

CASO PRÁCTICO

Tendencia anual, anomalías y predicción del comportamiento de cobertura de vegetación con imágenes Landsat y MOD13Q1, microcuenca Apacheta, Región Ayacucho

Wilmer Moncada¹, Bram Willems², Alex Pereda¹, Cristhian Aldana³, Jhony Gonzales³

¹ Universidad Nacional de San Cristóbal de Huamanga (UNSCH). Ayacucho, Perú.

² Centro de Competencia del Agua (CCA). Lima, Perú.

³ Universidad Nacional de Frontera (UNF). Sullana, Piura, Perú.

Resumen: La variabilidad climática en la microcuenca Apacheta impacta en el comportamiento de la vegetación. El objetivo es analizar la tendencia anual, anomalías y predecir el comportamiento de cobertura de vegetación (CV) con imágenes Landsat y el producto MOD13Q1 en la microcuenca Apacheta de la Región Ayacucho. Para ello, se clasificó la CV, que se validó con el índice Kappa (p -valor=0,032; <0,05) obteniéndose una buena concordancia entre los valores observados *in situ* y los estimados en las imágenes Landsat. Los datos de CV se sometieron a la prueba de normalidad Lilliefors (p -valor=0,0014; <0,05) indicando que no provienen de una distribución normal. El pronóstico de CV se realizó con los paquetes *auto.arima*, *forecast* y *prophet*, en R, según el enfoque de Box-Jenkins y ARIMA, cuyo escenario futuro de dos años es aceptable, pero con mayor sesgo. Los resultados muestran una tendencia anual de CV creciente de 3.378,96 ha con imágenes Landsat y de 3.451,95 ha con el producto MOD13Q1, para finales del 2020. Las anomalías y el pronóstico de CV también evidencian un significativo incremento en los últimos 9 años, llegando a ser superiores en los años pronosticados, 2021 y 2022.

Palabras clave: NDVI, cobertura de vegetación, predicción, tendencia, anomalías.

Annual trend, anomalies and prediction of vegetation cover behavior with Landsat and MOD13Q1 images, Apacheta micro-basin, Ayacucho Region

Abstract: Climate variability in the Apacheta micro-basin has an impact on vegetation behavior. The objective is to analyze the annual trend, anomalies and predict the behavior of vegetation cover (CV) with Landsat images and the MOD13Q1 product in the Apacheta micro-basin of the Ayacucho Region. For this purpose, the CV was classified and validated with the Kappa index (p -value=0.032; <0.05), obtaining a good agreement between the values observed *in situ* and the estimated in the Landsat images. The CV data were subjected to the Lilliefors normality test (p -value=0.0014; <0.05) indicating that they do not come from a normal distribution. CV forecasting was performed with the *auto.arima*, *forecast* and *prophet* packages, in R, according to the Box-Jenkins and ARIMA approaches, whose two-year future scenario is acceptable, but with higher bias. The results show an annual

To cite this article: Moncada, W., Willems, B., Pereda, A., Aldana, C., Gonzales, J. 2022. Annual trend, anomalies and prediction of vegetation cover behavior with Landsat and MOD13Q1 images, Apacheta micro-basin, Ayacucho Region. *Revista de Teledetección*, 59, 73-86. <https://doi.org/10.4995/raet.2021.15672>

* Corresponding author: wilmer.moncada@unsch.edu.pe

increasing CV trend of 3,378.96 ha with Landsat imagery and 3,451.95 ha with the MOD13Q1 product, by the end of 2020. The anomalies and the CV forecast also show a significant increase in the last 9 years, becoming higher in the forecasted years, 2021 and 2022.

Key words: NDVI, vegetation cover, prediction, trend, anomalies.

1. Introducción

En la actualidad, la variabilidad climática afecta de manera negativa a la cobertura nival en la microcuenca Apacheta (Pereda et al., 2018). Esto es debido al incremento de la temperatura superficial del suelo, TSS (Moncada y Willems, 2020a) que impacta en el comportamiento de la cobertura de vegetación (CV), predicho por algunos modelos (Rashmi y Lele, 2010). Además, siendo una zona de recarga hídrica, se evidencian problemas de disponibilidad de agua en los ecosistemas de bofedales y a la presa Cuchoquesera (Moncada y Willems, 2020b). En ese sentido, el uso de imágenes Landsat, TM, ETM+, OLI (30 m), en el cálculo del Índice de Vegetación de Diferencia Normalizada (NDVI), brindan una mayor precisión en el monitoreo de la CV que el NDVI del producto MOD13Q1 del sensor MODIS (250 m) (Hoek van Dijke et al., 2019; Zaraza y Manrique, 2019); donde, la CV densa o menos densa difiere de la clase observada con una mayor variabilidad, dado que la resolución espacial no permite apreciarla al detalle (Qiu et al., 2014).

Algunos métodos aplican Análisis de Redes Neuronales (ARN), a partir de la emisividad y la temperatura de la superficie en la estimación de la proporción de CV (P_V), para obtener mayor precisión en la validación de los índices de vegetación clásicos, NDVI, EVI, SAVI, entre otros, con respecto a las clases de vegetación observadas en campo (Neinavaz et al., 2020). Sin embargo, un mejor análisis del comportamiento de la CV a partir del NDVI se realiza clasificando la CV (Olivo, 2017), además del uso de múltiples pruebas estadísticas para la determinación de la tendencia de CV (Han et al., 2019).

Por otro lado, el análisis de anomalías evaluada por encima y debajo del valor medio de la CV muestra respuesta significativa cuando se relaciona con la anomalía de precipitación (Nanzad et al., 2019).

En ese sentido, como se desconoce la tendencia anual de la CV derivada del impacto del deshielo de los nevados y del incremento de la TSS, se tiene la necesidad de explicar el comportamiento de la CV en un futuro cercano. De esta manera su predicción implica cuantificar la componente determinística (DM) de la dinámica de vegetación a partir de un modelo aditivo que incluye parámetros estacionales, tendencias anuales y análisis de discontinuidad, que no involucra dependencias espaciales. Además se extraen residuos aleatorios estacionarios generados por DM y aplicando dependencias sistemáticas autorregresivas (AR) mediante un modelo AR espacio-temporal articulado a las correlaciones de secuencias de datos (Forzieri et al., 2010).

Entre tanto, la predicción univariante de la serie de tiempo de CV del producto MOD13Q1 se realiza con el modelo determinístico AR integrado de medias móviles (ARIMA), logrando una mejor predicción a corto plazo, reduciendo la complejidad y tiempos de los modelos de predicción tradicionales. En cambio puede ser superado si se utilizan los parámetros de altitud, potencial de humedad y radiación solar, índice de potencial de nieve y el historial de perturbaciones, aplicando ARN (Abujayyab y Karaş, 2019; Cairns, 2001).

Además, el enfoque de Box-Jenkins y ARIMA, tienen en cuenta la estacionalidad, variación anual y discontinuidades inducidas por efectos no estacionarios, para la estimación de tendencia y anomalías (Ceroni et al., 2015). Es posible aplicar técnicas de *forecasting*, para identificar tendencia, estacionalidad, cambios acelerados, puntos de inflexión o residuos en la predicción con ARIMA, usando paquetes R (*forecast*, con *auto.arima*) (Hyndman et al., 2020) y *prophet*, desarrollando un procedimiento de predicción automática, basado en un modelo aditivo y ajustando las tendencias a una estacionalidad (Taylor y Letham, 2017).

De esta manera, se pretende analizar la tendencia anual, anomalías y predicción del comportamiento de CV con imágenes Landsat y el producto MOD13Q1 en la microcuenca Apacheta de la Región Ayacucho, Perú.

2. Material y métodos

2.1. Área de estudio

La microcuenca Apacheta, Figura 1, se ubica en la cabecera de la cuenca Cachi en el distrito de Paras, provincia de Cangallo, Región Ayacucho, Perú, con longitudes de 74° 37' 26.4" W a 74° 45' 32.4" W y latitudes de 13° 17' 6" S a 13° 26' 9.6" S. Tiene un área de 14.348,21 ha, con altitud mínima de 4112 m s.n.m., altitud máxima de 5045 m s.n.m., y altitud media de 4651 m s.n.m.

Se caracteriza por tener tres estadios estacionales, el lluvioso (diciembre, enero, febrero y marzo) con valores altos de precipitación acumulada de 145,96 mm; el seco (mayo, junio, julio y agosto) con valores bajos de 15,41 mm; el intermedio (abril, setiembre, octubre y noviembre) con

51,89 mm, determinando la estacionalidad de la CV (Figura 6). Su clima presenta valores medios anuales de precipitación acumulada de 71,09 mm, con temperatura máxima del aire 12,73 °C, temperatura mínima del aire -0,35 °C, humedad relativa 40,43%, velocidad del viento 2,91 m/s y radiación solar 514,43 Ly (Moncada et al., 2020).

2.2. NDVI con imágenes Landsat TM, ETM+, OLI y MOD13Q1

Se clasificaron 194 imágenes Landsat de los sensores TM, ETM+ y OLI, libres de nubes, correspondientes a la escena Path 06 y Row 69, entre 5 a 6 imágenes por año desde enero de 1985 hasta diciembre de 2020, del servidor Visor de visualización Global de la USGS (GloVis) a través del enlace: <https://glovis.usgs.gov/app>. El preprocesamiento implica realizar la corrección radiométrica y atmosférica mediante el método Flaash (ITT Visual Information Solutions, 2009; Aguilar et al., 2014).

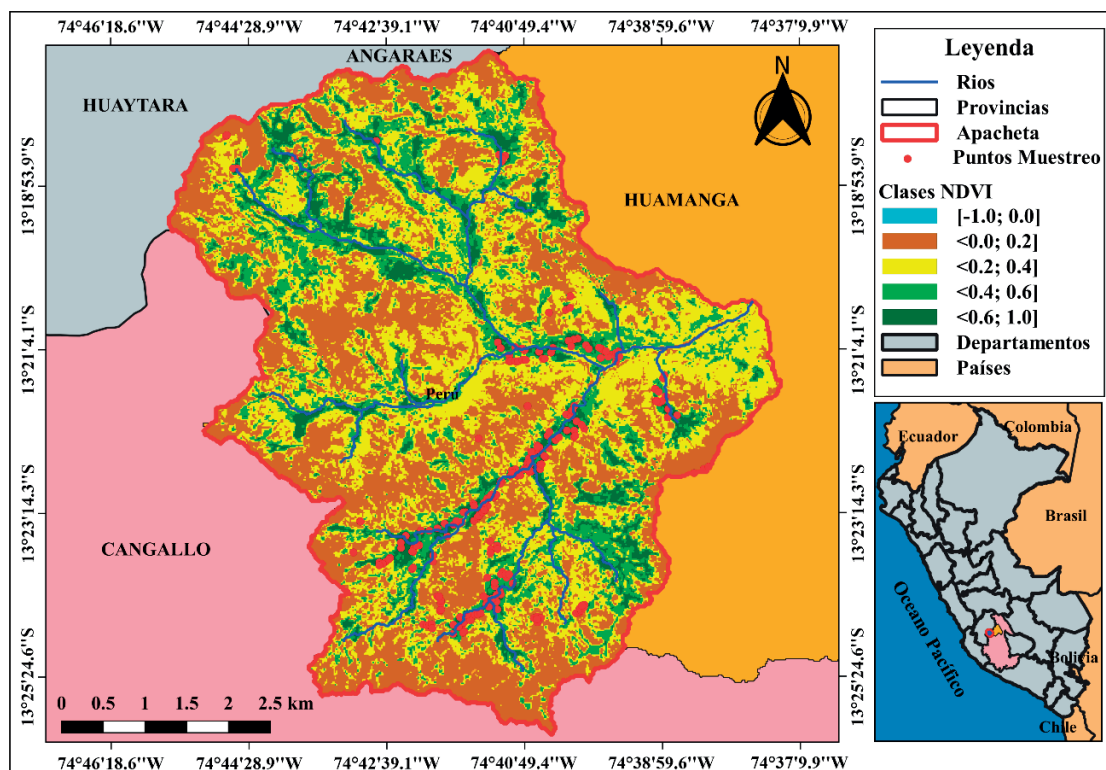


Figura 1. Ubicación geográfica de la microcuenca Apacheta, Región Ayacucho.

El cálculo del NDVI se realiza mediante los valores de reflectividad en la banda del infrarrojo cercano, NIR (ρ_{NIR}) y en la banda del rojo (ρ_R), según (Huete et al., 2002):

$$NDVI = \frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + \rho_R} \tag{1}$$

La descarga del producto MOD13Q1 del sensor MODIS, V6-L3, resolución 250 m, 16 días, se realiza del servidor NASA del Centro de Archivo Activo Distribuido de Procesos Terrestres (LP DAAC), a través de <https://lpdaac.usgs.gov/products/mod13q1v006/>, mediante el uso de “*library(MODISisp)*”, en R: “*MODISisp*”. El uso de imágenes Landsat y MODIS permite complementar los resultados y verificar la tendencia de CV en el mismo periodo.

2.3. Clasificación de la cobertura de vegetación (CV)

La selección de puntos con diferentes clases de CV, Figura 1, se ha realizado mediante muestreo aleatorio simple *in situ* (235 observaciones de clases de CV con GPS, Tabla 1), donde cada punto tiene la misma probabilidad de ser seleccionado a través de la funcionalidad de los espacios isomorfos que hace corresponder a cada punto *in situ* con los de la imagen Landsat. Para el cálculo del tamaño de muestra ($n=235$) se tomó el criterio de la varianza máxima para la proporción de éxito $p=0,5$ y la proporción de fracaso $1-p=0,5$ con un coeficiente de confianza del 95% para un $Z=1,96$ y un error de muestreo, $e=0,064$.

Para la validación de las clases de CV (Tabla 1), se contrastaron las clases estimadas de los rangos de valores del NDVI calculados en las imágenes Landsat en correspondencia con las clases observadas *in situ* en los mismos puntos de coordenadas. Esta correlación se da sobre las similitudes obtenidas de la diagonal principal de la matriz de convolución, además de las disimilitudes que están sobre o debajo de la diagonal principal (Sánchez, 2016), necesarios para la estimación del índice Kappa.

$$K = \frac{P_0 - P_e}{1 - P_e} \tag{2}$$

Donde, $P_0 = \sum_{i=1}^m P_{ii}$ es la proporción de acuerdos observados en la clasificación *in situ* y $P_e = \sum_{i=1}^m P_i * P_i^*$ la data satelital, y es la proporción de acuerdos esperados por el azar.

La Tabla 1 muestra el rango de valores de NDVI adoptada para la clasificación de la CV de acuerdo con las 235 muestras recogidas, Figura 1 (Olivo, 2017). Para el análisis de la tendencia anual, anomalías y pronóstico, se han considerado valores de $NDVI \geq 0,4$ geolocalizados en las imágenes Landsat y el producto MOD13Q1. Estos valores se corresponden con las zonas de vegetación dispersa (clase 4) y densa (clase 5) en la microcuenca Apacheta.

Tabla 1. Rango de valores de NDVI para la clasificación de CV en la microcuenca Apacheta.

Clase	Rango	Descripción
1	[-1,0;0,0]	Zonas con presencia de agua y/o sombra y/o nieve
2	<0,0;0,2]	Zonas de suelo desnudo seco
3	<0,2;0,4]	Zonas con vegetación escasa y suelo desnudo
4	<0,4;0,6]	Zonas con vegetación dispersa
5	<0,6;1,0]	Zonas con vegetación densa

Fuente: Adaptada de (Olivo, 2017).

2.4. Cálculo de la anomalía estandarizada (z) de CV

Se calcula midiendo la desviación de los datos de CV, x_i , respecto al valor medio \bar{x} de la CV, $x_i - \bar{x}$, en relación a la desviación estándar σ muestral (Spiegel y Stephens, 2009):

$$z = \frac{x_i - \bar{x}}{\sigma} \tag{3}$$

Los mapas de anomalías, Figura 3, se generan con la Ecuación (3) en las imágenes Landsat, para $NDVI \geq 0,4$. Las anomalías positivas (amarillo) se encuentran por encima del valor medio de la CV y representa ganancia. Los que coinciden con el valor medio de la CV (verde) no muestran cambios en ese año. Las anomalías negativas (rojo), por debajo del valor medio de la CV, expresan pérdida de vegetación.

2.5. Prueba de hipótesis y predicción de la CV

La prueba de Kolmogorov-Smirnov con corrección Lilliefors, (1967) es una prueba no paramétrica que se emplea para verificar si los datos proceden o no de una distribución normal, con variables cuantitativas continuas de tamaño muestral mayor de 50 (Dallal y Wilkinson, 1986). En un caso general, la función de distribución acumulativa empírica $F_{\xi_k}(x)$, para la muestra $\xi_j = (\xi_1, \dots, \xi_k)$ de tamaño k , se define como la fracción de datos menor o igual a x (Katchanov et al., 2019).

$$F_{\xi_k}(x) = \frac{1}{k} \sum_{j=1}^k \begin{cases} 1, & \text{si } \xi_j \leq x \\ 0, & \text{si } \xi_j > x \end{cases} \quad (4)$$

Se aplica la prueba Lilliefors, con el paquete *nortest*, en R: *lillie.test(Datos)*. La serie de tiempo mensual de la CV del producto MOD13Q1 se somete al análisis estadístico de los paquetes *auto.arima*, *forecast* y *prophet* para predecir un posible escenario futuro de 24 meses. En este procedimiento se combinan técnicas de regresión. En primer lugar, se ajustan los datos al mejor modelo *ARIMA(p,d,q)*, donde p , es el término de la componente auto regresiva (*AR*); d , es el término de la componente diferencial (*I*) y q , es el término de la componente de media móvil (*MA*), para series de tiempo estacionales con la función *auto.arima*. En segundo lugar, se cargan los datos y se aplica la librería *forecast* que utiliza la función *auto.arima*. Si al evaluar la serie de tiempo se determina que existe estacionalidad, entonces se construye el modelo *ARIMA(p,d,q)* no estacional (Hyndman y Khandakar, 2008):

$$\phi(B)(1 - B^d)y_t = c + \theta(B)\varepsilon_t \quad (5)$$

donde, ε_t , es el proceso de ruido blanco con media cero y varianza σ^2 ; B , es el operador de desplazamiento hacia atrás [$By_t = y_{t-1}$], $\theta(z)$, son polinomios de orden p y q . La librería *prophet*, utiliza modelos de regresión aditivo, que ajusta los parámetros de estacionalidad, cambios de tendencia y capacidad de crecimiento o irregularidades atípicas, generando pronósticos en la falta de datos, para un periodo de 24 meses de CV (Tornero, 2017; Moncada y Willems, 2020b).

3. Resultados y discusión

3.1. Validación de la clasificación de CV según rangos de NDVI

La Tabla 2 muestra los índices Kappa obtenidos de las matrices de confusión que relacionan las observaciones *in situ* con las clases estimadas a partir de los rangos de NDVI en las imágenes Landsat.

Tabla 2. Validación de la clasificación de CV, mediante el índice Kappa.

NDVI	Valor Kappa	p-valor	T aprox.	Fuerza de concordancia
22-05-2018	0,726	0,034	22,029	Buena
29-10-2018	0,741	0,033	22,598	Buena
10-06-2019	0,823	0,029	25,025	Muy buena
11-05-2020	0,570	0,038	17,775	Moderada
12-06-2020	0,850	0,027	25,875	Muy buena
16-09-2020	0,763	0,032	23,156	Buena
Promedio	0,746	0,032	22,743	Buena

El índice Kappa de valor medio 0,746 (p -valor=0,032; $\alpha=0,05$) valida la hipótesis estadística que postula la concordancia entre las clases de CV provenientes del NDVI a través de las observaciones *in situ* que no es debido a las probabilidades de ocurrencia del azar, si no a las probabilidades observadas en el trabajo de campo, siendo la concordancia, adecuada. Por tanto, los rangos de NDVI establecidos para dichas clases proporcionan confianza para la clasificación de la CV con un grado de error mínimo.

3.2. Anomalías del comportamiento de CV y prueba de normalidad

La vegetación más predominante (color verde) en los mapas de la Figura 2 toman los valores de las clases 4 y 5, $NDVI \geq 0,4$ de la Tabla 1, correspondiente a zonas con vegetación densa y dispersa, que cuantifican las zonas de bofedales.

Los datos de CV, x_i de la Tabla 3, permiten determinar la serie de tendencia anual y calcular las anomalías de la CV desde el año 1985 al 2020 mediante el uso de la Ecuación (3) para el cálculo de la anomalía estandarizada (z) para cada año.

La prueba Lilliefors, se aplica a los datos x_i : Área (ha) de la Tabla 3. El resultado muestra una discrepancia máxima en valor absoluto entre los datos medidos y teóricos, $D=0,075$, con un

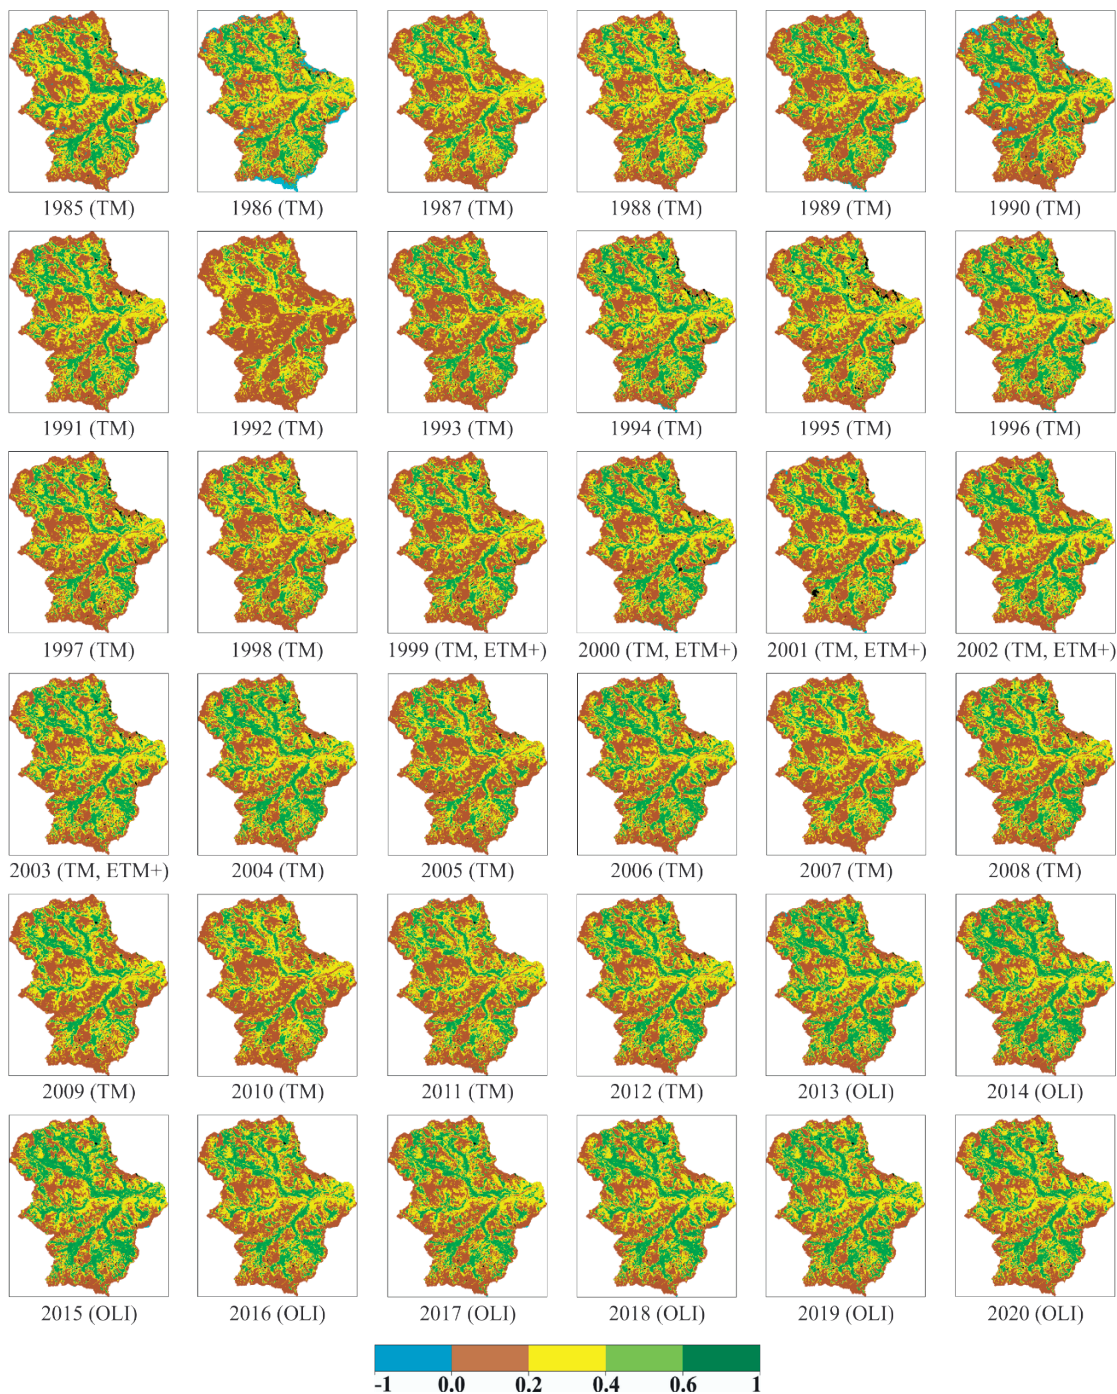


Figura 2. Mapas de clasificación de la CV media anual ($NDVI \geq 0,4$) con imágenes Landsat, en la microcuenca Apacheta, 1985 al 2020.

p -valor=0,001 menor al nivel de significancia ($\alpha=0,05$), que rechaza la hipótesis nula, lo que significa que los datos de CV media mensual no

proviene de una distribución normal. Esto sugiere que el pronóstico de CV tendrá un mayor sesgo.

Tabla 3. Anomalías estandarizadas de la CV ($NDVI \geq 0,4$) en imágenes Landsat, microcuenca Apacheta, 1985 al 2020.

Año	Nº Píxeles	x_i : Área (ha)	$(x_i - \bar{X})$	$(x_i - \bar{X})^2$	$(x_i - \bar{X})/\sigma$
1985	32584	2932,56	52,09	2713,52	0,0875
1986	34942	3144,78	264,31	69860,55	0,4441
1987	25745	2317,05	-563,42	317440,44	-0,9467
1988	27325	2459,25	-421,22	177425,05	-0,7078
1989	29062	2615,58	-264,89	70165,93	-0,4451
1990	29512	2656,08	-224,39	50350,21	-0,3770
1991	29954	2695,86	-184,61	34080,31	-0,3102
1992	18253	1642,77	-1237,70	1531897,65	-2,0796
1993	28204	2538,36	-342,11	117038,25	-0,5748
1994	38139	3432,51	552,04	304749,79	0,9276
1995	26950	2425,50	-454,97	206996,36	-0,7645
1996	38433	3458,97	578,50	334663,95	0,9720
1997	28626	2576,34	-304,13	92494,16	-0,5110
1998	24326	2189,34	-691,13	477658,64	-1,1613
1999	27270	2454,30	-426,17	181619,62	-0,7161
2000	35338	3180,42	299,95	89970,88	0,5040
2001	28606	2574,54	-305,93	93592,27	-0,5140
2002	35605	3204,45	323,98	104963,99	0,5444
2003	36259	3263,31	382,84	146567,59	0,6433
2004	39687	3571,83	691,36	477980,68	1,1617
2005	24415	2197,35	-683,12	466650,93	-1,1478
2006	37970	3417,30	536,83	288188,03	0,9020
2007	24497	2204,73	-675,74	456622,56	-1,1354
2008	31763	2858,67	-21,80	475,18	-0,0366
2009	29145	2623,05	-257,42	66264,30	-0,4325
2010	21623	1946,07	-934,40	873100,61	-1,5700
2011	27043	2433,87	-446,60	199450,25	-0,7504
2012	33801	3042,10	161,62	26121,50	0,2716
2013	41743	3756,87	876,40	768079,54	1,4726
2014	44108	3969,72	1089,25	1186468,77	1,8302
2015	48013	4321,17	1440,70	2075620,73	2,4207
2016	33931	3053,79	173,32	30040,33	0,2912
2017	34078	3067,02	186,55	34801,45	0,3135
2018	41227	3710,43	829,96	688836,04	1,3945
2019	41237	3711,33	830,86	690330,78	1,3961
2020	37471	3372,39	491,92	241986,73	0,8265
\bar{X} : Promedio		2880,47		Desviación Estándar Muestral (σ)	595,151

En los mapas de la Figura 3 se ha discriminado píxeles con $NDVI < 0,4$ con la finalidad de generar anomalías estandarizadas, Ecuación (3), para zonas con vegetación de clase 4 y 5, donde las zonas de color amarillo, anomalías positivas, con valores por encima del valor medio de CV indican ganancia de vegetación. Los valores de píxel que no difieren del valor medio de CV, anomalías neutras de color verde, indican que en ese periodo la vegetación no ha sufrido cambio significativo. Los píxeles de color rojo, anomalías negativas, están por debajo del valor medio de CV e indican pérdida de vegetación.

Respecto a la cuantificación de las anomalías de CV, la Figura 4, muestra anomalías positivas entre 0 y 2,4 por encima del valor medio 2.880,47 ha, en

1985, 1986, 1994, 1996, 2000, 2002, 2003, 2004, 2006, 2012 al 2020, experimentando un significativo incremento de CV en los últimos 9 años, siendo el año 2015 con mayor CV. Sin embargo, existen notables decrecimientos de CV en los años 1987 a 1993, 1995, 1997, a 1999, 2001, 2005, 2007 al 2011, con anomalías negativas inferiores a 0, por debajo del valor medio, siendo el año 1992 con menor CV. Por lo que, en comparación con los resultados de Nanzad et al. (2019), la variación de anomalías de CV mantiene una buena correlación temporal con las variables climáticas, precipitación y temperatura.

La Figura 5 muestra una tendencia anual creciente de CV correspondiente a zonas de bofedal con vegetación dispersa y densa, desde 1985 al 2020,



Figura 3. Mapas de anomalía estandarizada de la CV media anual (NDVI \geq 0,4) con imágenes Landsat, en la microcuenca Apacheta, 1985 al 2020.

cuyo comportamiento sigue el modelo descrito por:

$$CV \text{ (ha)} = 26,348 \times \text{Año} - 49.844 \quad (6)$$

De acuerdo con la Ecuación (6), en 1985 la CV media fue de 2.456,78 ha y el 2020, 3.378,96 ha, mostrando un significativo aumento de 922,81 ha equivalente al 6,4% del área total. Entre 1992




Figura 4. Anomalías estandarizadas de la CV media anual, con imágenes Landsat, en la microcuenca Apacheta, 1985 al 2020.




Figura 5. Tendencia de la CV (ha) media anual a partir del NDVI con imágenes Landsat, microcuenca Apacheta, 1985 al 2020.

y 2010 se resaltan valores bajos de CV y en el 2015 el valor más alto comparado con otros años. Han et al., (2019) afirman que la tendencia creciente de la CV depende de la elevación y del suelo, en contraste con otras de diferentes características con tendencia negativa. Sin embargo, Moncada y Willems, (2020a), indican que en los últimos nueve años el incremento de CV en la microcuenca Apacheta obedece al rápido derretimiento de la cobertura de nieve, debido al

incremento de la temperatura superficial del suelo de 4,9 °C en toda la microcuenca y de 5,8 °C en las zonas nevadas.

3.3. Tendencia anual de la CV con el producto MOD13Q1

El comportamiento estacional de la CV a partir del NDVI del producto MOD13Q1, desde el año 2000 al 2020 (Figura 6), indica que en los meses

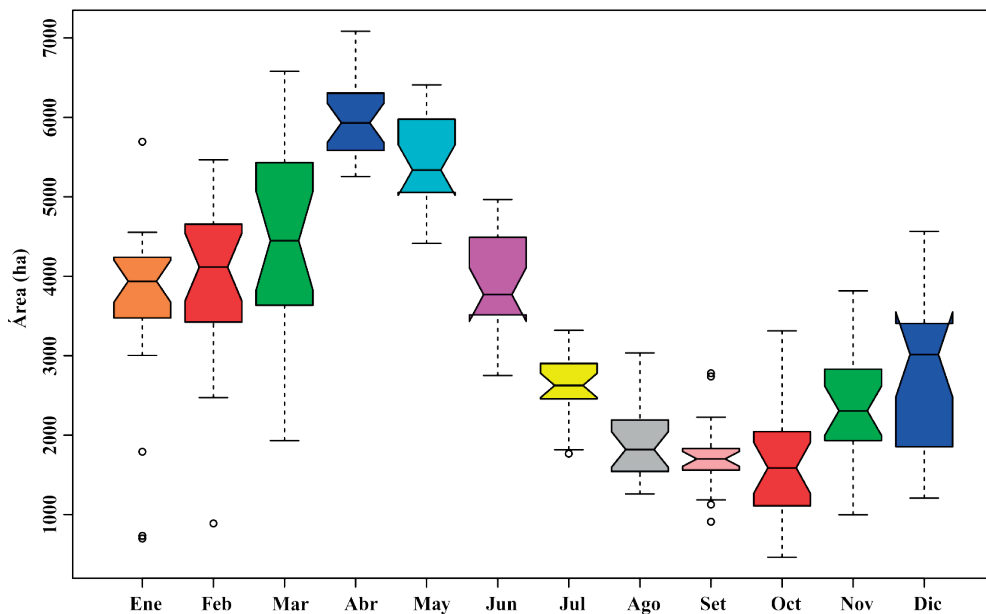


Figura 6. Diagrama de cajas de la estacionalidad de CV, a partir del NDVI del producto MOD13Q1, microcuenca Apacheta, 2000 al 2020.




Figura 7. Tendencia anual de la CV (ha) media anual, a partir del NDVI del producto MOD13Q1, microcuenca Apacheta, 2000 al 2020.

de marzo, abril y mayo se da la mayor CV en respuesta al estadio lluvioso. Lo contrario se observa en los meses de agosto, setiembre y octubre, después del estadio seco o invierno estacional en la microcuenca, con valores atípicos de CV (Moncada et al., 2020).

La tendencia anual de CV, Figura 7, muestra un significativo incremento entre los años 2000 al 2020, según el modelo:

$$CV (ha) = 7,3475 \times \text{Año} - 11.390 \tag{7}$$




Figura 8. Descomposición de la serie de tiempo de la CV, a partir del NDVI del producto MOD13Q1, microcuenca Apacheta, 2000 al 2020.

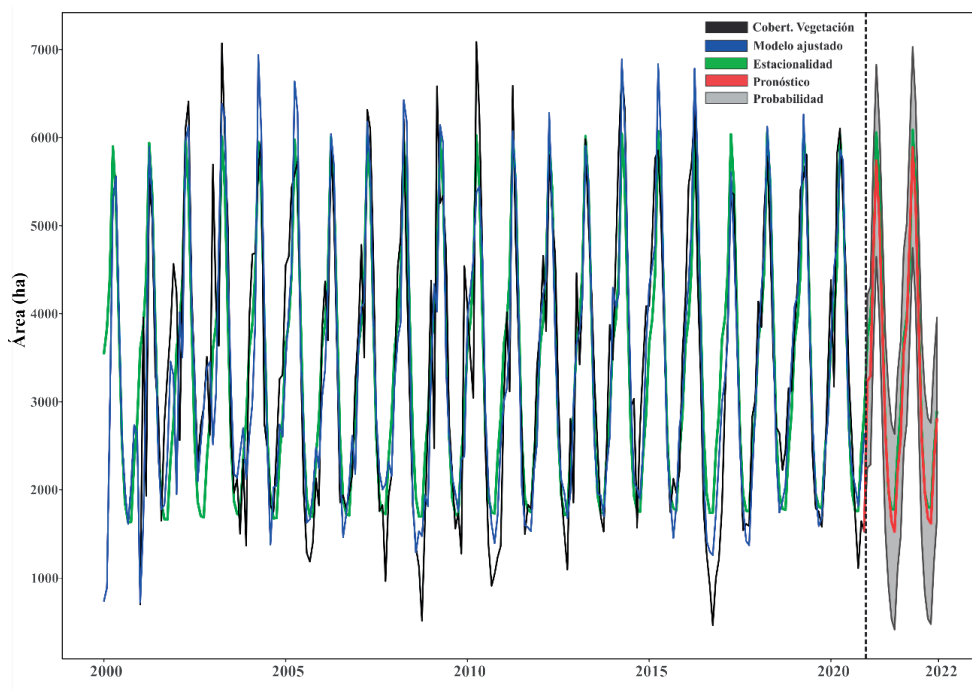


Figura 9. Serie de tiempo mensual de CV, NDVI del producto MOD13Q1, en la microcuenca Apacheta, 2000 al 2020 (negro). Datos ajustados al modelo (azul). Estacionalidad de datos modelados (verde). Pronóstico desde enero de 2021 a diciembre de 2022 (rojo). Rango de probabilidad del pronóstico de CV (sombra gris).

De acuerdo con la Ecuación (7), la CV media anual en el 2000 es 3.305,0 ha y en el 2020 es 3.451,95 ha, mostrando un significativo incremento de 146,95 ha equivalente al 1,02 % del área total. Los menores valores de CV se dan en los años 2000, 2008, 2010, 2016 y 2017, al contrario de los años 2002 y 2014 que tienen un elevado incremento. El incremento de la CV obtenido de la Ecuación 6 es mayor que el obtenido con la Ecuación 7, debido que, para este caso, la resolución espacial y temporal de las imágenes Landsat es mayor que para los datos obtenidos con MODIS.

La descomposición clásica de la serie de tiempo mensual de CV de la microcuenca desde el 2000 al 2020, Figura 8, muestra que la componente estacional es constante para cada año con la existencia de un patrón de producción de CV. La componente de tendencia indica que a medida que transcurre el tiempo el comportamiento de CV se hace constante entre el 2002 al 2015 para decaer el 2016 y volver a incrementarse el 2017 y 2018, sufriendo una ligera caída el 2020. En la componente de irregularidad, ruido blanco o residuo se muestran muchas variaciones, por lo que se concluye que hay estacionalidad.

3.4. Predicción de la CV del producto MOD13Q1

La Figura 9 muestra la serie de tiempo mensual de CV a partir del NDVI del producto MOD13Q1 en la microcuenca Apacheta durante los años 2000 al 2020, donde se determina el pronóstico del área de CV para los años 2021 y 2022.

El comportamiento del pronóstico de la CV para los años 2021 al 2022 es estacional con mayor sesgo debido a que los datos no provienen de una distribución normal, indicando una tendencia creciente al igual que las tendencias anuales mostradas en las figuras 5, 7 y 8, con valores mínimos por encima de los años anteriores.

4. Conclusiones

El índice Kappa determinó que existe concordancia entre las clases de CV observadas *in situ* con respecto a las clases estimadas de los rangos de NDVI calculados en las imágenes Landsat, dado que las dos referencias son espacios isomorfos; por tanto, proporcionan la misma información con

un error mínimo para estimaciones puntuales y con mayor precisión para estimaciones en intervalo, haciendo que las clases con $NDVI \geq 4$ permitan comprender la dinámica de las zonas de bofedal y pastos de puna, correspondientes a la vegetación representativa de la microcuenca Apacheta.

La tendencia positiva de CV, según el NDVI de las imágenes Landsat, indica que a finales de 2020 hubo un incremento significativo, al igual que la tendencia generada con el producto MOD13Q1, siendo ambos resultados similares. De igual modo, las anomalías estandarizadas muestran un significativo incremento de la CV entre el 2012 al 2020 con anomalías positivas por encima del valor medio y con incremento significativo en el 2013 al 2015, 2018 y 2019. Asimismo, se detectaron anomalías negativas en algunos años anteriores (1992 y 2010).

Debido a que los datos de CV no proceden de una distribución normal, la predicción obtenida en el 2021 y 2022 es aceptable, evidenciándose un comportamiento estacional con valores máximos de CV en los meses de marzo, abril y mayo en respuesta al estadio lluvioso y con valores mínimos de CV mayores a los años anteriores. En base a estos posibles escenarios y teniendo en cuenta la influencia de patrones climáticos, se infiere que el incremento de CV a largo plazo tendrá un límite, el cual dependerá de manera directa de la disponibilidad del recurso hídrico en la microcuenca Apacheta, por lo que se recomienda evaluar la humedad del suelo de bofedal y factores climáticos que impactan en el comportamiento de estos ecosistemas, importantes para la recarga hídrica.

Agradecimientos

Este trabajo ha sido posible gracias a los proyectos “*Strengthening resilience of Andean river basin headwaters facing global change*” (PGA_084063), financiado por el Programa PEER de USAID y “Modelado de aguas subterráneas en los ecosistemas de humedales de la microcuenca Apacheta”, financiado por FOCAM de la Universidad Nacional de San Cristóbal de Huamanga. Los autores también agradecen a la Universidad Nacional de Frontera por su apoyo incondicional.

Referencias

- Abujayyab, S. K., Karaş, İ. R. 2019. Automated Prediction System for Vegetation Cover Based on MODIS-NDVI Satellite Data and Neural Networks. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLII-4/W19*, 9-15. <https://doi.org/10.5194/isprs-archives-XLII-4-W19-9-2019>
- Aguilar, H., Mora, R., Vargas, C. 2014. Metodología para la corrección atmosférica de imágenes Aster, Rapideye, Spot 2 y Landsat 8 con el módulo Flaash del software Envi. *Revista Geográfica de América Central*, 2(53), 39-59. <https://doi.org/10.15359/rgeac.2-53.2>
- Cairns, D. M. 2001. A Comparison of Methods for Predicting Vegetation Type. *Plant Ecology*, 156(1), 3-18. <https://doi.org/10.1023/A:1011975321668>
- Ceroni, M., Achkar, M., Gazzano, I., Burgeño, J. 2015. Estudio del NDVI mediante análisis multiescalar y series temporales utilizando imágenes SPOT, durante el período 1998-2012 en el Uruguay. *Revista de Teledetección. Asociación Española de Teledetección*, 43, 31-42. <https://doi.org/10.4995/raet.2015.3683>
- Dallal, G. E., Wilkinson, L. 1986. An Analytic Approximation to the Distribution of Lilliefors's Test Statistic for Normality. *The American Statistician*, 40(4), 294-296. <https://doi.org/10.1080/00031305.1986.10475419>
- Forzieri, G., Castelli, F., Vivoni, E. R. 2010. A Predictive Multidimensional Model for Vegetation Anomalies Derived From Remote-Sensing Observations. *IEEE Transactions on Geoscience and Remote Sensing*, 48(4), 1729-1741. <https://doi.org/10.1109/TGRS.2009.2035110>
- Han, J., Huang, Y., Zhang, H., Wu, X. 2019. Characterization of elevation and land cover dependent trends of NDVI variations in the Hexi region, northwest China. *Journal of Environmental Management*, 232, 1037-1048. <https://doi.org/10.1016/j.jenvman.2018.11.069>
- Hoek van Dijke, A. J., Mallick, K., Teuling, A. J., Schlerf, M., Machwitz, M., Hassler, S. K., Blume, T., Herold, M. 2019. Does the Normalized Difference Vegetation Index explain spatial and temporal variability in sap velocity in temperate forest ecosystems? *Hydrology and Earth System Sciences*, 23(4), 2077-2091. <https://doi.org/10.5194/hess-23-2077-2019>
- Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., Ferreira, L. G. 2002. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1), 195-213. [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2)
- Hyndman, R., Athanasopoulos, G., Bergmeir, C., Caceres, G., Petropoulos, F., Chhay, L., O'Hara-Wild, M., Yasmeeen, F. 2020. *Package «Forecast». Forecasting functions for time series and linear models*. <https://pkg.robjhyndman.com/forecast/>
- Hyndman, R. J., Khandakar, Y. 2008. Automatic Time Series Forecasting: The forecast Package for R. *Journal of Statistical Software*, 27(1), 1-22. <https://doi.org/10.18637/jss.v027.i03>
- ITT Visual Information Solutions. 2009. *ENVI Atmospheric Correction Module: QUAC and FLAASH User's Guide, Version 4.7*, pp. 44. http://www.harrisgeospatial.com/portals/0/pdfs/envi/Flaash_Module.pdf
- Katchanov, Y. L., Markova, Y. V., Shmatko, N. A. 2019. The distinction machine: Physics journals from the perspective of the Kolmogorov-Smirnov statistic. *Journal of Informetrics*, 13(4), 100982. <https://doi.org/10.1016/j.joi.2019.100982>
- Lilliefors, H. W. 1967. On the Kolmogorov-Smirnov Test for Normality with Mean and Variance Unknown. *Journal of the American Statistical Association*, 62(318), 399-402. <https://doi.org/10.1080/01621459.1967.10482916>
- Moncada, W., Willems, B. 2020a. Spatial and temporal analysis of surface temperature in the Apacheta micro-basin using Landsat thermal data. *Revista de Teledetección*, 0(57), 51-63. <https://doi.org/10.4995/raet.2020.13855>
- Moncada, W., Willems, B. 2020b. Tendencia anual del caudal de salida, en referencia al caudal ecológico en la microcuenca Apacheta / Ayacucho / Perú, del 2000 al 2018. *Ecología Aplicada*, 19(2), 93-102. <https://doi.org/10.21704/rea.v19i2.1560>
- Moncada, W., Willems, B., Rojas, J. 2020. Estimación de estadios estacionales a partir de parámetros climáticos medidos en la estación meteorológica de la microcuenca Apacheta, Región Ayacucho, 2000 al 2018. *Revista de Investigación de Física. UNMSM*, 23(2), 17-25. <https://doi.org/10.15381/rif.v23i2.20296>
- Nanzad, L., Zhang, J., Tuvdendorj, B., Nabil, M., Zhang, S., Bai, Y. 2019. NDVI anomaly for drought monitoring and its correlation with climate factors over Mongolia from 2000 to 2016. *Journal of Arid Environments*, 164, 69-77. <https://doi.org/10.1016/j.jaridenv.2019.01.019>
- Neinavaz, E., Skidmore, A. K., Darvishzadeh, R. 2020. Effects of prediction accuracy of the proportion of vegetation cover on land surface emissivity and temperature using the NDVI threshold method. *International Journal of Applied Earth Observation and Geoinformation*, 85, 101984. <https://doi.org/10.1016/j.jag.2019.101984>

- Olivo, A. 2017. *Clasificación de la vegetación del Karst de Sierra de las Nieves, utilizando imágenes Landsat* (Sierra de las Nieves, Málaga, Andalucía, España) [Masters, E.T.S.I de Minas y Energía]. <http://oa.upm.es/48286/>
- Pereda, A., Moncada, W., Verde, L. 2018. *Respuesta nival de la cabecera de cuenca Cachi-Apacheta de Ayacucho: Vol. I*. Editorial Académica Española. <https://www.morebooks.shop/store/es/book/respuesta-nival-de-la-cabecera-de-cuenca-cachi-apacheta-de-ayacucho/isbn/978-620-2-12620-5>
- Qiu, B., Zeng, C., Cheng, C., Tang, Z., Gao, J., Sui, Y. 2014. Characterizing landscape spatial heterogeneity in multisensor images with variogram models. *Chinese Geographical Science*, 24(3), 317-327. <https://doi.org/10.1007/s11769-013-0649-y>
- Rashmi, M. K., Lele, N. 2010. Spatial modeling and validation of forest cover change in Kanakapura region using GEOMOD. *Journal of the Indian Society of Remote Sensing*, 38(1), 45-54. <https://doi.org/10.1007/s12524-010-0011-0>
- Sánchez, J. M. 2016. Análisis de Calidad Cartográfica mediante el estudio de la Matriz de Confusión. *Pensamiento Matemático*, 6(2), 9-26. Disponible en <https://dialnet.unirioja.es/servlet/articulo?codigo=5998855>
- Spiegel, M., Stephens, L. 2009. *Estadística* (4a edición). McGraw-Hill. Interamericana Editores, S.A. https://www.academia.edu/36241872/Estad%C3%ADstica_Serie_Schaum_4ta_edici%C3%B3n_Murray_R_Spiegel_pdf_1_1_
- Taylor, S., Letham, B. 2017. Forecasting at scale. *PeerJ Preprints* 5, 25. <https://doi.org/10.7287/peerj.preprints.3190v2>
- Tornero, J. 2017. Introducción al Forecasting con R Statistics [Estadística]. *Doctor Metrics*. <https://www.doctormetrics.com/introduccion-al-forecasting-con-r-statistics/>
- Zaraza, M. A., Manrique, L. M. 2019. Generation of change data of land cover in the Bogotá savannah using time series with Landsat images and MODIS-Landsat synthetic images between 2007 and 2013. *Revista de Teledetección*, 0(54), 41-58. <https://doi.org/10.4995/raet.2019.12280>