

# Cambios en la producción primaria bruta (GPP) de la vegetación natural en la Comunidad Valenciana (2001-2018)

Beatriz Martínez\*, Sergio Sánchez-Ruiz, Manuel Campos-Taberner,  
Francisco Javier García-Haro, María Amparo Gilabert

*UV-Environmental Remote Sensing Group (UV-ERS). Departament de Física de la Terra i Termodinàmica. Facultat de Física. Universitat de València. Dr. Moliner, 50. 46100. Burjassot. València.*

**Resumen:** Este trabajo analiza los cambios en la vegetación natural de la Comunidad Valenciana experimentados durante el periodo 2001-2018. Para ello se utiliza un producto de GPP (*Gross Primary Production*) diario a 1 km de resolución espacial obtenido con el modelo de eficiencia en el uso de la radiación propuesto por Monteith, combinando datos de observación de la Tierra (EO) (e.g., MODIS/Terra-Aqua y SEVIRI/MSG) y datos meteorológicos (e.g., precipitación y temperatura). La detección de cambios se ha llevado a cabo aplicando un análisis multi-resolución (AMR) basado en la transformada *wavelet* (TW) a las series temporales de GPP. Este análisis permite descomponer la serie en varias componentes con resoluciones temporales diferentes. La tendencia, positiva o negativa, de la componente que se asocia con la variabilidad interanual es la que determina el cambio, positivo (*greening*) o negativo (*browning*) de la actividad fotosintética a largo plazo. Los cambios graduales negativos detectados en la vegetación natural ponen de manifiesto la existencia de zonas caracterizadas con un cierto nivel de degradación y que, además, coinciden con zonas incluidas dentro de programas de conservación, como por ejemplo el Parque Natural de la *serra d' Espadà* en Castellón. Para poder identificar estas zonas se han eliminado previamente las zonas con cambios bruscos negativos que son consecuencia de incendios en los que la regeneración de la vegetación es muy lenta o todavía no se ha completado. Estas zonas presentan un buen acuerdo con la cartografía de incendios proporcionada por la *Generalitat Valenciana*.

**Palabras clave:** producción primaria bruta, cambios, incendios forestales, *wavelets*.

## **Gross primary production (GPP) changes of natural vegetation in the Comunidad Valenciana (2001-2018)**

**Abstract:** This work analyzes the vegetation changes in the Comunidad Valenciana observed during the period 2001-2018, using the daily GPP (*Gross Primary Production*) time series at 1-km spatial resolution derived from Earth observation-based (EO) data. The GPP time series have been obtained from EO-based data (e.g., MODIS/Terra-Aqua and SEVIRI/MSG) and meteorological (e.g., precipitation and temperature) data using the light use efficiency model proposed by Monteith. The carbon fluxes detection has been performed by means of a multi-resolution analysis (MRA) based on the wavelet transform (WT). This analysis allows to decomposing the signal into different temporal resolution components. The interannual trend determines the vegetation change, positive (*greening*) or negative (*browning*) of vegetation photosynthetic activity over long-term scales. The negative long-term changes observed in natural vegetation reveal the presence of areas characterized by high degraded conditions. This is the case of Natural Park of 'Serra d' Espadà' in Castellon province, which is also controlled

**To cite this article:** Martínez, B., Sánchez-Ruiz, S., Campos-Taberner, M., García-Haro, F.J., Gilabert, M.A. 2023. Gross primary production (GPP) changes of natural vegetation in the Comunidad Valenciana (2001-2018). *Revista de Teledetección*, 61, 15-27. <https://doi.org/10.4995/raet.2023.18659>

\* Corresponding author: [beatriz.martinez@uv.es](mailto:beatriz.martinez@uv.es)

by a local ecosystem conservation program. To identify more precisely these areas, the areas affected by abrupt changes (associated to forest fires) in which vegetation has not been yet recovered have been removed. In this case, the results show a good agreement with the official burnt areas from the local government.

**Key words:** gross primary production, changes, forest fires, wavelets.

## 1. Introducción

El análisis de la dinámica de la vegetación permite comprender su capacidad de respuesta ante perturbaciones como, por ejemplo, las debidas al cambio climático, cada vez más frecuentes. Como consecuencia, la vegetación presenta una variabilidad a diversas escalas espaciales y temporales. En el caso de los ecosistemas de la cuenca mediterránea, diversos estudios evidencian cambios registrados en los usos del suelo y en la gestión de los recursos naturales (Poyatos et al., 2003). El estudio de los cambios en los ecosistemas terrestres mediante el uso de sensores remotos, junto con el desarrollo de herramientas de modelización, ha dado lugar a un conocimiento más profundo del estado de los ecosistemas. Hasta la fecha, el producto más utilizado en el estudio de cambios en la cubierta vegetal a partir de series temporales de teledetección ha sido el índice de vegetación de diferencia normalizada (NDVI) (Rouse et al., 1974; Huang et al., 2020). Las ventajas que ofrece son, principalmente, su fácil cálculo y la disponibilidad de series temporales largas de diferentes satélites a distintas resoluciones espaciales y temporales, como es el caso de los datos proporcionados por los sensores *Advanced Very High Resolution Radiometer* (AVHRR) a bordo del satélite *National Oceanic and Atmospheric Administration* (NOAA) (Alcaraz-Segura et al., 2010; de Jong et al., 2011; Zhao et al., 2015) desde finales de los años 70. A pesar de que la bibliografía muestra que el NDVI presenta correlaciones con variables biofísicas como el índice de superficie foliar (LAI, *Leaf Area Index*), el contenido en clorofila, la fracción de cubierta vegetal (FVC, *Fraction of Vegetation Cover*) o la fracción de radiación fotosintéticamente activa absorbida por la cubierta ( $f_{\text{APAR}}$ , *Fraction of Absorbed Photosynthetically Active Radiation*), no deja de ser una variable adimensional cuya interpretación depende de estas correlaciones. En las dos últimas décadas se ha realizado un ingente esfuerzo en obtener a partir de datos de observación de la Tierra (EO, *Earth Observation*) variables biofísicas que se puedan interpretar más

fácilmente. Entre otras, se han desarrollado metodologías operativas para cuantificar los flujos de carbono (Running et al., 2004; Xiao et al., 2019) que la vegetación intercambia con la atmósfera. A través de estas imágenes se pueden analizar los diferentes patrones espacio-temporales que se presentan, así como evaluar dichos flujos y su vinculación con la producción de alimentos, madera y fibra (Chapin III et al., 2002; Xiao et al., 2019). En particular, para explorar la respuesta de los ecosistemas a perturbaciones externas como las antropogénicas o las debidas al cambio climático, se puede recurrir a cuantificar su actividad fotosintética (Schimel, 1995), por ejemplo a través de la producción primaria bruta (GPP, *Gross Primary Production*). La GPP cuantifica la cantidad de carbono fijado por los ecosistemas a través de la fotosíntesis, que constituye el mayor flujo de carbono entre la biosfera terrestre y la atmósfera. Los cambios experimentados por la cubierta afectan directamente al proceso de fotosíntesis de la planta y, por tanto, se reflejan directamente en la GPP.

Desde el primer producto operacional de GPP proporcionado por el programa del Sistema de Observación de la Tierra de la NASA (*National Aeronautics and Space Administration*) a principios del 2000 (Running et al., 2004) a través del espectrorradiómetro MODIS a una resolución espacial de 1 km, se han ido desarrollando otros productos operacionales a partir de modelos a diferentes escalas espaciales y temporales. Este es el caso de los productos MODIS MOD17A2 y MOD17A3 v006 (Heinsch et al., 2006), el producto diario SMAP (*Soil Moisture Active Passive*) Level-4 carbon (L4\_C) a 9 km (Jones et al., 2017; Kimball et al., 2017) de la NASA o el producto de productividad bruta de materia seca (GDMP, *Gross Dry Matter Productivity*) a 1 km (CGLOPS1, 2018) del *Copernicus Global Land Service* (CGLS) de la Agencia Espacial Europea (ESA, *European Space Agency*). Todos ellos utilizan el modelo de eficiencia en el uso de la radiación propuesto por Monteith (1972). También conviene mencionar en este contexto al

producto FLUXCOM, que es mensual y a una resolución espacial de  $0,5^\circ \times 0,5^\circ$  (Tramontana et al., 2016) del Instituto Max Planck de Biogeoquímica. Aunque no se trata de un producto operacional, se ha obtenido integrando datos EO junto con estimaciones de la GPP procedentes de medidas *in situ* en torres *eddy covariance* (EC) utilizando métodos de aprendizaje automático (ML, *Machine Learning*).

Las técnicas más utilizadas en el estudio de la dinámica de la vegetación a partir de series temporales largas se pueden clasificar en (i) métodos de análisis estadístico, como por ejemplo las técnicas más clásicas que utilizan el análisis por componentes principales o la media móvil (Li et al., 2003; Rigina y Rasmussen, 2003) o las técnicas más novedosas basadas en métodos de regresión, segmentación de la serie o ajuste de modelos (de Beurs y Henebry, 2005; Verbesselt et al., 2010; Jamali et al., 2015) y, (ii) los métodos de análisis espectral, como la transformada de Fourier (TF) (Azzali y Menenti, 2000; Stöckli y Vidale, 2004) y la transformada *wavelet* (TW) (Martínez y Gilabert, 2009; Rhif et al., 2019). En el análisis multitemporal de la dinámica de la vegetación a partir de series largas, la TW ha mostrado una alta eficiencia en el estudio local de series no estacionarias (i.e., su media y varianza no permanecen constantes y la serie temporal presenta una tendencia con el tiempo) y de rápida transitoriedad (Furon et al., 2008; Martínez y Gilabert, 2009; Martínez et al., 2011; Giner et al., 2012; Ben Abbes et al., 2018). La TW proporciona, de manera simultánea, información sobre cuándo ocurren los fenómenos bajo estudio y su amplitud. Además, la TW permite realizar un análisis multi-resolución (AMR), que ha demostrado ser de gran utilidad para estudiar la evolución temporal de los ecosistemas vegetales al permitir descomponer la señal radiométrica en varias componentes a diversas escalas temporales.

El objetivo de este trabajo consiste en analizar los cambios experimentados por la vegetación natural en la Comunidad Valenciana a lo largo de casi dos décadas, utilizando como variable el flujo de carbono GPP. Para ello, se ha aplicado un análisis multi-resolución basado en la transformada *wavelet* (AMR-TW) a la serie temporal diaria de GPP a 1 km. Esta serie se ha obtenido a partir de una metodología robusta que utiliza el modelo de

Monteith (1972), combinando datos EO con datos meteorológicos espacializados procedentes de estaciones de la Agencia Española de Meteorología (AEMet). La información obtenida se analizará conjuntamente con datos de precipitación, con el fin de interpretar la naturaleza de las variaciones y proporcionar un mapa de cambios para el periodo considerado. Es de gran interés identificar los cambios graduales (negativos) que presentan las cubiertas en procesos de degradación, debido al escenario de cambio climático que estamos viviendo actualmente y que afecta, principalmente, a zonas áridas y semiáridas. Según las previsiones climáticas, en 2100 más del 20% de las tierras emergidas del planeta podrían cruzar uno o varios umbrales de aridez (Berdugo et al., 2020). En estos casos, donde el principal factor limitante es la disponibilidad de agua, la disminución de la cubierta es gradual y sutil, por lo que se requiere de técnicas que proporcionen la tendencia de la serie temporal con un valor bajo de la incertidumbre asociada.

## 2. Datos

### 2.1. GPP

La aproximación clásica de Monteith (1972) permite el cálculo de la GPP diaria ( $\text{g m}^{-2} \text{d}^{-1}$ ) a partir de la siguiente expresión:

$$\text{GPP} = \epsilon f_{\text{APAR}} \text{PAR} \quad (1)$$

donde PAR ( $\text{MJ m}^{-2} \text{d}^{-1}$ ) es la radiación fotosintéticamente activa, que comprende la radiación solar incidente en el rango espectral entre 0,4 mm y 0,7 mm, suponiendo un 46% de la irradiación global. La serie de PAR diaria se ha generado a partir de la irradiación global obtenida con el método propuesto por Moreno et al. (2011), que utiliza redes neuronales (RNAs) con parámetros de entrada proporcionados por la red de estaciones meteorológicas de la AEMet, previamente espacializados a 1 km mediante la técnica geostatística de *kriging* (Alsamamra et al., 2009). En concreto se consideran la temperatura máxima, temperatura mínima y precipitación. Además, se tiene en cuenta la irradiación solar global extraterrrestre. Moreno et al. (2011) muestran que el error absoluto asociado con la irradiación global diaria es de  $2,3 \text{ MJ m}^{-2} \text{d}^{-1}$ .

La fracción de PAR absorbida por la cubierta vegetal,  $f_{\text{APAR}}$  (adimensional), se ha obtenido a partir del cálculo del índice de vegetación RDVI (*Renormalized Difference Vegetation Index*) (Roujean y Bréon, 1995) definido como:

$$\text{RDVI} = \frac{\rho_{\text{IRC}} - \rho_{\text{R}}}{\sqrt{\rho_{\text{IRC}} + \rho_{\text{R}}}} \quad (2)$$

donde  $\rho_{\text{R}}$  y  $\rho_{\text{IRC}}$  corresponden a las reflectividades en las bandas del rojo e infrarrojo cercano para una geometría óptima que minimiza el efecto de las incertidumbres asociadas con los ángulos de observación y con el suelo de fondo. Esta metodología se utiliza para derivar el producto operacional  $f_{\text{APAR}}$  diario (MdfAPAR; LSA-425) cada 10 días (MTfAPAR; LSA-426) a partir de datos SEVIRI/MSG (<https://landsaf.ipma.pt/en/data/catalogue/>). En nuestro caso, se ha empleado el modelo semiempírico de la función de reflectividad bidireccional (BRDF) del producto MODIS (MCD43A1), para obtener  $\rho_{\text{R}}$  y  $\rho_{\text{IRC}}$  y calcular el RDVI, a una resolución temporal de 8 días y una espacial de 1 km. Por último, las series temporales se han filtrado y reconstruido a partir del método de regresión local LOESS (*LOcally Estimated Scatterplot Smoothing*) optimizado para obtener imágenes diarias de  $f_{\text{APAR}}$ . El detalle de la metodología se puede encontrar en (Gilabert et al., 2015).

Por último, la eficiencia en el uso de la radiación,  $\varepsilon$  (g MJ<sup>-1</sup>), se considera igual al producto de una eficiencia máxima,  $\varepsilon_{\text{max}}$  (g MJ<sup>-1</sup>), dependiente del tipo de cubierta vegetal (asociada a su funcionamiento óptimo), y de dos escalares adimensionales  $F(w)$  y  $G(T)$  que cuantifican la reducción en  $\varepsilon_{\text{max}}$  debida al déficit hídrico y al estrés térmico por baja temperatura, respectivamente (Gilabert et al., 2015).  $\varepsilon_{\text{max}}$  presenta un rango de variación de 1,1 g MJ<sup>-1</sup> a 1,8 g MJ<sup>-1</sup>, y se ha generado utilizando un mapa híbrido (Pérez-Hoyos et al., 2012a) de tipos de cubierta vegetal y datos de bibliografía. El mapa híbrido se realiza a partir de una combinación sinérgica de cuatro productos de cubiertas del suelo (CORINE, GLC2000, MODIS y GlobCover) a partir de un sistema de votación basado en: 1) la precisión de cada producto para un tipo de cubierta determinada, y 2) el uso de la lógica difusa y el FAO-LCCS (*Land Cover Classification System*). La lógica difusa se ha utilizado para traducir las diferentes leyendas de acuerdo a una serie de atributos comunes (e.g., presencia de vegetación)

definidos en el LCCS y estableciendo una métrica de solape entre las diferentes leyendas (más detalles en Pérez-Hoyos et al., 2012b).

Por otra parte, como  $F(w)$  se utiliza el coeficiente de estrés hídrico,  $C_{\text{ws}}$ , que se define como:

$$C_{\text{ws}} = 0.5 + 0.5 (AET/ET_0) \quad (3)$$

siendo AET la evapotranspiración actual y  $ET_0$  la evapotranspiración potencial la potencial (PET) (véase Gilabert et al. (2015) para más detalle). La expresión indica que la máxima reducción en la eficiencia por efecto del estrés hídrico se estima en un 50%.

Por último, como factor corrector del estrés térmico por bajas temperaturas,  $G(T)$ , se ha utilizado un parámetro que depende de la temperatura mínima que se emplea en el producto oficial GPP de MODIS, MOD17 (Heinsch et al., 2006). Como el valor umbral de temperatura mínima diaria es diferente para cada tipo de vegetación, se incorpora en el algoritmo a través del mapa híbrido de tipos de vegetación utilizado para parametrizar  $\varepsilon_{\text{max}}$ .

## 2.2. Precipitación

Se han utilizado imágenes de precipitación diaria a una resolución espacial de 1 km derivadas del espacializado mediante *kriging* de datos de precipitación acumulada diaria de la red de estaciones meteorológicas de la AEMet.

Se ha calculado el índice de precipitación estandarizado SPI (*Standardized Precipitation Index*) (McKee et al., 1993) a partir del ajuste de las series de precipitación a una función de distribución de probabilidad Gamma para el periodo determinado de tiempo y para la zona de estudio. La función Gamma se transforma después a una función normal con media cero y desviación estándar uno. El SPI admite diversas interpretaciones en función de su escala de tiempos. Por ejemplo, dado el mes  $i$ , el SPI de 1 mes utiliza sólo la precipitación registrada en ese mes  $i$ ; el de 2 meses, la precipitación de los meses  $i$  e  $i-1$ , el SPI de 3 meses, la de  $i$ ,  $i-1$  e  $i-2$ , etc. Por lo tanto, el SPI1 refleja condiciones a corto plazo, el SPI3 y el SPI6 proporcionan estimaciones estacionales de la precipitación, etc. En nuestro caso, el SPI se ha calculado a una escala de 12 meses, que proporciona las variaciones interanuales de la precipitación con respecto a su valor

medio en el periodo (2001-2018). El SPI presenta algunas ventajas sobre otros índices: su simplicidad, su consistencia espacial y su flexibilidad temporal, permitiendo observar déficits de agua a diferentes escalas.

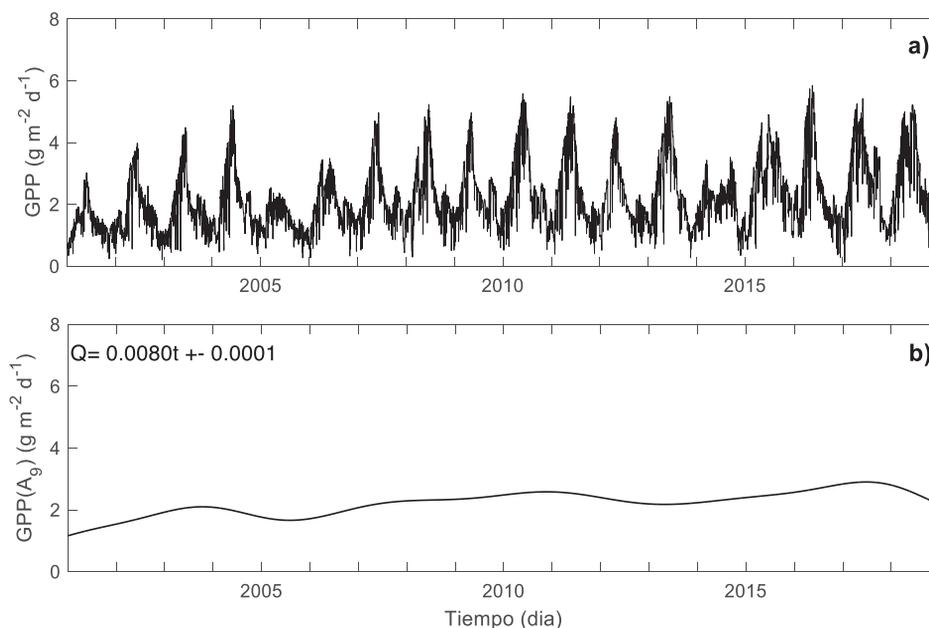
### 3. Análisis multiresolución basado en la transformada *wavelet*

La detección de cambios en la vegetación se ha llevado a cabo a partir del análisis de su variabilidad interanual. Para ello, se ha aplicado el AMR basado en la TW (Percival y Walden, 2000). Esta técnica permite descomponer la señal original en varias componentes asociadas a diferentes resoluciones temporales mediante la aplicación de un filtro de paso alto o de detalle ( $D$ ) y un filtro de paso bajo o de aproximación ( $A$ ) trasladando una onda finita denominada *wavelet* madre (WM) (Martínez y Gilabert, 2009). De este modo, la señal original  $f(t)$  se puede reconstruir a partir de la siguiente expresión:

$$f(t) = A_J(t) + \sum_{j=1}^J D_j(t) \quad (4)$$

donde  $J$  es el nivel más alto de descomposición considerado,  $A_J$  es la componente de aproximación para el nivel más alto y  $D_j$  son las diferentes componentes de detalle hasta llegar al nivel más alto.

Las escalas temporales en las que se descompone la serie temporal vienen condicionadas por la frecuencia central de la WM utilizada y por la resolución temporal de la serie original. Este método se ha aplicado con éxito en la detección de cambios a diferentes escalas, zonas de estudio y series temporales (Martínez y Gilabert, 2009, Martínez et al., 2011, Giner et al., 2012). En la mayoría de ellos, se ha utilizado la WM *Meyer*, que presenta un comportamiento suave que permite detectar, principalmente, tendencias monotónicas a largo plazo en la vegetación como, por ejemplo, cambios debido a procesos de degradación de la cubierta o desertificación. Utilizando esta *wavelet* madre, el AMR permite descomponer la serie diaria en 9 componentes de aproximación con los siguientes periodos para la WM Meyer:  $j=1$  (1,5 días),  $j=2$  (3 días),  $j=3$  (6 días),  $j=4$  (12 días),  $j=5$  (24 días),  $j=6$  (48 días),  $j=7$  (96 días),  $j=8$  (198 días) y  $j=9$  (385 días). El último nivel estaría asociado en este caso a la variabilidad interanual. La figura 1 muestra un ejemplo simplificado de la descomposición



**Figura 1.** (a) Ejemplo de serie temporal original de GPP para un píxel de matorral. (b) Componente de aproximación  $A_9$  resultante de aplicar el método AMR-WT con la WM *Meyer*. Se observa, en este caso, una tendencia positiva.

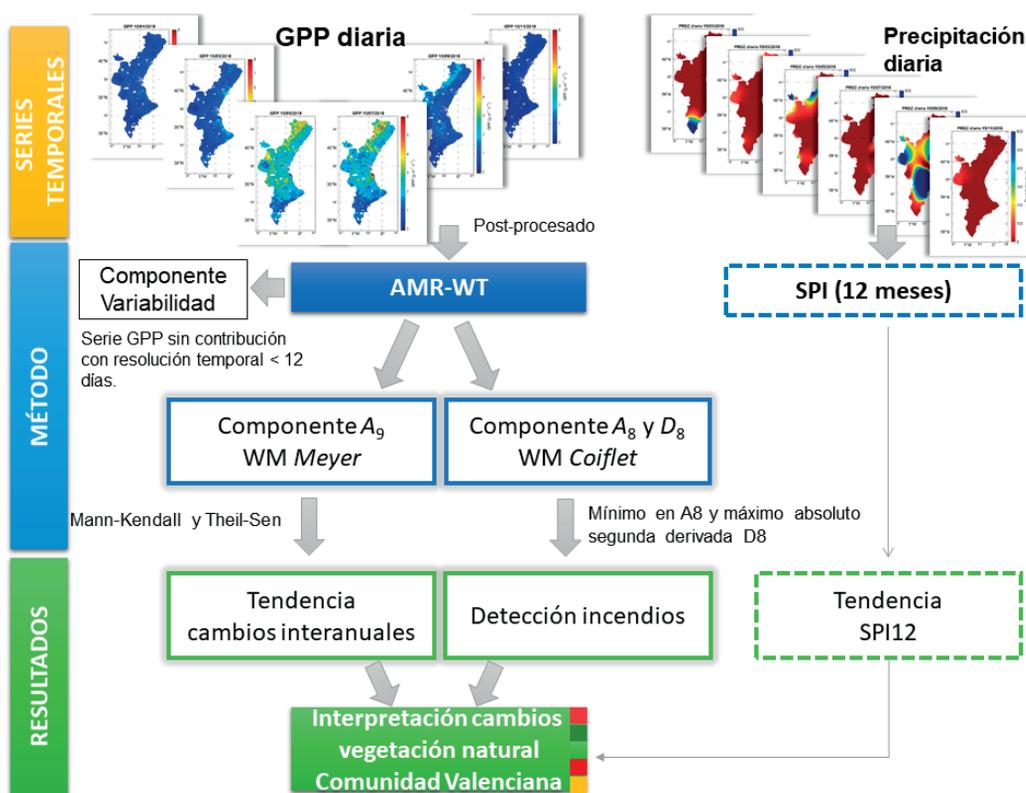
de la serie temporal de GPP diaria (Figura 1a) para el caso particular de un píxel de matorral con pendiente positiva. La Figura 1b hace referencia a la componente de aproximación ( $A_9$ ) utilizada para evaluar los cambios a escala interanual.

#### 4. Procedimiento experimental

La figura 2 muestra el procedimiento experimental para cada uno de los píxeles de las imágenes de la serie temporal de GPP calculada según el procedimiento descrito en 2.1. En primer lugar, se aplica un post-procesado para eliminar (i) valores negativos (no admisibles) y (ii) rellenar huecos, por ejemplo, debidos a la presencia de nubes que no se han filtrado adecuadamente utilizando la banda QC (*Quality Control*). Dado el bajo porcentaje de huecos (menor del 15%), se utiliza una interpolación lineal para el relleno de las series,

que permite además aumentar su resolución temporal a un día. En segundo lugar, se aplica el AMR-TW con la WM Meyer. Se obtiene la componente de aproximación  $A_9$  y, posteriormente, se lleva a cabo el análisis de tendencias con el test no paramétrico Mann-Kendall junto con el método Theil-Sen (Martínez y Gilabert, 2009) para evaluar la dirección y magnitud ( $Q$ ) de las variaciones interanuales experimentadas en la GPP (imagen de tendencia).

El análisis de tendencias permite identificar zonas de cambios positivos (*greening*) y negativos (*browning*). En estas últimas pueden quedar englobadas también zonas afectadas por incendios (cambios bruscos) en las que la vegetación ha tardado en regenerarse o todavía no presenta los niveles de actividad fotosintética pre-incendio. Aunque la incidencia que tienen los incendios forestales sobre la cubierta vegetal se puede



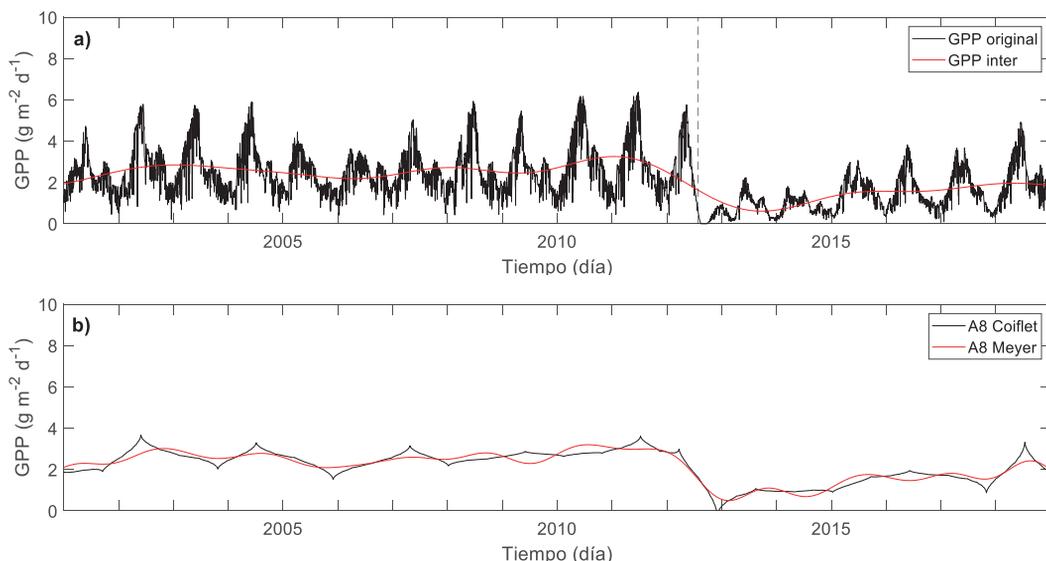
**Figura 2.** Esquema simplificado del procedimiento experimental llevado a cabo en cada píxel de las imágenes. Una vez se ha realizado el post-procesado a los datos originales, se aplica el AMR-WT para obtener: la componente de aproximación  $A_9$  con la *wavelet Meyer* (tendencia de la serie, que permite detectar cambios graduales) y las componentes  $A_8$  y  $D_8$  con la *wavelet coiflet* (más específicas para la detección de cambios bruscos, como los debidos a incendios). La interpretación de los cambios se lleva a cabo analizando dichas componentes junto con la tendencia del SPI12.

observar a una escala prácticamente diaria, su efecto persiste en los meses posteriores. Esto permite recurrir a componentes de aproximación en el AMR a escalas superiores –que ya están exentas de la variabilidad estacional, que puede enmascarar el cambio debido al incendio– como  $A_8$  y  $A_9$ . Se ha comprobado que la primera localiza la fecha del incendio de manera más precisa, en particular, se utiliza la segunda derivada de la componente  $A_8$  para localizar el mínimo en la GPP. Por otra parte, la detección de estos cambios bruscos se complementa con la componente de detalle  $D_8$  (diferencia entre la componente  $A_8$  y  $A_7$ , asociadas a escalas temporales comprendidas entre 96 y 198 días), que realiza la pérdida de estacionalidad de la vegetación consecuencia del incendio, presentando valores alrededor de cero en los meses posteriores al mismo. Aunque el AMR con la *wavelet Meyer* ha mostrado resultados satisfactorios en la detección de zonas afectadas por cambios bruscos como los debidos a incendios forestales (Martínez y Gilabert, 2009), se ha comprobado que si se utiliza la *wavelet coiflet* se localiza la fecha del incendio con mayor precisión. Esto puede ser de gran ayuda si se desea comparar con alguna cartografía de incendios. Por este motivo, se ha utilizado la *wavelet coiflet* para identificar

las zonas con pendiente negativa que son debidas a incendios.

La figura 3 muestra un ejemplo para el incendio de Andilla que tuvo lugar el 29 de Junio de 2012 y que afectó a más de 20000 ha. La componente  $A_8$  derivada con la *WM coiflet* (negro) detecta el mínimo en la GPP debido al incendio en 2012 y permite aislar perfectamente el comportamiento de la vegetación en este caso e, incluso, localizarlo en el tiempo con más precisión que la *WM Meyer* (rojo). En el caso de utilizar la componente  $A_9$  o  $A_8$  derivada de la *WM Meyer*, la localización del incendio se retrasaría hasta principios de 2013.

Por último, los cambios interanuales observados en la vegetación natural (excepto incendios) a partir de la imagen de tendencia de GPP se han cruzado con los cambios interanuales de la precipitación para el mismo periodo, porque entendemos que es la principal variable que influye en el estado de la vegetación natural. Para ello, se ha calculado el SPI12, dado que proporciona las variaciones interanuales de la precipitación con respecto a su valor medio entre 2001 y 2018 y, posteriormente, se ha aplicado también el método de Mann-Kendall y Theil-Sen para obtener la magnitud y la dirección de dichos cambios. El análisis se ha realizado enmascarando los cultivos a partir del mapa híbrido



**Figura 3.** (a) GPP original (negro) y componente interanual con la *WM Meyer* (rojo) para el píxel correspondiente al incendio de Andilla el 29 de Junio de 2012. (b) componentes de aproximación  $A_8$  de la GPP con la *WM Meyer* (rojo) y *coiflet* (negro) para el mismo píxel.

de cubiertas utilizado en el apartado 2.1 dado que su interpretación resulta más compleja debido a varios factores como, por ejemplo, las diferentes variedades de cultivos y pequeñas diferencias espectrales entre ellas, el pequeño tamaño de las explotaciones agrarias, la alta fragmentación espacial y, en el caso de identificar cultivos abandonados, las mínimas diferencias espectrales entre parcelas abandonadas y en producción.

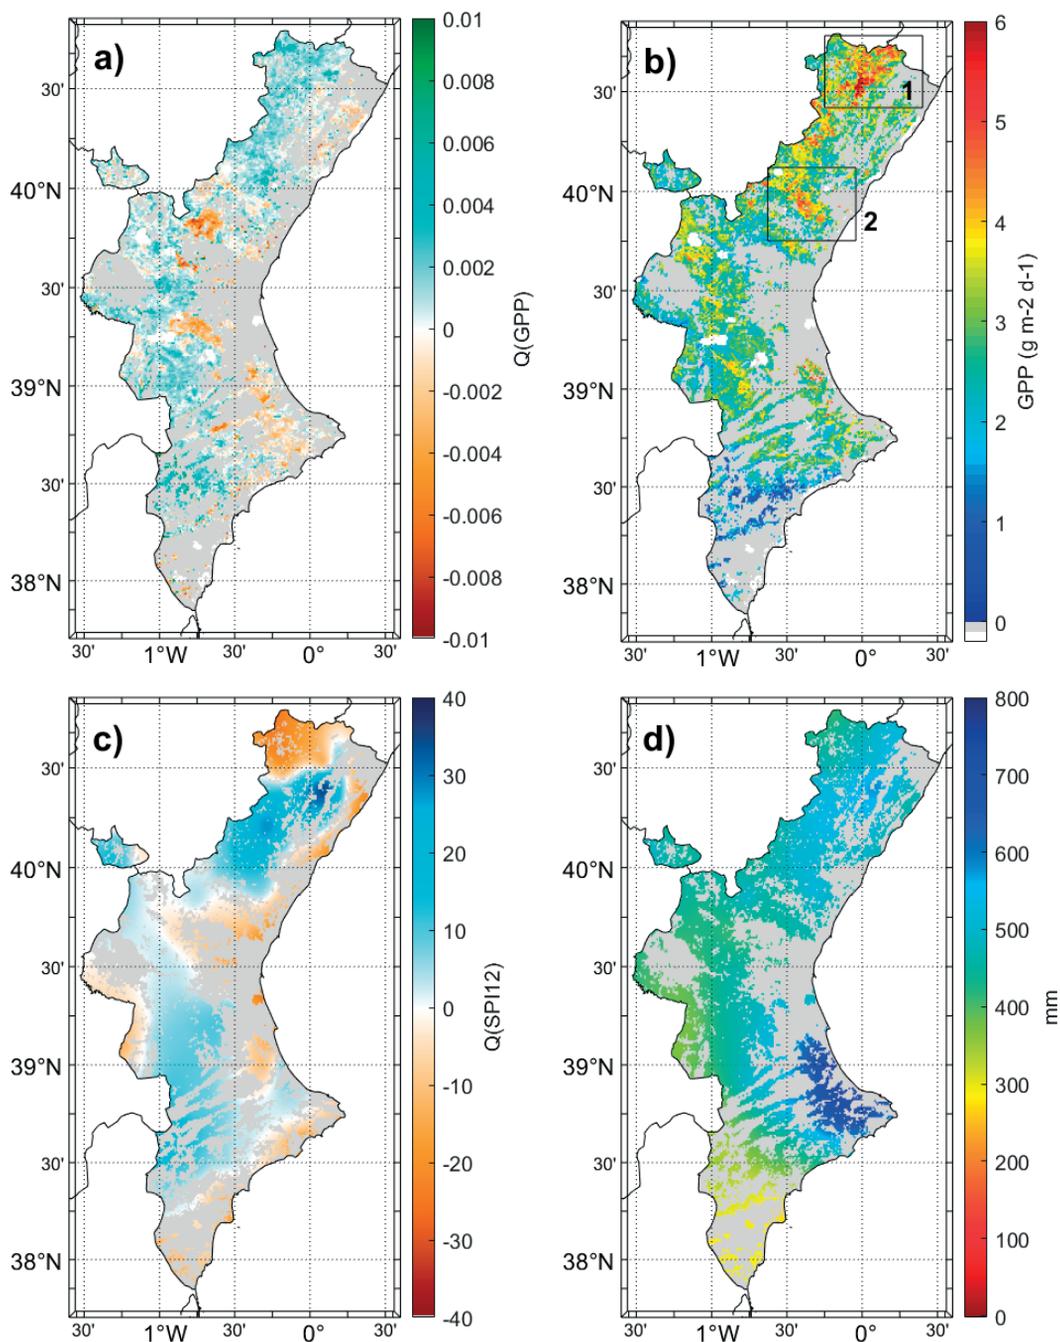
## 5. Resultados y discusión

La figura 4 muestra los resultados de aplicar la metodología propuesta para detectar los cambios en la GPP. La imagen de tendencia (Figura 4a) se ha normalizado con respecto al valor medio de cada píxel para toda la serie (Figura 4b). En la figura 4a, los tonos verdes indican un aumento en la GPP (valores positivos) mientras que los tonos marrones reflejan una disminución (valores negativos). En el interior de la comunidad predominan las zonas sin cambios significativos o bien con aumento de la GPP, mientras que los valores negativos se localizan sobre todo en zonas afectadas por incendios forestales y cercanas a la costa. Respecto al valor medio de la GPP, se observan valores de producción primaria bruta de hasta  $5 \text{ g m}^{-2} \text{ d}^{-1}$  en la zona norte de la provincia de Castellón, donde se localizan las zonas forestales del parque natural de *Tinença de Benifassà* en el *Baix Maestrat* con una superficie de 4965 ha (zona 1). Esta zona, junto con la *Serra d'Espadà* (zona 2), se encuentran dentro de una selección de parcelas de observación permanente de la red Bioclima (<https://agroambient.gva.es/es/>). Se observan valores bajos de GPP en la zona de Utiel-Requena (oeste de la provincia de Valencia) y en el centro de la provincia de Alicante (comarcas del *Alt, Mitjà* y *Baix* Vinalopó). En las figuras 4c y 4d se muestran los mapas de pendiente del SPI y precipitación media utilizados para discutir la naturaleza de los diferentes cambios observados en la variable GPP, principalmente los cambios negativos. Se observan cambios positivos en la precipitación, principalmente, en la zona del interior de la comunidad con valores medios entre 400 y 800 mm, mientras que destacan los cambios negativos en el aporte hídrico observados en la zona 1 al norte de la provincia de Castellón.

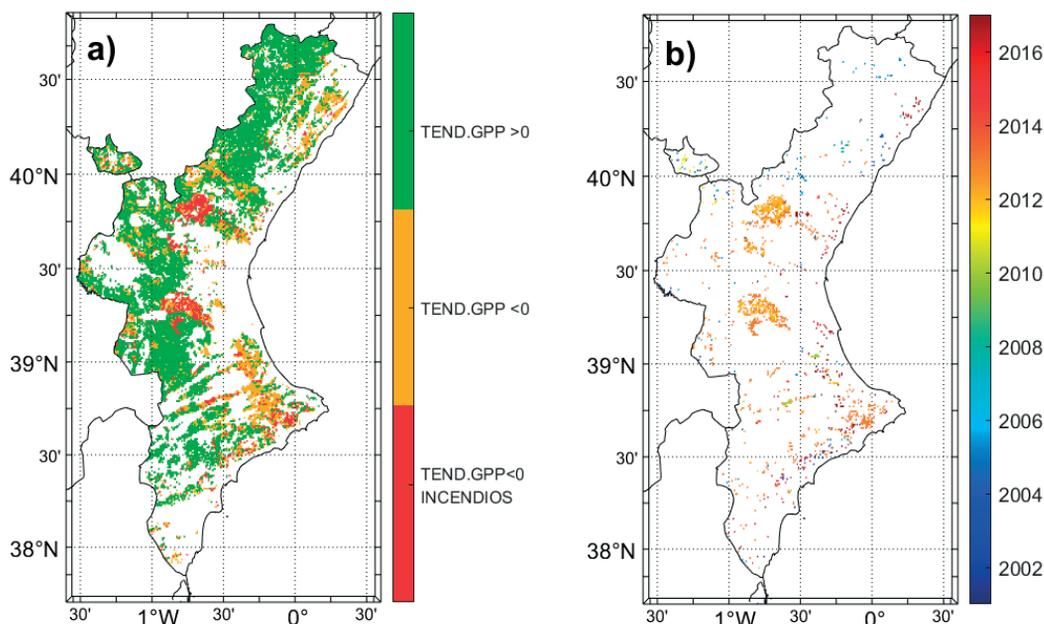
La figura 5a muestra, en color verde, las cubiertas que presentan una tendencia positiva de la

GPP. En color naranja, la vegetación natural que presenta una tendencia negativa en la GPP y, en rojo, aquellas zonas que presentan una disminución de la GPP pero que, según la metodología propuesta, corresponden a zonas afectadas por incendios forestales en las que no se ha recuperado la vegetación. Estas zonas afectadas por incendios forestales se han comparado con la cartografía proporcionada por la *Generalitat Valenciana* (<https://agroambient.gva.es/es/web/prevencion-de-incendios/cartografia-descargable1>) desde 2001 hasta 2018. El acuerdo existente es de un 66%, dado que –al margen de discrepancias asociadas a la resolución espacial de nuestras imágenes– en este trabajo solo se identifican los incendios que no se han regenerado (para estos, la correspondencia es superior al 90%), es decir, que han ocurrido a partir de la mitad del periodo considerado, tal como se observa en la figura 5b, la cual muestra, siguiendo la metodología descrita, la fecha (año) de los incendios identificados. La metodología propuesta presenta limitaciones cuando la cubierta se ha quemado varias veces (e.g., Barranco Moned en Buñol) o cuando se ha recuperado más rápido. En cualquier caso, estas zonas no presentarían una tendencia negativa o, incluso, podrían haber quedado catalogadas como cambios positivos.

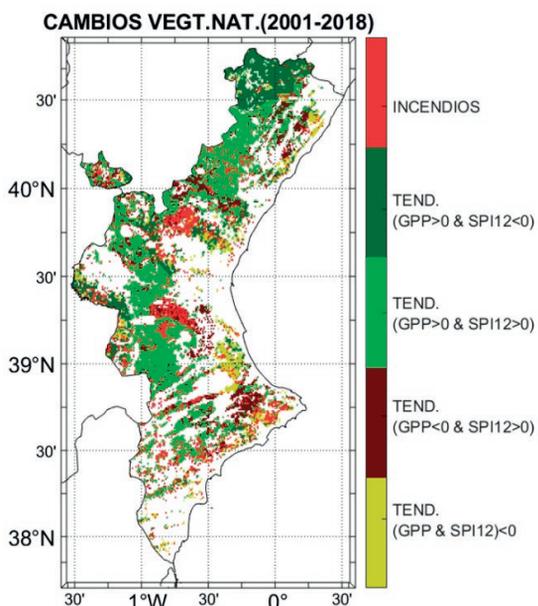
Por otra parte, se presenta un análisis de los cambios de la vegetación natural al cruzar la imagen de tendencia en la GPP (Figura 4a) con los cambios en la precipitación (Figura 4c). La tabla 1 muestra los criterios que se han considerado para caracterizar los diferentes cambios. La figura 6 muestra el mapa de cambios derivado al aplicar dichos criterios. En color rojo se han representado los píxeles con cambios negativos detectados como incendios por la *wavelet coiflet*. En color mostaza se han representado aquellos píxeles donde la tendencia de la GPP y el SPI es negativa y, por tanto, se consideran como zonas con una disminución de la GPP posiblemente relacionada con la escasez de agua. Es decir, la pérdida de masa de vegetación natural puede estar vinculada a factores climáticos. Por el contrario, las zonas representadas con el color verde claro indican el fenómeno opuesto. Se les asocia un aumento de actividad fotosintética en la vegetación (tendencia positiva de la GPP) asociado, principalmente, a un aporte hídrico natural (tendencia positiva de la precipitación). Como se ha mencionado antes, zonas afectadas por incendios al principio del periodo que se hubieran



**Figura 4.** (a) Pendiente de la GPP normalizada con respecto a la media, (b) valor medio de la GPP donde las zonas señaladas con los rectángulos presentan los valores medios más altos para la GPP y, además, se corresponden con una selección de parcelas de observación permanente de la red Bioclima, (c) tendencia de la precipitación obtenida a partir del SPI acumulado a 12 meses y (d) precipitación media. Todas las figuras muestran solo la variable de interés para la vegetación natural. En gris aparecen enmascaradas las zonas identificadas como cultivos en el mapa híbrido.



**Figura 5.** (a) Cambios en la variable GPP correspondientes a vegetación natural. En verde se muestran los cambios en la GPP positivos, mientras que en color naranja se señalan los cambios negativos. En rojo se muestran las zonas afectadas por incendios forestales y con tendencia negativa en la GPP. (b) Fecha de los incendios identificados.



**Figura 6.** Mapa de cambios a partir de las imágenes de tendencia de la GPP y de la precipitación (SPI12) para las diferentes cubiertas de vegetación natural (forestal, matorral y herbáceas).

regenerado satisfactoriamente también quedarían incluidas aquí. Por otra parte, los píxeles identificados en marrón hacen referencia a zonas donde la vegetación presenta una disminución en la GPP a pesar de que existe un aumento en la precipitación. Estas zonas se caracterizan por presentar un cierto nivel de degradación, dado que, por mucho que existan condiciones favorables para su desarrollo, no se recuperan. Es el caso del Parque Natural de la *serra d'Espadà* en Castellón (zona 2 en la figura 4b), la *serra d'Alfaro* en Alicante o el norte de Castellón. Por último, los píxeles representados en verde oscuro corresponden a aquellos que presentan un aumento de la GPP a pesar de que el aporte hídrico no es favorable. Esto parece indicar que la vegetación en estas zonas (sobre todo, zonas forestales y de pasto arbustivo) presenta una elevada resistencia a la sequía. Es el caso de las hoces del Cabriel (Sur de la comarca Utiel-Requena y zona seleccionada en la red Bioclima), y la comarca del *Els Ports* al norte de Castellón (zona 1).

**Tabla 1.** Criterios de cambios propuestos utilizando información derivada de la tendencia en la GPP y la precipitación (SPI) para la vegetación natural. Son los cambios que aparecen como estadísticamente significativos en la figura 5.

Tendencia GPP	Tendencia SPI	Descripción del cambio	Color mapa
-	-	Disminución de la GPP asociada a disminución de precipitación.	
-	+	Disminución de la GPP asociada a procesos de degradación.	
-	-/+	Disminución de la GPP asociada a incendios relativamente recientes.	
+	+	Aumento de la GPP asociado con un aumento de precipitación.	
+	-	Aumento de la GPP y disminución de la precipitación, asociado con una alta resistencia a la sequía.	

## 6. Conclusiones

Se ha llevado a cabo un estudio de la detección de cambios en la vegetación natural a partir del análisis de series temporales diarias de la GPP en la Comunidad Valenciana para el periodo 2001-2018, utilizando el método de AMR-WT. Se ha utilizado la combinación de dos *wavelets* madre (WMs), *Meyer* y *coiflet*, para analizar cambios graduales en la productividad a largo plazo y cambios abruptos (como los asociados a incendios forestales), respectivamente. El estudio combinado con datos de precipitación ha permitido profundizar un poco más en la naturaleza de los cambios observados y detectar, a la vez que confirmar, el deterioro en algunas zonas que disminuyen su productividad, bien por la falta de respuesta al aporte hídrico o por disminución del mismo.

Las zonas afectadas por procesos de degradación presentan cambios graduales y sutiles cuya caracterización a partir de series temporales resulta un reto, dado que el cálculo de la tendencia puede estar enmascarado por la variabilidad estacional, que conviene eliminar para detectar la tendencia de la serie con mayor precisión. Este requisito lo satisface el método empleado, el AMR, cuya funcionalidad ha sido analizada en trabajos previos (Martínez y Gilabert, 2009, Martínez et al., 2011, Giner et al., 2012), que pusieron de manifiesto su menor incertidumbre. Con el AMR el número de píxeles que presentan cambios y que son estadísticamente significativos aumenta considerablemente. Por otra parte, y dado que el principal factor limitante en zonas de clima árido y semiárido es la disponibilidad de agua, se ha introducido en el estudio la información de la variabilidad de la precipitación a través del SPI12. El análisis conjunto de la tendencia interanual de la GPP y de la precipitación ha permitido detectar los cambios graduales en la vegetación natural asociados con un cierto nivel de degradación, que se localizan

preferentemente en zonas incluidas dentro de programas de conservación. Se identifican, además, zonas en las que la GPP presenta cambios también graduales pero positivos, a pesar de que la precipitación haya disminuido. En estas zonas la vegetación parece contar con recursos fisiológicos para mitigar los efectos de la escasez de agua, es decir, presenta una mayor resistencia a la sequía. Se incluyen también en este caso zonas afectadas por incendios al principio del periodo y que ahora se encuentran en proceso de regeneración (como es el caso del incendio que tuvo lugar en 2001 en la zona del norte de Castellón, *Els Ports-Maestrat*). Por otra parte, el AMR con la *wavelet coiflet* ha permitido detectar y localizar en el tiempo cambios negativos bruscos que se asocian con incendios. La validación con la cartografía de incendios de la *Generalitat Valenciana* permite concluir existe un 66% de acuerdo; no obstante, aumenta considerablemente si consideramos solo los incendios en los que la vegetación todavía no se ha recuperado.

## Agradecimientos

Trabajo financiado por los proyectos LSA SAF (EUMETSAT), ESCENARIOS (CGL2012-35831) y ECCE EO (ayuda PID2020-118036RB-I00 financiada por MCIN/AEI/ 10.13039/501100011033 y por “FEDER Una manera de hacer Europa”).

## Referencias

- Alcaraz-Segura, D., Liras, E., Tabik, S., Paruelo, J., Cabello, J. 2010. Evaluating the Consistency of the 1982–1999 NDVI Trends in the Iberian Peninsula across Four Time-series Derived from the AVHRR Sensor: LTDR, GIMMS, FASIR, and PAL-II. *Sensors*, 10, 1291–1314. <https://doi.org/10.3390/s100201291>

- Alsamamra, H., Ruiz-Arias, J.A., Pozo-Vázquez, D., Tovar-Pescador, J. 2009. A comparative study of ordinary and residual kriging techniques for mapping global solar radiation over southern Spain, *Agricultural and Forest Meteorology*, 149(8), 1343–1357. <https://doi.org/10.1016/j.agrformet.2009.03.005>
- Azzali, A., Menenti, M. 2000. Mapping vegetation–soil complexes in southern Africa using temporal Fourier analysis of NOAA AVHRR NDVI data. *International Journal of Remote Sensing*, 21, 973–996. <https://doi.org/10.1080/014311600210380>
- Ben Abbes, A., Bounouh, O., Farah, I.R., de Jong, R., Martínez, B. 2018. Comparative study of three satellite image time-series decomposition methods for vegetation change detection. *European Journal of Remote Sensing*, 51(1), 607–615. <https://doi.org/10.1080/22797254.2018.1465360>
- Berdugo, M., Delgado-Baquerizo, M., Soliveres, S., Hernández-Clemente, R., Zhao, Y., Gaitán, J.J., Gross, N., Saiz, H., Maire, V., Lehman, A., Rillig, M.C., Solé, R.V., Maestre, F.T. 2020. Global ecosystem thresholds driven by aridity. *Science*, 367, 787–790. <https://doi.org/10.1126/science.aay5958>
- CGLOPS1, 2018. Copernicus Global Land Operations “Vegetation and Energy” Product User Manual for Dry Matter Productivity (DMP) and Gross Dry Matter Productivity (GDMP). Collection 1 km, version 2- CGLOPS1\_PUM\_DMP1km-V2, February 2018, 47 pp.
- Chapin III, F.S., Matson, P.A., Mooney, H.A. 2002. *Principles of Terrestrial Ecosystem Ecology*. Springer-Verlag, New York. <https://doi.org/10.1007/b97397>
- de Beurs, K.M., Henebry, G.M. 2005. A statistical framework for the analysis of long image time series. *International Journal of Remote Sensing*, 26, 1551–1573. <https://doi.org/10.1080/01431160512331326657>
- de Jong, R. de Bruin, S. de Wit, A. Schaepman, M.E. Dent, D.L. 2011. Analysis of monotonic greening and browning trends from global NDVI time-series. *Remote Sensing of Environment*, 115(2), 692–702. <https://doi.org/10.1016/j.rse.2010.10.011>
- Furon, A. C., Wagner-Riddle, C., Smith, C. R., Warland, J. S. 2008. Wavelet analysis of wintertime and spring thaw CO<sub>2</sub> and N<sub>2</sub>O fluxes from agricultural fields. *Agricultural and Forest Meteorology*, 148, 1305–1317. <https://doi.org/10.1016/j.agrformet.2008.03.006>
- Gilabert, M.A., Moreno, A., Maselli, F., Martínez, B., Chiesi, M., Sánchez-Ruiz, S., García-Haro, F.J., Pérez-Hoyos, A., Campos-Taberner, M., Pérez-Priego, O., Serrano-Ortiz, P., Carrara, A. 2015. Daily GPP estimates in Mediterranean ecosystems by combining remote sensing and meteorological data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 102, 184–197. <https://doi.org/10.1016/j.isprsjprs.2015.01.017>
- Giner, C., Martínez, B., Gilabert, M.A., Alcaraz-Segura, D. 2012. Tendencias en el verdor de la vegetación y en la producción primaria bruta de las áreas forestales en la España peninsular (2000-2009). *Revista de Teledetección*, 38, 51–64. Disponible en: <http://www.aet.org.es/?q=revista38-7>
- Heinsch, F.A., Maosheng, Z., Running, S.W., Kimball, J.S., Nemani, R.R., Davis, K.J., et al., 2006. Evaluation of remote sensing based terrestrial productivity from MODIS using regional tower eddy flux network observations. *IEEE Transaction on Geoscience and Remote Sensing*, 44(7), 1908–1925. <https://doi.org/10.1109/TGRS.2005.853936>
- Huang, S., Tang, L., Hupy, J., Wang, Y., Shao, G. 2020. A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. *Journal of Forest Research*, 32, 1–6. <https://doi.org/10.1007/s11676-020-01155-1>
- Jamali, S., Jönsson, P., Eklundh, L., Ardö, J., Seaquist, J. 2015. Detecting changes in vegetation trends using time series segmentation. *Remote Sensing of Environment*, 156, 182–195. <https://doi.org/10.1016/j.rse.2014.09.010>
- Jones, L.A., Kimball, J.S., Reichle, R.H., Madani, N., Glassy, J., Ardizzone, J.V., et al. 2017. The SMAP level 4 carbon product for monitoring ecosystem land-atmosphere CO<sub>2</sub> exchange. *IEEE Transactions on Geoscience and Remote Sensing*, 55(11), 6517–6532. <https://doi.org/10.1109/TGRS.2017.2729343>
- Kimball, J.S., Jones, L.A., Zhang, K., Heinsch, F.A., McDonald, K.C., Oechel, W.C. 2009. A satellite approach to estimate land-atmosphere CO<sub>2</sub> exchange for boreal and arctic biomes using MODIS and AMSR-E. *IEEE Transactions on Geoscience and Remote Sensing*, 47(2), 569–587. <https://doi.org/10.1109/TGRS.2008.2003248>
- Li, X.B., Chen, Y.H., Fan, Y. Da, Zhang, Y.X. 2003. Detecting inter-annual variations of vegetation growth based on satellite-sensed vegetation index data from 1983 to 1999. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 5(C), 3263–3265.

- McKee, T.B., Doesken, N.J., Kliest, J. 1993. The relationship of drought frequency and duration to time scales. In *Proceedings of the 8th Conference of Applied Climatology, 17-22 January, Anaheim, CA*. American Meteorological Society, Boston, MA. 179-184.
- Martínez, B., Gilabert, M.A. 2009. Vegetation dynamics from NDVI time series analysis using the wavelet transform. *Remote Sensing of Environment*, 113(9), 1823–1842. <https://doi.org/10.1016/j.rse.2009.04.016>
- Martínez, B., Gilabert, M.A., García-Haro, F.J., Faye, A., Meliá, J. 2011. Characterizing land condition variability in Ferlo, Senegal (2001-2009) using multi-temporal 1-km Apparent Green Cover (AGC) SPOT Vegetation data. *Global and Planetary Change*, 76, 152–165. <https://doi.org/10.1016/j.gloplacha.2011.01.001>
- Monteith, J.L. 1972. Solar radiation and productivity in tropical ecosystems. *Journal of Applied Ecology*, 9, 747–766. <https://doi.org/10.2307/2401901>
- Moreno, A., Gilabert, M.A., Martínez, B. 2011. Mapping daily global solar irradiation over Spain: a comparative study of selected approaches. *Solar Energy*, 85, 2072–2084. <https://doi.org/10.1016/j.solener.2011.05.017>
- Percival, D.B., Walden, A.T. (2000). *Wavelet methods for time series analysis*. Cambridge University Press 594 pp.
- Pérez-Hoyos, A., García-Haro, F.J., San Miguel-Ayanz, J. 2012a. A methodology to generate a synergetic land-cover map by fusion of different land-cover products. *International Journal of Applied Earth Observation and Geoinformation*, 19, 72–87. <https://doi.org/10.1016/j.jag.2012.04.011>
- Pérez-Hoyos, A., García-Haro, F.J., San-Miguel-Ayanz, J. 2012b. Conventional and fuzzy comparisons of large-scale land cover products: Application to CORINE, GLC2000, MODIS and GlobCover in Europe. *ISPRS Journal of Photogrammetry and Remote Sensing*, 74, 185-201. <https://doi.org/10.1016/j.isprsjprs.2012.09.006>
- Poyatos, R., Latron, J., Llorens, P. 2003. Land Use and Land Cover Change After Agricultural Abandonment. The Case of a Mediterranean Mountain Area (Catalan Pre-Pyrenees). *Mountain Research and Development*, 23(4), 362-368. [https://doi.org/10.1659/0276-4741\(2003\)023\[0362:LUALCC\]2.0.CO;2](https://doi.org/10.1659/0276-4741(2003)023[0362:LUALCC]2.0.CO;2)
- Rhif, M., Ben Abbes, A., Farah, I.R., Martínez, B., Sang, Y. 2019. Wavelet transform application for/in non-stationary time-series analysis: A review. *Applied Sciences*, 9(7), 1345. <https://doi.org/10.3390/app9071345>
- Rigina, O., Rasmussen, M.S. 2003. Using trend line and principal component analysis to study vegetation changes in Senegal 1986-1999 from AVHRR NDVI 8 km data. *Geografisk Tidsskrift, Danish Journal of Geography*, 103(1), 31–42. <https://doi.org/10.1080/00167223.2003.10649477>
- Roujean, J.L., Breon, F.M. 1995. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements, *Remote Sensing of Environment*, 51(3), 375–384. [https://doi.org/10.1016/0034-4257\(94\)00114-3](https://doi.org/10.1016/0034-4257(94)00114-3)
- Rouse, J.W., Haas, R.H., Schell, J.A., Deering, D.W., Harlan, J.C. 1974. Monitoring the vernal advancement of retrogradation of natural vegetation, *Final Report, Type III*, NASA/GSFC, Greenbelt, MD, 371 pp.
- Running, S.W., Nemani, R.R., Heinsch, F.A., Zhao, M., Reeves, M., Hashimoto, H. 2004. Continuous Satellite-Derived Measure of Global Terrestrial Primary Production, *BioScience*, 54(6), 547–560. [https://doi.org/10.1641/0006-3568\(2004\)054\[0547:ACSMOG\]2.0.CO;2](https://doi.org/10.1641/0006-3568(2004)054[0547:ACSMOG]2.0.CO;2)
- Schimel, D. 2010. Drylands in the earth system. *Science*, 22, 418–419. <https://doi.org/10.1126/science.1184946>
- Stöckli, R., Vidale, P.L. 2004. European plant phenology and climate as seen in a 20-year AVHRR land-surface parameter dataset. *International Journal of Remote Sensing*, 25, 3303–3330. <https://doi.org/10.1080/01431160310001618149>
- Tramontana, G., Jung, M., Schwalm, C.R., Ichii, K., Camps-Valls, G., Radulu, B., et al., 2016. Predicting carbon dioxide and energy fluxes across global FLUXNET sites with regression. *Biogeosciences* 13, 4291–4313. <https://doi.org/10.5194/bg-13-4291-2016>
- Verbesselt, J., Hyndman, R., Newnham, G., Culvenor, D. 2010. Detecting trend and seasonal changes in satellite image time series. *Remote Sensing of Environment*, 114(1), 106–115. <https://doi.org/10.1016/j.rse.2009.08.014>
- Xiao, J., Chevallier, F., Gomez, C., Guanter, L., Hicke, J.A., Huete, A.R., Ichii, K., Ni, W., Pang, Y., Rahman, A.F. et al., 2019. Remote sensing of the terrestrial carbon cycle: A review of advances over 50 years. *Remote Sensing of Environment*, 233, 111383. <https://doi.org/10.1016/j.rse.2019.111383>
- Zhao, X., Hu, H., Shen, H., Zhou, D., Zhou, L., Myneni, R.B., Fang, J. 2015. Satellite-indicated long-term vegetation changes and their drivers on the Mongolian Plateau. *Landscape Ecology*, 30, 1599–611. <https://doi.org/10.1007/s10980-014-0095-y>