

MODELOS EMPÍRICOS DE PREDICCIÓN DEL CONTENIDO DE HUMEDAD DEL COMBUSTIBLE VIVO MEDIANTE ÍNDICES ESPECTRALES DE SENTINEL-2 Y DATOS METEOROLÓGICOS

EMPIRICAL MODELS FOR PREDICTING LIVE FUEL MOISTURE CONTENT USING SENTINEL-2 SPECTRAL INDICES AND METEOROLOGICAL DATA

María Alicia Arcos^{a,*}, Ángel Balaguer-Beser^{a,b}, Luis Ángel Ruiz^a

^a Grupo de Cartografía GeoAmbiental y Teledetección (CGAT), Departamento de Ingeniería Cartográfica, Geodesia y Fotogrametría, Universitat Politècnica de València, Camino de Vera s/n, 46022 Valencia, España. maar12m@doctor.upv.es; laruiz@cgf.upv.es

^b Departamento de Matemática Aplicada, Universitat Politècnica de València, Camino de Vera s/n, 46022 Valencia, España. abalague@mat.upv.es

Abstract:

The water content of the vegetation affects the flammability of the vegetation and fire behavior. A standard measure of this parameter is the live fuel moisture content (LFMC), calculated as the percentage of humidity of the vegetation relative to its dry weight. The aim of this work was to predict LFMC values of *Rosmarinus officinalis* in forest areas of the Valencian Community (Spain) using spectral indices obtained from Sentinel-2 satellite images and meteorological data. For this, LFMC values of this species were obtained from field samples collected biweekly from June to October in years 2019 and 2020 in three forest plots in the province of Valencia (Spain). The meteorological data (precipitation, temperature, relative humidity and wind speed) were obtained from observatories of the State Meteorological Agency (AEMET) of Spain. Multiple linear regression models were applied to estimate LFMC, using as predictor variables different spectral indices generated from Sentinel-2 images, calculated using Google Earth Engine and R programming. The results obtained using smoothed spectral data with the Savitzky-Golay filter were compared with data without such smoothing, also considering the differential contribution of the meteorological variables in each of the interpolated dates for each plot with data from the study area.

Key words: live fuel moisture; mediterranean forests; Sentinel-2; spectral indices; meteorological data; Google Earth Engine

Resumen:

El contenido de agua de la vegetación afecta a la inflamabilidad de la vegetación y al comportamiento del fuego. Una medida estándar de este parámetro es la humedad del combustible vivo (HCV), calculada como el porcentaje de humedad de la vegetación respecto a su peso seco. El objetivo de este trabajo ha sido predecir los valores de HCV de *Rosmarinus officinalis* en zonas forestales de la Comunitat Valenciana (España) utilizando índices espectrales obtenidos a partir de imágenes de los satélites Sentinel-2 y datos meteorológicos. Para ello, se obtuvieron valores de HCV de dicha especie en muestras tomadas quincenalmente entre los meses desde junio hasta octubre de los años 2019 y 2020 en tres parcelas forestales en la provincia de Valencia (España). Los datos meteorológicos (precipitación, temperatura, humedad relativa y velocidad del viento) se obtuvieron a partir de observatorios de la Agencia Estatal de Meteorología (AEMET) de España. Se aplicaron modelos de regresión lineal múltiple para estimar los valores de HCV, usando como variables predictoras distintos índices espectrales generados a partir de imágenes Sentinel-2, calculados usando *Google Earth Engine* y programación en R. Se compararon los resultados obtenidos empleando datos espectrales suavizados con el filtro Savitzky-Golay y datos sin suavizar, considerando además el aporte diferencial de las variables meteorológicas en cada una de las fechas interpoladas para cada parcela con datos de campo.

Palabras clave: humedad de combustible vivo; bosques mediterráneos; Sentinel-2; índices espectrales; datos meteorológicos; *Google Earth Engine*

1. Introducción

La humedad de combustible vivo (HCV) está estrechamente relacionada con la inflamabilidad de las especies vegetales y, en consecuencia, con la ocurrencia y propagación de los incendios forestales. Yebra *et al.* (2013) revisaron el uso de datos de teledetección para estimar el contenido de HCV y encontraron relaciones

entre HCV y el comportamiento del fuego en experimentos de ignición de combustible a escalas pequeñas.

La humedad de combustible vivo corresponde al contenido de agua de la vegetación, calculada como el porcentaje de la masa de agua contenida en las especies muestreadas en campo respecto a su peso seco (ver Ecuación 1).

* Corresponding Author: María Alicia Arcos, maar12m@doctor.upv.es

$$HCV = \frac{\text{PesoVerde} - \text{PesoSeco}}{\text{PesoSeco}} * 100 \quad (1)$$

El peso verde corresponde al peso de la especie tomado cuando se recoge la muestra en campo y el peso seco el que se obtiene después de introducirla en la estufa de secado a 100° C.

Existen varias referencias donde se relacionan los valores de HCV, tanto con índices espectrales extraídos de diferentes satélites (MODIS, Landsat, Sentinel), como con variables meteorológicas (véase García *et al.* (2020) Marino *et al.* (2018) o Myoung *et al.* (2018)). Marino *et al.* (2020) ajustaron modelos empíricos con diferentes métodos estadísticos: regresión lineal simple (LR) y múltiple (MLR), regresión no lineal (NLR) usando índices espectrales extraídos de imágenes MODIS o Sentinel-2. Sin embargo, los distintos enfoques que emplearon tendían a sobrestimar los valores más bajos de HCV, necesitándose más trabajo para mejorar las predicciones. En su estudio subrayan, además, que los datos de teledetección son una fuente importante de información para la estimación de modelos operativos de HCV que se pueden utilizar para el análisis de riesgo de incendios forestales.

Myoung *et al.* (2018) probaron un modelo utilizando varias variables meteorológicas como variables independientes, además del EVI (*Enhanced vegetation index*) obtenido usando datos MODIS. Los resultados indicaron que, entre las temperaturas diarias, la humedad y la precipitación, la mejora del modelo fue mayor con el uso de la temperatura mínima diaria, especialmente para valores más bajos de HCV. Sin embargo, la resolución espacial proporcionada por MODIS (500 m) puede no ser adecuada para monitorear la dinámica de HCV en áreas montañosas (Quan *et al.* 2017).

Los satélites Sentinel-2 incluyen un sensor óptico de alta resolución que opera en 13 bandas entre el visible y el SWIR (*Short wave infrared*). La resolución espacial es de 10 m para bandas del visible y NIR (*Near infrared*), 20 m para bandas del borde rojo y SWIR, y 60 m para bandas atmosféricas. De esta forma, Sentinel-2 ofrece actualmente una resolución temporal de 5 días y una resolución espacial de 10, 20 o 60 m, dependiendo de las bandas. Marino *et al.* (2018) usaron los índices VARI (*Visible Atmospheric Resistant Index*) y EVI extraídos de imágenes Sentinel-2. Sin embargo, las propiedades de los índices de humedad pueden ayudar a estimar mejor la HCV. Por otra parte, Martin-StPaul *et al.* (2018) establecieron un modelo lineal para predecir los valores anuales más bajos de HCV a través de datos meteorológicos.

El valor de HCV depende fundamentalmente de la especie, de su estado fenológico, la meteorología, el relieve y el suelo (Castro *et al.* 2003). Esta relación hace que los valores de HCV varíen en función de la localización espacial y de la época del año en estudio, aunque también puede variar de un año a otro. Debido a esta causa, la variación suele ser diferente en especies del estrato arbóreo (como *Pinus halepensis* y *Quercus ilex*) con respecto a las de estrato arbustivo (como *Rosmarinus officinalis*, *Quercus coccifera*, *Ulex parviflorus*, y *Juniperus oxycedrus*) y las de estrato herbáceo. En el caso de la Provincia de Valencia, donde han sido tomados los datos de HCV usados en este trabajo, la variación de HCV puede ser importante en los meses de verano y otoño atendiendo al régimen de

precipitaciones. La meteorología suele influir más en la variación de la HCV de especies del estrato herbáceo y en algunas de arbustos como la de *Rosmarinus officinalis* o *Ulex parviflorus*. En este análisis se ha elegido la especie de *Rosmarinus officinalis* debido a que es una de las más representativas del área de estudio, y sus valores de HCV sufren una mayor variación a lo largo del tiempo (Soriano and Quilez 2017). Se han analizado las series temporales para 2019 y 2020 de la humedad de combustible vivo en los meses de junio a octubre, en una zona forestal de la provincia de Valencia (España).

El objetivo de este trabajo, entonces, se centra en predecir los valores de HCV de la especie *Rosmarinus officinalis* en una zona de la provincia de Valencia usando índices espectrales extraídos de Sentinel-2 y algunos datos meteorológicos de la zona. Se analizaron las diferencias de HCV en 3 lugares que distan menos de 250 m (resolución de las bandas 1 y 2 de MODIS), durante los meses desde junio a octubre, con datos de los años 2019 y 2020. También, se examinaron las diferencias que ocurren al calcular los índices espectrales con ventanas de lado igual a 10, 30 o 90 metros, a fin de comprobar el grado de precisión espacial y robustez que proporcionarían en el diseño de modelos de predicción de HCV.

2. Datos y área de estudio

En la Figura 1 se ilustra la ubicación de los puntos de toma de las muestras de la especie *Rosmarinus officinalis*, correspondientes a las parcelas: G2, G3 y G5 en los municipios de Gilet y Sagunto, localizados en la provincia de Valencia (España). Las parcelas se encuentran a una elevación entre 255 y 310 msnm (ver Tabla 1).

Tabla 1: Características de las parcelas (P). FCC indica la fracción de cabida cubierta de la especie *Rosmarinus officinalis*.

P	Altitud (m)	Pendiente (°)	Orientación (Dirección)	FCC	Modelo_Combust
G2	255	25,2	SE	25	SH4
G3	310	16,2	SO	40	SH4
G5	295	25,9	SE	30	SH4

Las tres parcelas, distan entre sí menos de 250 m, sin embargo, a pesar de que los puntos están cerca y se analiza la misma especie pueden darse diferencias entre un sitio y otro en los valores de HCV, debido a la topografía, orientación, así como a las proporciones (FCC, fracción de cabida cubierta) de las especies coexistentes (ver Tabla 1).

El relieve es un factor importante dentro del comportamiento de la vegetación puesto que abarca varios aspectos como la altitud, la pendiente y la orientación. En base a la altitud se dan ciertas especies vegetales u otras, considerando que a mayor altitud aumentan las precipitaciones y desciende la temperatura. Dado que la altitud máxima de la provincia de Valencia es 1837 m, la mínima: 0 m y la altitud media: 591 m, las 3 parcelas de este estudio se encuentran por debajo de la altitud media, variando desde los 255 m a los 310 m. En cuanto a la precipitación de la zona analizada, ésta es relativamente baja, sin embargo, se trata de una variable

que depende tanto de la estación como del año en estudio.

Por otra parte, también la orientación provoca un desarrollo distinto en la vegetación. En el hemisferio norte, con una orientación sur o solana se tienen temperaturas más altas, mientras que con una orientación norte o de umbría la humedad es mayor. En este último caso, dado que la vegetación recibe menos radiación, tarda más en secarse. Las tres parcelas poseen orientación de solana y por tanto, mayor radiación solar y menor humedad.

Las pendientes de las parcelas G2 y G5 son elevadas (20-30%), mientras que G3 tiene una pendiente moderada (10-20%). Considerando la tendencia de que, a mayor pendiente, menor humedad (Martínez-González *et al.* 2010), G3 podría ser más húmeda que G2 y G5, lo cual se corroboró con los datos tomados en campo.




Figura 1: Área de estudio: Provincia de Valencia, municipios de Gilet y Sagunto, parcelas: G2, G3 y G5. Las coordenadas UTM X e Y corresponden al centro de cada parcela

3. Metodología

Las mediciones de la humedad de combustible vivo (HCV) se realizaron en cada punto (G2, G3 y G5) de forma quincenal, tanto para el año 2019 como para 2020, durante los meses de junio hasta octubre. Para construir modelos de estimación de HCV se emplearon no sólo índices meteorológicos sino también espectrales como variables explicativas.

3.1. Cálculo de índices espectrales

A fin de obtener los datos de imágenes con el menor tiempo posible de cálculo, se optó por calcular los índices de vegetación para Sentinel-2 usando *Google Earth Engine 14* (Google Earth Engine 2021). Con esto se aportó un mayor grado de operatividad para la obtención de modelos. Las series temporales del área de interés se procesaron con esta herramienta, con la reflectancia superficial y corregida atmosféricamente. Se consideraron los siguientes índices de vegetación: índice de vegetación normalizado (NDVI), índice de vegetación mejorado (EVI), índice de vegetación ajustado al suelo (SAVI), índice de diferencia de agua normalizada (NDWI), índice de resistencia atmosférica visible (VARI), el índice normalizado de la diferencia de humedad (NDMI), el índice de sequía multibanda normalizado (NMDI) y el índice de proporción de vegetación (RVI). La mayor parte de estos índices miden las variaciones de verdor, que pueden estar relacionadas indirectamente con el contenido de agua de la hoja.

Los valores de estos índices se calcularon en diferentes ventanas que contienen el centro de cada parcela: ventana formada por un único píxel de 10 m, ventana de 3x3 píxeles y ventana formada por 9x9 píxeles. Por ejemplo: NDVI_10m significa que el índice NDVI está calculado en un solo píxel Sentinel-2, NDVI_30m está calculado en una ventana de 9 píxeles (3x3) y NDVI_90m en una ventana de 81 píxeles (9x9) centrada en cada punto de muestreo.

Es importante mencionar que, a fin de suavizar la serie temporal y reducir con ello el ruido atmosférico y los residuos de la corrección radiométrica, se usó el filtro Savitzky-Golay (Yang *et al.* 2019) implementado en un paquete con el software R. Este filtro usa los valores anteriores y posteriores a cada fecha en la serie temporal para realizar el suavizado.

3.2. Variables meteorológicas

La Agencia Espacial de Meteorología (AEMET) a través de la Generalitat Valenciana proporcionó los datos meteorológicos diarios de: precipitación, temperatura media, máxima y mínima, velocidad del viento y humedad mínima relativa, correspondientes a diferentes estaciones meteorológicas de la Comunitat Valenciana.

Tras el proceso de depuración de los datos de los observatorios meteorológicos, los valores se interpolaron a las ubicaciones de HCV utilizando el paquete *Meteoland R* (De Cáceres *et al.* 2018), que integra varias herramientas para facilitar la estimación del clima diario sobre paisajes. Se han adaptado las funciones de dicho paquete en un script de R propio para interpolar diariamente los datos de clima teniendo en cuenta los efectos topográficos; y para corregir los sesgos temporales de una serie meteorológica dada. También se han interpolado los datos de humedad mínima relativa y velocidad del viento a pesar de contar con un menor número de estaciones con este tipo de datos pues las condiciones climáticas extremas como los vientos fuertes pueden incidir en las relaciones entre los datos meteorológicos y los valores de HCV. El método de interpolación usado es similar a la distancia inversa ponderada, pero utiliza un filtro gaussiano truncado para seleccionar estaciones meteorológicas, e incluye

correcciones basadas en los efectos de la altitud en las variables meteorológicas.

Todas las variables meteorológicas se han promediado y, en el caso de la precipitación se han calculado valores acumulados, en los días anteriores a cada toma de datos en campo. Así, se ha calculado el promedio de las temperaturas medias diarias y el promedio de las temperaturas diarias máxima y mínima en ventanas temporales de 7, 15 y 30 días antes de la fecha de recolección de datos de campo. También se ha calculado la precipitación acumulada en los últimos 3, 7, 15, 30 y 60 días. Otros índices calculados han sido el promedio en los últimos 3, 7 y 15 días de estas variables: humedad relativa mínima diaria y velocidad promedio en km/h de las rachas máximas de viento en los últimos 7 días. A cada punto de muestreo se le asignaron los datos meteorológicos interpolados y de esta forma se pudo comparar la evolución temporal de los valores de HCV para la especie elegida junto con datos meteorológicos acumulados o promediados en los días anteriores a la fecha de toma de la muestra de HCV en campo.

3.3. Modelos de regresión

En base a los datos meteorológicos y espectrales obtenidos, se aplicó una regresión lineal simple para el caso de una sola variable, mientras que, para el análisis de dos, se consideró la regresión lineal múltiple usando el método de selección paso a paso hacia adelante.

En las regresiones simples se tomó la R^2 como referencia para la comparativa de resultados, cuando se trata de dos variables se consideró tanto la R^2 como la R^2 ajustada. Para que los modelos fueran estadísticamente significativos se tuvo en cuenta, además, que el P-valor del estadístico T de todos los coeficientes fuera menor que 0,05.

Adicionalmente, para los modelos de dos variables, se consideró el valor de la raíz del error cuadrático medio (RMSE) y el error absoluto medio (MAE) para su validación.

4. Resultados

4.1. Estudio de la influencia de los eventos de precipitación en la variación de los valores de HCV

En primer lugar, se realiza el análisis de la precipitación en nuestra zona de estudio para comprobar si esta variable meteorológica guarda algún tipo de relación con los valores de HCV de la especie *Rosmarinus officinalis* y por tanto influye en su comportamiento a lo largo de cada una de las fechas objeto de este estudio.

La Figura 2 muestra la evolución temporal de los valores de HCV junto con los valores de precipitación diaria registrada en la estación meteorológica (Indicativo: 8444, Nombre: Gilet Santo Espiritu) más cercana a las parcelas de estudio (1km), donde se realizaron las mediciones de HCV, en los meses de junio a octubre, tanto para el año 2019 como para el 2020. Por simplicidad, analizamos los valores tomados directamente en dicho observatorio sin interpolar, para evitar la posible influencia del método de interpolación utilizado.

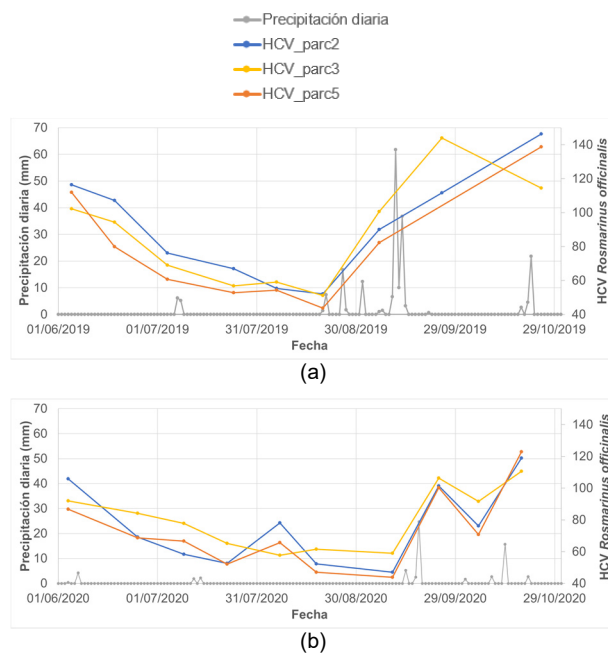


Figura 2: Valores de HCV (eje izquierdo) y precipitación diaria (eje derecho) para los meses de junio a octubre de: a) 2019; b) 2020.

En 2020 los valores de HCV comenzaron más bajos que en 2019 y esta diferencia se mantuvo a lo largo de estos meses. El comportamiento de HCV en 2019 fue más estacional, con una tendencia descendente desde junio hasta mediados de agosto y un crecimiento posterior debido en parte a la precipitación acumulada durante el final de agosto e inicios de septiembre. Por su parte, en el año 2020 se evidenciaron picos/crecidas en julio, septiembre y octubre, motivados en parte por el aumento de HCV tras las lluvias experimentadas unos días antes de las mediciones de HCV en campo.

Como se ha señalado antes, los valores de HCV entre parcelas son diferentes a pesar de estar en una zona de características topográficas similares, ya que no sólo están influenciados por éstas sino también por la proporción en la que se encuentran las demás especies coexistentes en la parcela. Considerando la FCC de las parcelas y, a pesar de que según el “Mapa de Modelos de Combustible” de la Generalitat Valenciana, los tres puntos son de la categoría de SH4 (Matorral con arbustos leñosos y hojarasca de arbusto), en la parcela 5 hay menos presencia de *Pinus halepensis* (ver Tabla 2) lo cual puede influir en las características del lugar y en los valores que toman los índices espectrales calculados a partir de las imágenes Sentinel-2.

Tabla 2: FCC de *Pinus halepensis* en las tres parcelas de estudio.

Parcela	FCC
G2	35
G3	70
G5	20

Detalles completos del Mapa de Modelos de Combustible pueden verse en Generalitat Valenciana (2015).

4.2. Modelos de predicción para HCV con datos compilados 2019-2020

4.2.1. Índices espectrales con series temporales no suavizadas

En primer lugar, se construyen modelos de regresión lineal simple para el año 2019 y para el año 2020 por separado usando índices espectrales con series temporales no suavizadas. En este caso, el valor de la serie temporal de cada índice espectral en la fecha donde se ha tomado el dato de HCV en campo se aproxima mediante el valor obtenido en la fecha más próxima de paso de los satélites Sentinel-2. El valor del coeficiente de determinación (R^2) es mayor para los datos de 2019 que para los de 2020 aunque el mejor índice es el NDMI para los dos años (ver Tabla 3).

Tabla 3: R^2 de datos no suavizados por ventanas (10 m, 30 m, 90 m) y año (2019, 2020).

Índice/ R^2	10 m 2019	30 m 2019	90 m 2019	10 m 2020	30 m 2020	90 m 2020
NDMI	63,91	67,47	41,34	49,38	41,21	23,74
NDWI	47,64	47,08	20,32	43,15	34,64	17,59
NDVI	40,11	40,23	26,06	27,69	24,40	10,58
NMDI	20,24	12,48	11,68	28,05	29,65	19,51
RVI	45,86	48,89	29,57	29,20	26,54	11,51
SAVI	34,29	27,71	29,28	22,16	15,95	16,53
VARI	32,29	33,11	5,96	15,03	18,09	5,28
EVI	41,12	26,79	24,03	18,80	13,09	14,71

En cuanto al tamaño de las ventanas utilizadas, resulta mejor usar 10 m o 30 m en todos los índices, salvo en alguna excepción, la R^2 baja al usar ventanas de 90 m.

Podemos diferenciar dos grupos de índices:

- Aquellos que contienen la banda roja como: EVI, SAVI, NDVI, RVI y VARI. Con RVI y NDVI se obtienen los mejores resultados.
- Índices que incluyen la banda SWIR: NDMI, NDWI y NMDI. Los dos primeros obtienen R^2 en promedio superiores al 50% en las ventanas de 10 y 30 metros en el año 2019.

Al combinar los datos de 2019 junto con los de 2020, se obtiene menor precisión (ver Tabla 4). En los modelos en que se usan dichos datos espectrales no suavizados con la información combinada de los años 2019 y 2020, los valores de R^2 más altos se obtienen generalmente con una ventana de 10 m, aunque la R^2 más alta de este estudio corresponde al índice NDMI (43,68%), con una ventana de 30 m.

4.2.2. Series temporales suavizadas de índices espectrales

Considerando la serie temporal de cada índice espectral suavizada mediante el filtro Savitzky-Golay (Yang *et al.* 2019), en el año 2019 y usando ventanas de 30 m se obtienen mejores resultados con dicho suavizado (Tabla 5) que con datos sin suavizar (Tabla 3). Las ventanas de 10 m y 90 m presentan una tendencia opuesta: los datos que tienen valores de R^2 más altos son los no suavizados.

Tabla 4: R^2 de datos conjuntos no suavizados combinando los datos de los dos años.

Índice/ R^2	10 m	30 m	90 m
NDMI	43,47	43,68	21,38
NDWI	32,92	31,17	11,45
NDVI	25,23	24,73	11,51
NMDI	21,96	14,01	12,92
RVI	27,55	28,31	12,35
SAVI	21,80	17,20	13,98
VARI	14,93	18,51	2,47
EVI	24,92	17,00	13,00

Tabla 5: R^2 de datos suavizados por ventanas (10 m, 30 m, 90 m) y año (2019, 2020).

Índice/ R^2	10 m 2019	30 m 2019	90 m 2019	10 m 2020	30 m 2020	90 m 2020
NDMI	61,16	69,63	34,89	36,68	30,63	18,56
NDWI	53,47	51,62	11,35	25,89	22,30	10,84
NDVI	35,17	43,83	8,15	19,52	20,43	8,68
NMDI	26,72	28,33	60,21	53,19	33,30	29,30
RVI	44,62	53,81	15,00	20,29	21,14	9,60
SAVI	27,32	27,88	8,24	13,67	12,87	14,10
VARI	26,75	34,56	5,75	8,53	11,58	3,84
EVI	30,97	27,17	9,26	11,72	11,38	15,16

En 2020, los valores de R^2 son mayores sin suavizado (salvo el caso del índice NMDI). Esto se observa de una forma notoria en la ventana de 10 m.

Comparando las Tablas 3 y 5 podemos llegar a estas conclusiones.

- Entre los datos de 2019 y 2020, el mejor R^2 (69,63%) corresponde al índice NDMI del año 2019, 30 m, con datos suavizados.
- Con la ventana de 90 m, los análisis presentan los peores resultados
- En general, los datos sin suavizar presentan mejores resultados que los suavizados.
- Los datos suavizados presentan mejores resultados con una ventana de 30 m en 2019 y con 10 m en 2020.
- Los datos no suavizados presentan mejores resultados con una ventana de 10 m, tanto en 2019 como en 2020.

Al combinar los datos de 2019 y 2020, los valores de R^2 con datos suavizados disminuyeron notoriamente como se puede observar en la Tabla 6.

Los valores más altos se obtienen con una ventana de 30 m.

Tabla 6: R² de datos conjuntos suavizados combinando los datos de los dos años.

Índice/R ²	10 m	30 m	90 m
NDMI	32,28	36,07	15,46
NDWI	22,90	23,40	4,86
NDVI	18,49	22,39	4,47
NMDI	31,55	26,76	49,24
RVI	20,95	24,23	6,43
SAVI	13,75	14,23	4,87
VARI	9,30	14,45	1,92
EVI	15,54	14,83	6,67

4.3. Modelos de HCV por índices espectrales y por parcelas

Este análisis se efectúa considerando los datos de los meses de junio a octubre del año 2020.

Dado que uno de los índices que mejor modeliza el comportamiento del HCV es el NDMI, en la Figura 3, se comparan las series temporales del HCV con la serie temporal del NDMI suavizada y no suavizada.

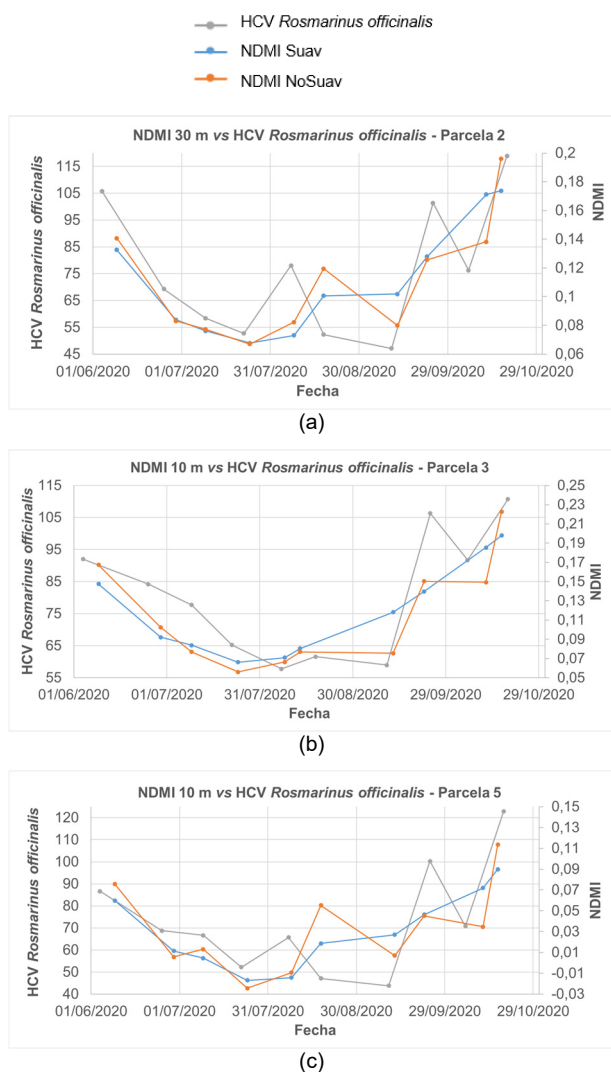


Figura 3: NDMI vs HCV: a) Parcela 2; b) Parcela 3; Parcela 5.

De las gráficas observadas, se puede destacar que en 2020 las series no suavizadas se ajustan mejor al HCV que las de los índices suavizados, lo cual se evidencia en la Figura 3. En ellas los datos no suavizados son los que siguen un patrón más semejante al de los valores de HCV de la especie de *Rosmarinus officinalis*. Estos cambios pueden estar asociados a las precipitaciones producidas en dichas fechas.

4.3.1. Comparación de series completas

A fin de verificar si lo concluido en la anterior sección, también sucede en el año 2019 y teniendo en cuenta no sólo las fechas más cercanas a la toma de datos en campo, sino todas las fechas obtenidas a partir de las imágenes Sentinel-2, se muestra un análisis gráfico por año y parcela (ver Figuras 4 y 5).

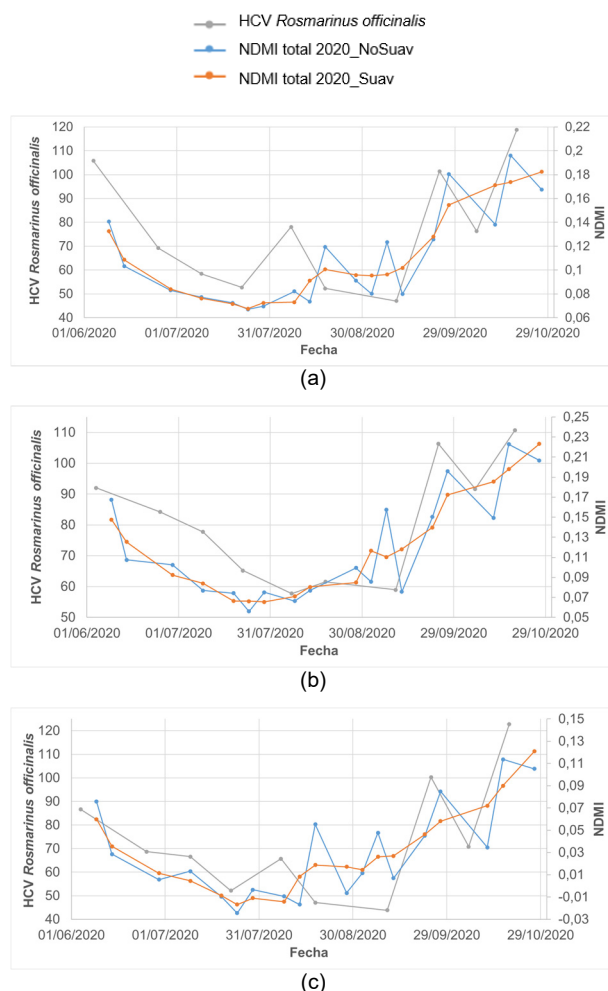


Figura 4: Serie completa de NDMI suavizado y no suavizado vs HCV: a) Parcela 2, 30 m; b) Parcela 3, 10 m; c) Parcela 5, 10 m.

4.3.1.1. Datos 2020

La Figura 4 muestra, además del HCV de *Rosmarinus officinalis*, las series completas (suavizadas y no suavizadas) del índice espectral NDMI para todo el período de estudio: junio – octubre de 2020. Con ello se ha querido reflejar una perspectiva más amplia del comportamiento de los datos al suavizarlos y al no hacerlo, aprovechando, de esta manera, la resolución temporal de Sentinel-2 y sin depender únicamente de la

fecha más cercana a la toma de datos de HCV en campo. Esto evita que se sesgue la apreciación del comportamiento del NDMI basándola en una cantidad mínima de información, que en ocasiones puede contener justamente los datos anómalos o menos representativos.

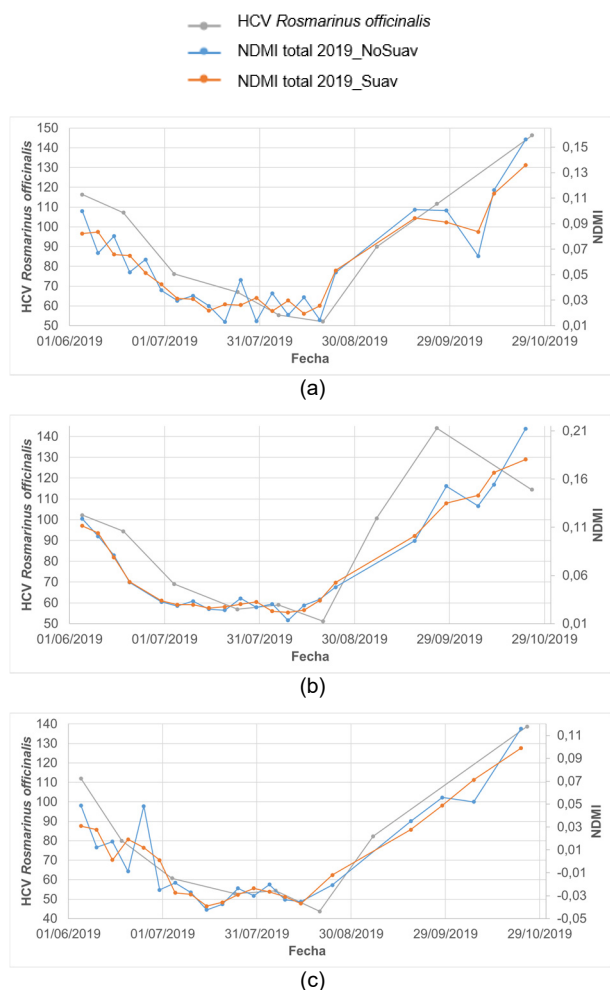


Figura 5: Serie completa de NDMI suavizado y no suavizado vs HCV: a) Parcela 2, 30 m; b) Parcela 3, 30 m; c) Parcela 5, 10 m.

La tendencia descendente de la HCV de *Rosmarinus officinalis* a lo largo de junio y julio 2020, así como los picos de cambio (presentes de agosto a octubre 2020), la recoge mejor el NDMI de los datos no suavizados, correspondiente a la línea marcada en color azul en la Figura 4.

4.3.1.2. Datos 2019

A diferencia del año 2020 en el que son característicos los cambios bruscos de HCV, la tendencia en el 2019 es distinta, de algún modo más estacional, los valores de HCV descienden hasta finales de agosto y a partir de esa fecha empiezan a aumentar.

En base a la Figura 5, se puede aseverar que, al centrar la atención en el comportamiento del HCV para el año 2019, los datos que mejor se ajustan corresponden a los de los índices suavizados.

Las series de datos no suavizados son las que menos se adaptan al HCV, con ligeras oscilaciones representando cambios que realmente no existen.

Este análisis, al igual que el del ítem anterior, se realiza considerando las series completas de NDMI, tanto para datos suavizados como no suavizados, en las parcelas: 2, 3 y 5, y con las diferentes ventanas evaluadas (10, 30 y 90 m). Aunque por simplicidad solo se muestran los resultados para alguna resolución, para todos estos casos las conclusiones son las mismas, es decir, el comportamiento y ajuste de datos no cambia sino solo entre años: HCV 2019 se ajusta mejor con el NDMI de los datos suavizados, mientras que el correspondiente a 2020 con el NDMI de los datos sin suavizar.

4.4. Modelos de regresión con dos variables combinando los datos de 2019 y 2020

Se realiza este análisis para los datos de HCV de *Rosmarinus officinalis* y teniendo en cuenta los datos no suavizados, debido a que son los que proporcionaron los mejores resultados para la mayoría de las variables espectrales.

Se emplean los datos de los años 2019 y 2020 juntos, desde junio hasta octubre.

4.4.1. Modelo I: dos variables espectrales

En este modelo (Ec. 2) se consideran los índices NDMI y NDWI, ambos con ventana de 10 m, obteniendo los siguientes resultados: R^2 : 52,51%, R^2 ajustada: 50,72%, RMSE: 19,00 y MAE: 13,63.

$$HCV = 154,179 + 903,768 * NDMI_{10m} - 486,536 * NDWI_{10m} \quad (2)$$

4.4.2. Modelo II: una variable espectral y una variable meteorológica de temperatura

En el segundo modelo (Ec. 3) participan las variables: NDMI con ventana de 10 m y la variable meteorológica de temperatura: t_{30} (promedio de las temperaturas medias diarias en los 30 días anteriores a la fecha de toma del valor de HCV en campo), obteniendo como resultados: R^2 : 55,63%, R^2 ajustado: 53,95%, RMSE: 18,37 y MAE: 14,05.

$$HCV = 172,866 + 200,544 * NDMI_{10m} - 4,35502 * t_{30} \quad (3)$$

4.4.3. Modelo III: una variable espectral y una variable meteorológica de precipitación

En el tercer modelo (Ec. 4), al igual que, en el anterior, interviene la variable NDMI de ventana de 10 m, pero esta vez junto a la variable meteorológica de precipitación: p_{60} , calculada como la precipitación acumulada en los 60 días anteriores a la toma de HCV en campo.

Se obtienen los valores de correlación más altos, reflejados de la siguiente manera: R^2 : 77,11%, R^2 ajustado: 76,25%, RMSE: 13,19 y MAE: 10,46.

$$HCV = 55,8105 + 103,936 * NDMI_{10m} + 0,493315 * p_{60} \quad (4)$$

Como se puede observar de los tres modelos, el que presenta un mejor resultado (R^2 ajustado más alto y

menores RMSE y MAE) y, por tanto, describe mejor el comportamiento de la humedad de combustible vivo es el tercero, en el que se toma en cuenta la precipitación, que como se mencionó anteriormente tiene gran relación con la HCV, especialmente en el año 2020. Sin embargo, el modelo I también mejora la correlación (R^2 : 52,51%) en comparación a los modelos que usan una sola variable, que como vimos en la Tabla 4 alcanzan un R^2 próximo al 44%.

5. Conclusiones

Los resultados de correlación entre el contenido de HCV de la especie *Rosmarinus officinalis* y cada uno de los índices espectrales presentan mejores resultados cuando el análisis se hace por separado en años diferentes: el año 2019 y el 2020.

Al combinar ambos años (2019 y 2020) y predecir los valores de la HCV de *Rosmarinus officinalis* considerando una sola variable explicativa, se pierde precisión y los valores de correlación entre la HCV y los índices espectrales disminuyen, de forma que se tiene que añadir una segunda variable para obtener modelos con un ajuste más representativo y por tanto más robustos.

Mediante el análisis de dos variables, se verifica cómo la precipitación es una variable que aporta más información

que la de temperatura, especialmente por su mayor correlación con los valores de HCV durante el año 2020.

Los tamaños de ventana que mejores resultados proporcionan son la de 10 m y la de 30 m. Se obtiene la mejor R^2 con los datos no suavizados, especialmente durante el año 2020 en el que el régimen de precipitaciones fue más irregular, ya que el filtro de suavizado, al no tomar en cuenta los diferentes picos/cambios de la variación de HCV, hace que la relación sea baja. El suavizado resulta más eficiente con ventana de 30 m para el año 2019, por una parte, y por otra, con el índice espectral NMDI para el año 2020.

Agradecimientos

M^a Alicia Arcos agradece la ayuda recibida por la Universitat Politècnica de València mediante un contrato predoctoral financiado en la convocatoria, PAID-01-19, subprograma 1. Este trabajo ha sido financiado a través de un convenio de colaboración entre la empresa Red Eléctrica de España S.A.U. y la Universitat Politècnica de València (2020-2023). Los autores agradecen a la Empresa Pública VAERSA y a la Direcció General de Prevenció d'Incendis Forestals de la Generalitat Valenciana por proporcionar los datos de medición de HCV en campo y los datos meteorológicos a través de la AEMET.

References

- CASTRO, F.X., TUDELA, A. and SEBASTIÀ, M.T., 2003. Modeling moisture content in shrubs to predict fire risk in Catalonia (Spain). *Agricultural and Forest Meteorology*, **116**, pp. 49-59.
- DE CÁCERES, M., MARTIN-STPAUL, N., TURCO, M., CABON, A., and GRANDA, V., 2018. Estimating daily meteorological data and downscaling climate models over landscapes. *Environmental Modelling and Software*, **108**, pp. 186–196.
- GARCÍA, M., RIAÑO, D., YEBRA, M., SALAS, J., CARDIL, A., MONEDERO, S., RAMIREZ, J., MARTÍN, M.P., VILAR, L., GAJARDO, J., and USTIN, S., 2020. A Live Fuel Moisture Content Product from Landsat TM Satellite Time Series for Implementation in Fire Behavior Models. *Remote Sensing*, **12**(11), 1714. DOI: 10.3390/rs12111714
- GENERALITAT VALENCIANA. 2015. Clave para la identificación de los Modelos de Combustible de la Comunitat Valenciana. Available: https://agroambient.gva.es/documents/162905929/169203680/Clave+fotogr%C3%A1fica+modelos+combustible_20200430/fd5ae58d-3b3f-4e50-866a-d83544a6f1b2 [7/17, 2021].
- GOOGLE EARTH ENGINE. 2021. Sentinel-2 MSI: MultiSpectral Instrument, Level-2A (google.com). Available: https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S2_SR [7/17, 2021].
- MARINO, E., GUILLÉN-CLIMENT, M., ALGEET, N., TOMÉ, J.L., and HERNANDO, C., 2018. Estimation of live fuel moisture content of shrubland using MODIS and Sentinel-2 Images. *Advances in Forest Fire Research 2018 - D. X. Viegas* (Ed.) Chapter 2 – Fuel Management. DOI: 10.14195/978-989-26-16-506_22.
- MARINO, E., YEBRA, M., GUILLÉN-CLIMENT, M., ALGEET, N., TOMÉ, J. L., MADRIGAL, J., and HERNANDO, C., 2020. Investigating Live Fuel Moisture Content Estimation in Fire-Prone Shrubland from Remote Sensing Using Empirical Modelling and RTM Simulations. *Remote Sensing*, **12**(14), 2251.
- MARTIN-STPAUL, N., PIMONT, F., DUPUY, J. L., RIGOLOT, E., RUFFAULT, J., FARGEON, H., and TOUTCHKOV, M., 2018. Live fuel moisture content (LFMC) time series for multiple sites and species in the French Mediterranean area since 1996. *Annals of Forest Science*, **75**(2), 57.
- MARTÍNEZ-GONZÁLEZ, F., SOSA-PÉREZ, F., and ORTIZ-MEDEL, J., 2010. Comportamiento de la humedad del suelo con diferente cobertura vegetal en la Cuenca La Esperanza. *Tecnología y ciencias del agua*, **1**(4), pp. 89-103.
- MYOUNG, B., KIM, S., NGHIEM, S., JIA, S., WHITNEY, K., and KAFATOS, M., 2018. Estimating Live Fuel Moisture from MODIS Satellite Data for Wildfire Danger Assessment in Southern California USA. *Remote Sensing*, **10**(1), 87.
- QUAN, X., HE, B., YEBRA, M., YIN, C., LIAO, Z., and LI, X., 2017. Retrieval of forest fuel moisture content using a coupled radiative transfer model. *Environmental modelling & software*, **95**, pp. 290-302.

- SORIANO, J.L. and QUILEZ, R, eds., 2017. Análisis de la humedad del combustible vivo en la Comunitat Valenciana: Actas del Séptimo Congreso Forestal Español. Cáceres, Extremadura Sociedad Española de Ciencias Forestales.
- YANG, Y., LUO, J., HUANG, Q., WU, W., and SUN, Y., 2019. Weighted Double-Logistic Function Fitting Method for Reconstructing the High-Quality Sentinel-2 NDVI Time Series Data Set. *Remote Sensing*, **11**(20), 2342. DOI: 10.3390/rs11202342.
- YEBRA, M., DENNISON, P. E., CHUVIECO, E., RIANO, D., ZYLSTRA, P., HUNT Jr, E. R., and JURDAO, S., 2013. A global review of remote sensing of live fuel moisture content for fire danger assessment: Moving towards operational products. *Remote Sensing of Environment*, **136**, pp. 455-468.