Machine Learning Approach for the Identification and Quantification of Erosive Events. *Water*, 15(12), 2225. <https://doi.org/10.3390/w15122225>
- Wang, Y. J., & Qin, D. H. (2017). Influence of climate change and human activity on water resources in arid region of Northwest China: An overview. *In Advances in Climate Change Research*, 8(4), 268-278. <https://doi.org/10.1016/j.accre.2017.08.004>
- Wardropper, C. B., & Rissman, A. R. (2019). Adaptations to extreme storm events by conservation organizations. *Climatic Change*, 152(1), 85-101. <https://doi.org/10.1007/s10584-018-2342-8>
- West, J. M., Courtney, C. A., Hamilton, A. T., Parker, B. A., Julius, S. H., Hoffman, J., Koltes, K. H., & MacGowan, P. (2017). Climate-Smart Design for Ecosystem Management: A Test Application for Coral Reefs. *Environmental Management*, 59(1), 102-117. <https://doi.org/10.1007/s00267-016-0774-3>
- Wiemken, T. L., & Kelley, R. R. (2020). Machine Learning in Epidemiology and Health Outcomes Research. *Annual Review of Public Health*, 41(1), 21-36. <https://doi.org/10.1146/annurev-publhealth-040119-094437>
- Xiang, Yunfan, Xiangyu Tian, Yue Xu, Xiaokun Guan, and Zhengchao Chen (2023). EGMT-CD: Edge-Guided Multimodal Transformers Change Detection from Satellite and Aerial Images. *Remote Sensing* 16(1):86. doi: 10.3390/rs16010086
- Yang, Shunfu, Yuluan Zhao, Die Yang, and Anjun Lan. 2024. Analysis of Vegetation NDVI Changes and Driving Factors in the Karst Concentration Distribution Area of Asia. *Forests* 15(3):398. doi: 10.3390/f15030398
- Zhang, B. G. (2000). Asymptotic behavior of solutions of certain difference equations. *Applied Mathematics Letters*, 13(1), 13-18. [https://doi.org/10.1016/S0893-9659\(99\)00138-X](https://doi.org/10.1016/S0893-9659(99)00138-X)
- Zhang, He, Yuan, Liu, Zhou, & Huang. (2019). Machine Learning-Based Spectral Library for Crop Classification and Status Monitoring. *Agronomy*, 9(9), 496. <https://doi.org/10.3390/agronomy9090496>