



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA



# UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Escuela Técnica Superior de Ingeniería Geodésica,  
Cartográfica y Topográfica

Evaluación de los efectos del cambio climático en el  
contenido de la humedad del combustible vivo en las zonas  
forestales de la Comunitat Valenciana.

Trabajo Fin de Máster

Máster Universitario en Ingeniería Geomática y Geoinformación

AUTOR/A: Urrecho Torres, Javier

Tutor/a: Balaguer Beser, Ángel Antonio

CURSO ACADÉMICO: 2023/2024



**ESCUELA TÉCNICA SUPERIOR  
DE INGENIERÍA GEODÉSICA  
CARTOGRÁFICA Y TOPOGRÁFICA**



**UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA**

**MÁSTER UNIVERSITARIO EN INGENIERÍA GEOMÁTICA Y  
GEOINFORMACIÓN**

**EVALUACIÓN DE LOS EFECTOS DEL  
CAMBIO CLIMÁTICO EN EL CONTENIDO DE  
LA HUMEDAD DE COMBUSTIBLE VIVO EN  
LA COMUNITAT VALENCIANA**

**AUTOR: JAVIER URRECHO TORRES**

**TUTOR: ÁNGEL ANTONIO BALAGUER BESER**

**CURSO ACADÉMICO: 2023/2024**

**VALENCIA, SEPTIEMBRE 2024**



## Agradecimientos

En primer lugar, quiero expresar mi más sincero agradecimiento a mis padres, quienes han sido y son un pilar fundamental para mí. Su apoyo incondicional, sus consejos y su confianza en mí han sido esenciales no solo durante la realización de este proyecto, sino a lo largo de toda mi vida académica. Gracias por enseñarme el valor del esfuerzo, la dedicación y la perseverancia.

A mis compañeros y amigos, tanto los que están ahí desde el principio como a los que he conocido por el camino, también quiero mostrarles mi agradecimiento. Sin vosotros, este recorrido no habría sido el mismo.

Por último, pero no menos importante, quiero expresar mi agradecimiento al grupo de investigación CGAT-UPV por su apoyo en la realización de este proyecto, en especial a mi tutor Ángel Balaguer, cuyo respaldo y orientación han sido fundamentales para llevarlo a buen término.

Este trabajo va por todos vosotros.



## Compromiso

El presente documento ha sido realizado completamente por el firmante; no ha sido entregado como otro trabajo académico previo y todo el material tomado de otras fuentes ha sido convenientemente entrecorillado y citado su origen en el texto, así como referenciado en la bibliografía.

Los datos de humedad de combustible vivo medidos en campo para este trabajo han sido proporcionados por la empresa VAERSA con la autorización de la Generalitat Valenciana, gracias a la colaboración mantenida para este fin entre el tutor de este trabajo y la Dirección General de Prevención de Incendios Forestales de la Generalitat Valenciana.



## Resumen

La Humedad del Combustible Vivo (HCV) representa el contenido de agua en relación con la materia seca de la vegetación y es una variable fundamental en la interacción entre el fuego y la materia combustible. Muchos factores medioambientales determinan el comportamiento de los incendios, pero la distribución espacial del contenido de HCV sobre el territorio y su variación a lo largo del tiempo caracteriza y condiciona la ignición, la propagación y el impacto de un incendio. El Sistema Integrado de Gestión de Incendios Forestales (SIGIF) de la Generalitat Valenciana está implementando una metodología basada en modelos de regresión lineal multivariante para obtener estimaciones del contenido de HCV en toda la superficie forestal de la Comunitat Valenciana, tarea en la cual está colaborando el tutor de este trabajo fin de máster. Para ello se usan datos obtenidos por los satélites Sentinel-2, aproximadamente cada 5 días, junto con datos meteorológicos diarios de precipitación, temperatura, humedad relativa y velocidad del viento, cedidos al SIGIF por la Agencia Estatal de Meteorología (AEMET). Las ecuaciones de dichos modelos fueron ajustadas usando datos de HCV tomados en campo desde junio de 2020 hasta noviembre de 2021. Dado que la Comunitat Valenciana no es homogénea en cuanto a sus características climáticas y geográficas, se han desarrollado ecuaciones específicas para diferentes especies arbóreas, pisos bioclimáticos y modelos de combustible.

En este trabajo se ha desarrollado una metodología para la validación de dichos modelos del SIGIF usando datos de campo de HCV obtenidos en la Comunitat Valenciana durante los años 2022 y 2023. Para ello se ha creado una nueva base de datos con los valores de HCV tomados en campo para diferentes especies vegetales, en diferentes parcelas y en diferentes instantes de tiempo durante los años 2022-2023, proporcionados al tutor del TFM por la empresa VAERSA. Para obtener las predicciones con los modelos que se están implementando en el SIGIF ha sido necesario usar diversas fuentes de datos: (1) información meteorológica puntual suministrada por la AEMET que ha sido interpolada para cubrir toda la zona de trabajo, (2) información espectral obtenida de los satélites Sentinel-2 y tratada con Google Earth Engine (GEE) para obtener distintos índices que guarden relación con la humedad de la vegetación y, (3) datos topográficos, obtenidos del ICV (Institut Cartogràfic Valencià), en puntos en los que la empresa VAERSA ha realizado muestreos de HCV.

Los datos meteorológicos diarios han permitido analizar los cambios en el patrón de precipitaciones, temperaturas y humedad relativa que se han producido en los años 2022 y 2023 respecto a los años precedentes. También se ha analizado su incidencia en la pérdida de precisión de los modelos del contenido de HCV ajustados con datos de los años 2020 y 2021 para hacer predicciones en los años siguientes. Y se ha propuesto una formulación alternativa de los modelos para mitigar los errores observados en dicha validación.

Este estudio demuestra la importancia de monitorizar de cerca indicadores clave en la prevención de incendios forestales, como la humedad del combustible vivo, que se pueden ver alterados por los efectos del cambio climático. La combinación de diversas fuentes de datos y el desarrollo de ecuaciones específicas para diferentes pisos bioclimáticos y tipos de vegetación en la Comunitat Valenciana proporciona una visión integral y precisa de la evolución del contenido de HCV en dicho territorio.



## Abstract

Live Fuel Moisture (LFM) represents the water content in relation to the dry matter of the vegetation and is a fundamental variable in the interaction between fire and fuel matter. Many environmental factors determine the behavior of fires, but the spatial distribution of LFM content over the territory and its variation over time characterizes and conditions the ignition, spread and impact of a fire. Sistema Integrado de Gestión de Incendios Forestales (SIGIF) of the Generalitat Valenciana is implementing a methodology based on multivariate linear regression models to obtain estimates of the LFM content in the entire forest area of the Valencian Community, a task in which the tutor of this master's final project. For this, data obtained by the Sentinel-2 satellites are used, approximately every 5 days, together with daily meteorological data on precipitation, temperature, relative humidity, and wind speed, transferred to the SIGIF by Agencia Estatal de Meteorología (AEMET). The equations of these models were adjusted using LFM data taken in the field from June 2020 to November 2021. Given that the Valencian Community is not homogeneous in terms of its climatic and geographical characteristics, specific equations have been developed for different tree species, bioclimatic floors, and fuel models.

In this work, a methodology has been developed for the validation of these SIGIF models using LFM field data obtained in the Valencian Community during the years 2022 and 2023. To this end, a new database has been created with the LFM values taken in the field for different plant species, in different plots and at different moments of time during the years 2022-2023, provided to the TFM tutor by VAERSA company. To obtain the predictions with the models that are being implemented in the SIGIF, it has been necessary to use several data sources: (1) point meteorological information provided by the AEMET that has been interpolated to cover the entire work area, (2) spectral information obtained from the Sentinel-2 satellites and processed with Google Earth Engine (GEE) to obtain different indices related to vegetation moisture and, (3) topographic data, obtained from ICV (Institut Cartogràfic Valencià), at points where VAERSA has carried out LFM sampling.

The daily meteorological data has made it possible to analyse the changes in the pattern of rainfall, temperatures and relative humidity that have occurred in 2022 and 2023 compared to previous years. Its impact on the loss of accuracy of LFM content models adjusted with data from the years 2020 and 2021 has also been analysed to make predictions in the following years. And an alternative formulation of the models has been proposed to mitigate the errors observed in such validation.

This study demonstrates the importance of closely monitoring key indicators in wildfire prevention, such as the moisture of living fuel, which can be altered by the effects of climate change. The combination of various data sources and the development of specific equations for different bioclimatic floors and vegetation types in the Valencian Community provides a comprehensive and accurate view of the evolution of LFM content in this territory.

**Keywords:** Live Fuel Moisture, Valencian Region, Sentinel-2, Climate Change, Remote Sensing, Regression



### **Acrónimos**

**AEMET:** Agencia Estatal de Meteorología

**CGAT:** Cartografía GeoAmbiental y Teledetección

**ETSICGT:** Escuela Técnica Superior de Ingeniería Geodésica, Cartográfica y Topográfica

**FCC:** Fracción de Cobertura Cubierta

**HCV:** Humedad del Combustible Vivo

**IDEV:** Infraestructura de Datos Espaciales Valenciana

**IPCC:** Intergovernmental Panel on Climate Change

**MDT:** Modelo Digital del Terreno

**NOAA:** National Oceanic and Atmospheric Administration

**ODS:** Objetivos de Desarrollo Sostenible

**PATFOR:** Plan de Acción Territorial Forestal de la Comunitat Valenciana

**SIGIF:** Sistema Integrado de Gestión de Incendios Forestales

**VAERSA:** Valenciana d'Estratègies i Recursos per a la Sostenibilitat Ambiental



## Índice de tablas

Tabla 1: Información bandas Sentinel-2. Fuente: European Space Agency.....	18
Tabla 2: Variables meteorológicas recogidas en el proyecto. Fuente: elaboración propia.....	19
Tabla 3: Parcelas muestreadas en el periodo 2020-2021. Fuente: elaboración propia. ....	23
Tabla 4: Índices espectrales utilizados en el proyecto. Fuente: elaboración propia. ....	24
Tabla 5: Valores de píxel en la banda SCL. Fuente: European Space Agency. ....	25
Tabla 6: Información de las parcelas. Fuente: elaboración propia.....	34
Tabla 7: Ecuaciones originales de HCV. Fuente: Arcos et al. (2023) .....	36
Tabla 8: RMSE según modelo para las parcelas de matorral situadas en el piso G1. Fuente: elaboración propia. ....	57
Tabla 9: RMSE según modelo del piso G2S para las parcelas de matorral situadas en el piso G1. Fuente: elaboración propia.....	61
Tabla 10: RMSE según modelo para las parcelas de arbolado situadas en el piso G1. Fuente: elaboración propia. ....	63
Tabla 11: RMSE según modelo del piso G2T para las parcelas de arbolado situadas en el piso G1. Fuente: elaboración propia. ....	65
Tabla 12: RMSE según modelo para las parcelas de matorral situadas en el piso G2. Fuente: elaboración propia. ....	67
Tabla 13: RMSE según modelo para las parcelas de arbolado situadas en el piso G2. Fuente: elaboración propia. ....	74
Tabla 14: RMSE según modelo del piso G1T para las parcelas de arbolado situadas en el piso G2. Fuente: elaboración propia. ....	76
Tabla 15: RMSE de las parcelas sobre las que se ha realizado un nuevo modelo local. Fuente: elaboración propia. ....	79
Tabla 16: RMSE según modelo para las parcelas cercanas a Gandía. Fuente: elaboración propia. .....	80
Tabla 17: RMSE según modelo para las parcelas de matorral cercanas a Gandía. Fuente: elaboración propia. ....	81
Tabla 18: RMSE según modelo para las parcelas de matorral cercanas a Yatova-Dos Aguas. Fuente: elaboración propia.....	82
Tabla 19: Validación de los 2 modelos respecto a los valores reales de HCV. Fuente: elaboración propia. ....	87



## Índice de mapas

Mapa 1: Situación de los puntos de muestreo. Fuente: elaboración propia a partir de datos de VAERSA. ....	17
Mapa 2: Pisos bioclimáticos en la Comunitat Valenciana. Fuente: elaboración propia a partir de datos del Banco de Datos para la Naturaleza. ....	21
Mapa 3: Mapa de Modelos de combustible de la Comunitat Valenciana. Fuente: Dirección General de Prevención de Incendios Forestales. Conselleria de Justicia e Interior - Generalitat Valenciana. ....	22
Mapa 4: Precipitación en la Comunitat Valenciana durante el día 05/02/2022. Fuente: elaboración propia. ....	30
Mapa 5: Mapa de pendiente de la Comunitat Valenciana. Fuente: elaboración propia. ....	32
Mapa 6: Precipitación acumulada registrada en la Comunitat Valenciana durante marzo de 2022. Fuente: AEMET. ....	37
Mapa 7: Parcelas de matorral situadas en el piso G1. Fuente: elaboración propia. ....	57
Mapa 8: Parcelas de arbolado situadas en el piso G1. Fuente: elaboración propia. ....	62
Mapa 9: Parcelas de matorral situadas en el piso G2. Fuente: elaboración propia. ....	66
Mapa 10: Parcelas de arbolado situadas en el piso G2. Fuente: elaboración propia. ....	73
Mapa 11: Parcelas sobre las que se ha realizado un nuevo modelo local. Fuente: elaboración propia. ....	78
Mapa 12: HCV estimado con la ecuación nueva para el día 05/04/2023. Fuente: elaboración propia. ....	85
Mapa 13: Detalle del HCV estimado con la ecuación nueva para el día 05/04/2023. Fuente: elaboración propia. ....	86
Mapa 14: Diferencia entre valores predichos de HCV en el modelo nuevo y el modelo original para el 05/04/2023. Fuente: elaboración propia. ....	87



## Índice de gráficas

Gráfica 1: Relación entre NDVI y MSK_CLD en Albaida sin filtrar. Fuente: elaboración propia.	26
Gráfica 2: Relación entre NDVI y MSK_CLD en Albaida al filtrar por MSK_CLD inferior o igual a 0.05. Fuente: elaboración propia.	26
Gráfica 3: Evolución del NDVI en Sant Mateu antes de filtrar outliers. Fuente: elaboración propia.	27
Gráfica 4: Evolución del NDVI en Sant Mateu después de filtrar outliers. Fuente: elaboración propia.	28
Gráfica 5: Precipitación anual según observatorio. Fuente: elaboración propia.	41
Gráfica 6: Precipitación por meses en Sant Mateu según periodo. Fuente: elaboración propia.	43
Gráfica 7: Precipitación por meses en Barx según periodo. Fuente: elaboración propia.	43
Gráfica 8: Precipitación por meses en Bétera según periodo. Fuente: elaboración propia.	44
Gráfica 9: Precipitación por meses en Beneixama según periodo. Fuente: elaboración propia.	44
Gráfica 10: Precipitación por meses en Sant Mateu según año. Fuente: elaboración propia.	45
Gráfica 11: Precipitación por meses en Barx según año. Fuente: elaboración propia.	46
Gráfica 12: Precipitación por meses en Bétera según año. Fuente: elaboración propia.	46
Gráfica 13: Precipitación por meses en Beneixama según año. Fuente: elaboración propia.	47
Gráfica 14: Temperatura media anual por estación. Fuente: elaboración propia.	48
Gráfica 15: Temperatura media mensual en Sant Mateu según periodo. Fuente: elaboración propia.	50
Gráfica 16: Temperatura media mensual en Barx según periodo. Fuente: elaboración propia.	50
Gráfica 17: Temperatura media mensual en Bétera según periodo. Fuente: elaboración propia.	51
Gráfica 18: Temperatura media mensual en Beneixama según periodo. Fuente: elaboración propia.	51
Gráfica 19: Temperatura media mensual en Sant Mateu según año. Fuente: elaboración propia.	53
Gráfica 20: Temperatura media mensual en Barx según año. Fuente: elaboración propia.	53
Gráfica 21: Temperatura media mensual en Bétera según año. Fuente: elaboración propia.	54
Gráfica 22: Temperatura media mensual en Beneixama según año. Fuente: elaboración propia.	54
Gráfica 23: Evolución del HCV por parcela en el periodo 2021-2023. Fuente: elaboración propia a partir de los datos suministrados por VAERSA.	56
Gráfica 24: Evolución del HCV en la parcela de Gandía Parpalló según modelo. Fuente: elaboración propia.	58
Gráfica 25: HCV observado en Gandia Parpalló según especie. Fuente: elaboración propia.	59
Gráfica 26: Evolución del HCV en la parcela de Bétera según modelo. Fuente: elaboración propia.	60
Gráfica 27: Evolución del HCV en la parcela de Gilet según modelo. Fuente: elaboración propia.	60
Gráfica 28: Evolución del HCV en Gilet según ecuaciones de los pisos G1S y G2S. Fuente: elaboración propia.	62
Gráfica 29: Evolución del HCV en la parcela de Gandía Umbria según modelo. Fuente: elaboración propia.	63



Gráfica 30: Evolución del ARVI y el EVI en la parcela de Gandía Umbria. Fuente: elaboración propia. ....	64
Gráfica 31: Evolución del HCV en la parcela de Desert Palmes según modelo. Fuente: elaboración propia. ....	65
Gráfica 32: Evolución del HCV en la parcela de 53_Eslida según modelo. Fuente: elaboración propia. ....	67
Gráfica 33: HCV observado en 53_Eslida según especie. Fuente: elaboración propia. ....	68
Gráfica 34: Evolución del HCV en la parcela de 77_Villalonga según modelo. Fuente: elaboración propia. ....	69
Gráfica 35: Evolución del HCV en la parcela de 87_Altea Jalon según modelo. Fuente: elaboración propia. ....	69
Gráfica 36: Evolución del HCV en la parcela de Albaida según modelo. Fuente: elaboración propia. ....	70
Gráfica 37: Evolución del HCV en la parcela de Yatova según modelo. Fuente: elaboración propia. ....	71
Gráfica 38: Evolución del HCV en la parcela de Dos Aguas según modelo. Fuente: elaboración propia. ....	71
Gráfica 39: HCV observado en Dos Aguas según especie. Fuente: elaboración propia. ....	72
Gráfica 40: Evolución del HCV en la parcela de Chovar según modelo. Fuente: elaboración propia. ....	73
Gráfica 41: Evolución del HCV en la parcela de 85_Altea Jalon según modelo. Fuente: elaboración propia. ....	75
Gráfica 42: Evolución del HCV en la parcela de Villargordo según modelo. Fuente: elaboración propia. ....	75
Gráfica 43: Evolución del HCV en la parcela de Torre Maçanes según modelo. Fuente: elaboración propia. ....	76
Gráfica 44: Evolución del HCV en la parcela de Montanejos según modelo. Fuente: elaboración propia. ....	77
Gráfica 45: HCV observado en Montanejos según especie. Fuente: elaboración propia. ....	78
Gráfica 46: Evolución del HCV en la parcela de Gandía Umbria según modelo. Fuente: elaboración propia. ....	79
Gráfica 47: Evolución del HCV en la parcela de Gandía Parpalló según modelo. Fuente: elaboración propia. ....	80
Gráfica 48: Evolución del HCV en la parcela de Gandía Parpalló según modelo. Fuente: elaboración propia. ....	81
Gráfica 49: Evolución del HCV en la parcela de Tous según modelo. Fuente: elaboración propia. ....	82
Gráfica 50: Evolución del HCV en la parcela de Dos Aguas según modelo. Fuente: elaboración propia. ....	83
Gráfica 51: Evolución del HCV en la parcela de Yatova según modelo. Fuente: elaboración propia. ....	83
Gráfica 52: Evolución del HCV en la parcela de 33_Cortes según modelo. Fuente: elaboración propia. ....	84



## Índice

Agradecimientos .....	1
Compromiso .....	2
Resumen.....	3
Abstract .....	4
Objetivos .....	12
1. Introducción .....	13
1.1. Trabajos anteriores.....	13
1.2. Humedad del combustible vivo y su cuantificación .....	14
1.3. Relación con los ODS .....	15
2. Datos .....	16
2.1. Datos de HCV .....	16
2.2. Información espectral.....	17
2.3. Información meteorológica .....	19
2.4. Información topográfica .....	20
2.5. Pisos bioclimáticos.....	20
2.6. Modelos de combustible .....	21
2.7. Base de datos de entrenamiento.....	23
3. Metodología .....	24
3.1. Descarga y procesamiento espectral.....	24
3.1.1. Descarga .....	24
3.1.2. Filtrados de datos general .....	25
3.1.3. Filtrado de <i>outliers</i> .....	27
3.1.4. Interpolación y cálculo de los valores medios de los índices espectrales.....	28
3.2. Procesamiento meteorológico .....	29
3.2.1. Interpolación y generación de mapas ráster meteorológicos.....	29
3.2.2. Extracción de valores meteorológicos.....	30
3.2.3. Cálculo de variables acumuladas.....	30
3.3. Procesamiento topográfico .....	31
3.4. Clasificación de parcelas por piso y combustible .....	32
3.5. Obtención de fórmulas de HCV .....	35
3.5.1. Variaciones sobre las ecuaciones originales .....	36
3.5.1.1. Ecuación para el piso G1S.....	38
3.5.1.2. Ecuación para el piso G1T.....	38
3.5.1.3. Ecuación para el piso G2S.....	38
3.5.1.4. Ecuación para el piso G2T.....	39
3.5.1.5. Ecuación para Gandía .....	39
3.5.1.6. Ecuación para matorral en Gandía .....	39



3.5.1.7. Ecuación para Yátova-Dos Aguas.....	39
3.6. Generación de mapas ráster de HCV.....	40
4. Resultados.....	41
4.1. Análisis meteorológico.....	41
4.1.1. Análisis pluviométrico 2010-2023.....	41
4.1.2. Análisis pluviométrico 2020-2023.....	45
4.1.3. Análisis de temperatura 2010-2023.....	48
4.1.4. Análisis de temperatura 2020-2023.....	52
4.2. Análisis de HCV.....	55
4.2.1. Evolución del HCV entre el 2020 y el 2023.....	55
4.2.2. Modelo de matorral en el piso G1.....	56
4.2.3. Modelo de arbolado en el piso G1.....	62
4.2.4. Modelo de matorral en el piso G2.....	65
4.2.5. Modelo de arbolado en el piso G2.....	73
4.2.6. Modelos locales.....	78
4.2.6.1. Modelo para parcelas de Gandía.....	79
4.2.6.2. Modelo para matorral de Gandía.....	81
4.2.6.3. Modelo para Yátova-Dos Aguas.....	82
4.3. Mapa de predicción de HCV con el nuevo modelo.....	84
5. Conclusiones.....	89
5.1. Posibles mejoras.....	90
6. Presupuesto.....	91
7. Bibliografía.....	92
8. Cartografía.....	94
Anexo A.....	98
Estadísticos de los nuevos modelos con los datos de entrenamiento.....	98
Piso G1S.....	98
Piso G1T.....	99
Piso G2S.....	100
Piso G2T.....	101
Ecuación para Gandía.....	102
Ecuación para matorral de Gandía.....	103
Ecuación para Yatova-Dos Aguas.....	104
Anexo B.....	105
Efecto sobre el HCV de utilizar medias actuales o antiguas.....	105
Piso G1S.....	105
Piso G1T.....	106
Piso G2T.....	107
Anexo C.....	109
Scripts.....	109



## Objetivos

La Humedad del Combustible Vivo (HCV) representa el contenido de agua en relación con la materia seca de la vegetación. El objetivo principal del proyecto es evaluar los efectos del cambio climático sobre el contenido de HCV en la Comunitat Valenciana, calculado a partir de ecuaciones de predicción de HCV que utilizan principalmente datos espectrales y meteorológicos.

Los objetivos secundarios son los siguientes:

- Elaborar una metodología para obtener datos espectrales y meteorológicos para cada punto de muestreo y fecha mediante código Python.
- Validar las ecuaciones originales mencionadas en Arcos et al. (2023) con datos de HCV registrados entre los años 2022 y 2023.
- Analizar las diferencias entre los valores de HCV predichos por las ecuaciones y los valores observados de HCV en el periodo 2022-2023.
- Comparar el periodo de entrenamiento 2020-2021 con el periodo de validación 2022-2023 y estudiar las diferencias climáticas entre ambos periodos, que pueden haber afectado a la predicción del HCV.
- Crear modelos nuevos de predicción que se adapten mejor a los condicionantes del periodo 2022-2023.
- Generar mapas ráster de HCV con estas nuevas ecuaciones.



## 1. Introducción

### 1.1. Trabajos anteriores

Dentro del grupo de investigación Cartografía Geoambiental y Teledetección de la UPV (CGAT-UPV), con el que se ha colaborado en la realización de este proyecto, se han realizado otros trabajos relacionados con estimaciones de HCV a partir de datos espectrales y meteorológicos, fruto de la colaboración con VAERSA, organismo encargado de suministrar las mediciones de HCV en campo.

Freire Quintanilla (2019), en su trabajo *Estimación de la humedad del combustible vivo usando imágenes Sentinel-2 en parcelas forestales de la Comunidad Valenciana*, hizo modelos de predicción de HCV estación a estación, lo que generó ecuaciones robustas con un error muy reducido, pero que solo tienen utilidad localmente, en el entorno de cada estación.

Otra aportación destacable es la de Pachacama (2022) con su trabajo *Modelización del contenido de Humedad de Combustible Vivo en la Comunitat Valenciana usando índices espectrales extraídos de Sentinel-2 durante los meses de verano y otoño desde 2019 hasta 2021*, en el que desarrolla modelos de predicción de HCV de carácter más general, generando un modelo distinto para cada provincia y modelo de combustible.

Por último, cabe destacar un artículo relacionado con la cuantificación del HCV realizado dentro del departamento, escrito por Arcos et al. (2023) con el título *Analyzing Independent LFMC Empirical Models in the Mid-Mediterranean Region of Spain Attending to Vegetation Types and Bioclimatic Zones*. En este estudio, se presentan diversos modelos de predicción de HCV específicos para la Comunitat Valenciana, diferenciados por piso bioclimático y tipo de combustible. Las ecuaciones, entrenadas con datos recogidos entre junio de 2020 y noviembre de 2021, han sido validadas en este proyecto utilizando datos más recientes.

Este proyecto representa una pequeña ampliación sobre todo el trabajo que el CGAT ha realizado en colaboración con VAERSA, validando los modelos más recientes de estimación de HCV y proponiendo modelos nuevos que se adapten mejor a las cambiantes condiciones meteorológicas afectadas por el cambio climático.



## 1.2. Humedad del combustible vivo y su cuantificación

El HCV es un parámetro crítico en el estudio del comportamiento del fuego en ecosistemas naturales. Este factor es esencial porque afecta directamente la inflamabilidad de la vegetación, la propagación del fuego y la intensidad de los incendios forestales.

El HCV es un indicador clave del estado hídrico de la vegetación, el cual se ve influenciado por factores climáticos, estacionales y fenológicos. En condiciones de baja humedad, las plantas tienden a ser más inflamables, lo que incrementa el riesgo de incendios forestales. La variabilidad en el HCV puede influir significativamente en la ocurrencia y severidad de incendios, especialmente en regiones propensas a sequías o con climas mediterráneos (Yebra et al., 2013).

Existen varios métodos para la cuantificación del HCV, que varían en precisión, coste y aplicabilidad en campo. Tradicionalmente, la humedad del combustible vivo se ha medido mediante el método gravimétrico, que implica recolectar muestras de vegetación, pesarlas frescas, secarlas en un horno y luego volver a pesarlas para determinar el contenido de agua. Aunque este método es conocido por su alta precisión, tiene varias limitaciones significativas. Es un proceso laborioso y costoso, ya que requiere equipos específicos y tiempo considerable para el secado y pesaje de las muestras. Además, este método es menos adecuado para el monitoreo en tiempo real o en grandes áreas debido a las demandas logísticas y temporales que impone (Sharma et al., 2018).

Con los avances tecnológicos, se han desarrollado métodos indirectos para estimar el HCV, como el uso de sensores de humedad y tecnología de teledetección. La teledetección, mediante satélites o drones equipados con sensores multispectrales, ha permitido estimar el HCV a escalas espaciales más amplias y con mayor frecuencia temporal (Quan et al., 2021).

La cuantificación precisa del HCV es fundamental para mejorar la modelización del comportamiento del fuego y para la planificación de estrategias de manejo forestal. Los modelos de simulación del fuego utilizan el HCV como una variable crítica para predecir la propagación del fuego y para tomar decisiones sobre la asignación de recursos para la prevención y supresión de incendios.



### 1.3. Relación con los ODS

Este proyecto se alinea estrechamente con varios Objetivos de Desarrollo Sostenible (ODS) de las Naciones Unidas, especialmente en lo que respecta a la acción climática, la vida de ecosistemas terrestres, y la educación de calidad.

Este proyecto se relaciona directamente con el ODS 13, que tiene como objetivo tomar medidas urgentes para combatir el cambio climático y sus impactos. El cambio climático está alterando los patrones de humedad en la vegetación, aumentando el riesgo de incendios forestales debido a la reducción del HCV. Al estudiar y modelar estos efectos, el proyecto contribuye a la comprensión de cómo el cambio climático afecta a los ecosistemas locales y proporciona herramientas para la mitigación y adaptación a sus impactos, lo cual es crucial para la planificación de estrategias de manejo forestal y la prevención de desastres naturales.

El ODS 15 busca proteger, restaurar y promover el uso sostenible de los ecosistemas terrestres y conservar la biodiversidad. La gestión adecuada del contenido de HCV es crucial para prevenir la degradación de los ecosistemas y proteger la biodiversidad. Este proyecto, al desarrollar modelos predictivos para el HCV y su relación con el cambio climático, contribuye directamente a estos objetivos. Comprender y anticipar los cambios en el HCV debido a la variabilidad climática permite mejorar las estrategias de manejo del fuego, fundamentales para la protección de los ecosistemas forestales y la biodiversidad. Implementar estas estrategias ayuda a mitigar los efectos negativos del cambio climático en los ecosistemas, promoviendo la sostenibilidad de los hábitats naturales (Driscoll et al., 2010).

El ODS 11 busca hacer que las ciudades y los asentamientos humanos sean inclusivos, seguros, resilientes y sostenibles. Los incendios forestales representan una amenaza significativa para las comunidades, especialmente en áreas urbanas y rurales cercanas a bosques y zonas naturales. Al mejorar la capacidad para predecir incendios forestales mediante el estudio del HCV, este proyecto contribuye a la seguridad y resiliencia de los municipios en la Comunitat Valenciana. La integración de estos modelos en la planificación urbana y la gestión del territorio puede reducir el riesgo de desastres, protegiendo tanto vidas humanas como infraestructuras (Moritz et al., 2014).



## 2. Datos

### 2.1. Datos de HCV

Los datos de HCV han sido suministrados por el Sistema Integrado de Gestión de Incendios Forestales (SIGIF) y descargados a través de su portal web<sup>1</sup> en formato Excel gracias al acceso proporcionado al tutor de este TFM. El archivo descargado ofrece 8197 datos de HCV del periodo 2022-2023, pertenecientes a distintas especies y recogidos en un gran número de estaciones situadas en la Comunitat Valenciana.

El archivo contiene información sobre la parcela, la fecha y la especie sobre la que se ha realizado el muestreo de HCV, junto con el valor de humedad recogido. Los valores de humedad están descompuestos en 4 variables distintas: peso bruto, peso bote, peso húmedo y peso seco. También hay un apartado de observaciones donde se apuntan incidencias que haber tenido lugar durante la recogida de las muestras.

Las muestras con las que se calcula el HCV han sido recogidas en campo por técnicos, tomando ramas, hojas y brotes pequeños de plantas de la especie concreta de la que se quiere realizar el muestreo. Posteriormente estas muestras son analizadas en laboratorio, donde son pesadas con balanzas de precisión y sometidas a un proceso de secado. Estas muestras han sido tomadas en campo por la empresa Valenciana d'Estratègies i Recursos per a la Sostenibilitat Ambiental (VAERSA), una empresa pública dependiente de la Generalitat Valenciana.

El peso bruto es el peso total de la muestra recogida en campo junto con el peso del bote. Al eliminar el peso del bote del peso bruto se obtiene un tercer peso, conocido como peso húmedo.

$$\text{Peso húmedo} = \text{Peso bruto} - \text{Peso bote} \quad (1)$$

El peso seco se obtiene después de someter a las muestras a una temperatura específica de 100 °C en un horno de secado durante 24-48 horas como mínimo o hasta que el peso se estabilice, indicando que toda la humedad ha sido eliminada. Después del secado estas muestras son finalmente pesadas.

El cálculo de la humedad del combustible vivo se realiza empleando una fórmula que relaciona el peso húmedo con el peso seco de la siguiente forma:

$$HCV = \frac{(\text{Peso húmedo} - \text{Peso seco})}{\text{Peso seco}} \times 100 \quad (2)$$


De forma general, se ha trabajado con aquellos datos que provienen de estaciones en las que se han recogido datos con una periodicidad semanal o mensual durante los años 2022 y 2023, para poder observar la evolución del HCV durante el periodo de estudio. Las estaciones utilizadas se pueden ver en el mapa 1. Las estaciones que llevan número delante, por ejemplo 36\_Gandia Umbria, es porque cuentan también con datos recogidos en los años 2020 y 2021.

Algunos de los puntos de muestreo están situados en zonas donde se ha producido recientemente un incendio, por lo que sus valores de HCV no se consideran representativos y no se han utilizado en el estudio. Estos puntos vienen señalados en la base de datos por las siglas IF antes del nombre de la parcela.

---

<sup>1</sup> <https://prevencionincendiosgva.es/>

Otras estaciones que no se han utilizado son aquellas en las que se han realizado quemas agrícolas. En el archivo original vienen recogidas con las siglas RX antes del nombre, de la misma forma que en el caso anterior.



Mapa 1: Situación de los puntos de muestreo. Fuente: elaboración propia a partir de datos de VAERSA.

En este proyecto se ha trabajado con la media ponderada del HCV para todas las especies presentes en cada parcela. Este valor medio se ha calculado ponderando el valor de HCV de cada especie según su Fracción de Cobertura (FCC), un valor proporcionado por el SIGIF que representa el porcentaje de superficie que ocupa cada especie. Este cálculo se ha realizado mediante un script de Python, que se puede ver en el anexo C (calculate\_media.py).

## 2.2. Información espectral

En la realización de este proyecto se han utilizado datos espectrales provenientes de los satélites Sentinel-2. Estos satélites son parte del programa Copernicus, gestionado por la Agencia Espacial Europea (ESA), y están especialmente equipados para la monitorización de la vegetación, los cuerpos de agua y la cobertura terrestre en general. Sentinel-2 captura imágenes en 13 bandas espectrales en el espectro visible, infrarrojo cercano e infrarrojo de onda corta, utilizando una constelación de dos satélites idénticos, Sentinel-2A y Sentinel-2B. Sentinel-2A fue puesto en



órbita el día 23 de junio de 2015, mientras que su gemelo Sentinel-2B fue puesto en órbita el día 7 de marzo de 2017.

Estos satélites operan en una órbita sincrónica con el sol a 786 km de altitud, pero con un desfase de 180° entre sí, lo que garantiza una iluminación constante de las áreas observadas y permite una cobertura global de la superficie terrestre cada cinco días en el ecuador. Esta alta frecuencia de revisita es crucial para monitorizar cambios dinámicos en el medio ambiente con gran precisión.

En este estudio, las bandas más relevantes son las que permiten la observación detallada de la vegetación y el contenido de agua. Estas bandas incluyen el rojo, el infrarrojo cercano y el infrarrojo de onda corta, que facilitan el cálculo de índices como el NDVI (Índice de Vegetación de Diferencia Normalizada) y el NDWI (Índice de Agua de Diferencia Normalizada).

Las imágenes de Sentinel-2 ofrecen una resolución espacial de hasta 10 metros para las bandas visibles e infrarrojas cercanas, de 20 metros para las bandas de infrarrojo de onda corta y de 60 metros para bandas de detección de nubes como B9. La información asociada a cada una de las bandas se puede encontrar en la tabla 1. Estas resoluciones ofrecidas por Sentinel-2 son bastante buenas para el propósito de este proyecto, teniendo en cuenta que trabajamos con toda la superficie de la Comunitat Valenciana.

Banda	Nombre	Espectro Electromagnético ( $\mu\text{m}$ )	Resolución (m)
B1	Coastal aerosol	0.443	60
B2	Blue	0.490	10
B3	Green	0.560	10
B4	Red	0.665	10
B5	Vegetation Red Edge	0.705	20
B6	Vegetation Red Edge	0.740	20
B7	Vegetation Red Edge	0.783	20
B8	NIR (Near Infrared)	0.842	10
B8A	Vegetation Red Edge	0.865	20
B9	Water vapour	0.945	60
B10	SWIR - Cirrus	1.375	60
B11	SWIR	1.610	20
B12	SWIR	2.190	20

Tabla 1: Información bandas Sentinel-2. Fuente: European Space Agency.

Junto a estas bandas, también se han utilizado otras bandas auxiliares como SCL (Scene Classification Layer), MSK\_CLD (Cloud Mask) o TCI (True Color Index).

La banda SCL clasifica automáticamente los píxeles en categorías como vegetación, agua, nubes y otros, facilitando el filtrado de datos erróneos. La banda MSK\_CLD es esencial para identificar y excluir áreas cubiertas por nubes, mientras que la banda TCI proporciona imágenes en color verdadero. Estas bandas han sido utilizadas para filtrar datos espectrales erróneos observados durante el procesamiento de datos.

Las imágenes utilizadas tienen un nivel de procesamiento L2A, que es preferido por incluir correcciones atmosféricas esenciales para análisis precisos de reflectancia de la superficie terrestre. Este paso es necesario para realizar comparaciones temporales y espaciales efectivas y para minimizar las distorsiones que las variaciones atmosféricas pueden introducir.



### 2.3. Información meteorológica

Los datos meteorológicos utilizados en este proyecto han sido suministrados al SIGIF por la AEMET y posteriormente reenviados al tutor de este proyecto. La información meteorológica está dividida en 4 archivos con datos de temperatura, precipitación, humedad relativa y viento registrados por la AEMET en los distintos observatorios que tiene situados en la Comunitat Valenciana y alrededores.

En cada uno de los archivos viene información asociada al código y al nombre de la estación, la fecha en la que ha sido tomada la variable, la altitud del observatorio y las coordenadas UTM. En la tabla 2 se puede ver la información relativa a estas variables.

Variable	Nombre	Unidad	Descripción
TMAX	Temperatura máxima	décimas de °C	Temperatura máxima registrada en un día.
TMED	Temperatura media	décimas de °C	Promedio de las temperaturas registradas durante un día.
TMIN	Temperatura mínima	décimas de °C	Temperatura mínima registrada en un día.
P77	Precipitación acumulada	décimas de mm	Cantidad total de precipitación (lluvia, nieve, granizo, etc.) acumulada en un día.
HU00	Humedad a 00:00	%	Porcentaje de humedad relativa a las 00:00 horas.
HU07	Humedad a las 07:00	%	Porcentaje de humedad relativa a las 07:00 horas.
HU13	Humedad a las 13:00	%	Porcentaje de humedad relativa a las 13:00 horas.
HU19	Humedad a las 19:00	%	Porcentaje de humedad relativa a las 19:00 horas.
HUMAX	Humedad máxima	%	Porcentaje de humedad relativa máxima registrada en un día.
HHUMAX	Hora de humedad máxima	horas	Hora del día en la que se registró el porcentaje de humedad relativa máxima.
HUMIN	Humedad mínima	%	Porcentaje de humedad relativa mínima registrada en un día.
HHUMIN	Hora de humedad mínima	horas	Hora del día en la que se registró el porcentaje de humedad relativa mínima.
R_MAX_DIR	Dirección del viento en la racha máxima	°	Dirección desde la cual soplaba el viento en la racha máxima registrada en un día.
R_MAX_VEL	Velocidad de la racha máxima del viento	km/h	Velocidad máxima del viento registrada en una racha en un día.
R_MAX_HOR	Hora de la racha máxima	horas	Hora del día en la que se registró la racha máxima del viento.

Tabla 2: Variables meteorológicas recogidas en el proyecto. Fuente: elaboración propia.

En muchos de estos observatorios se recogen datos climáticos de forma ininterrumpida hasta el año 2010, lo que nos ha permitido realizar un análisis de la evolución de las condiciones climáticas, en cuanto a temperatura y precipitación, desde el año 2010 hasta el año 2023.



## 2.4. Información topográfica

Junto a las variables espectrales y meteorológicas ya vistas, hay variables topográficas que pueden influir significativamente en el HCV, como son la altitud, la pendiente y la orientación.

La altitud afecta la temperatura y la presión atmosférica, con una presión atmosférica menor a mayor altitud, lo que influye en la capacidad del aire para retener humedad. Por lo general, a mayor altitud, las temperaturas tienden a ser más bajas, generando condiciones más frescas y húmedas.

La orientación del terreno también es determinante, ya que puede afectar la cantidad de radiación solar recibida y, por lo tanto, las condiciones de humedad. Por ejemplo, las laderas orientadas al norte en el hemisferio norte pueden recibir menos luz solar directa, siendo potencialmente más frescas y húmedas en comparación con las laderas orientadas al sur. La exposición al sol y al viento puede variar según la orientación del terreno, influyendo en las tasas de evaporación y, por lo tanto, en la humedad del suelo y del combustible vivo.

La pendiente del terreno juega un papel crucial al influir en la distribución del agua y en la retención de humedad en el suelo y la vegetación. En terrenos más inclinados, el agua tiende a moverse más rápido, lo que puede resultar en una menor retención de humedad en el suelo y la vegetación, especialmente en áreas montañosas y con vegetación densa, donde una mayor pendiente puede provocar una rápida escorrentía y menor infiltración, reduciendo así la humedad disponible tanto para el suelo como para el combustible vivo.

Los valores de altitud ortométrica de cada parcela de HCV se han obtenido a partir del MDT de 10 metros de resolución de la Comunitat Valenciana, descargado del catálogo de datos de la IDEV. Este MDT fue generado a partir de un vuelo LIDAR de 0,5 puntos por metro cuadrado y publicado en el año 2018. Los valores de orientación y de pendiente se han obtenido de capas ráster derivadas de este MDT.

## 2.5. Pisos bioclimáticos


Los pisos bioclimáticos son divisiones geográficas que se establecen en función de características climáticas, vegetales y otros factores ambientales. Proporcionan una visión integral de la diversidad de ecosistemas dentro de una región, mostrando cómo varían las condiciones ambientales desde las áreas bajas hasta las elevadas.

El piso termomediterráneo, ubicado en áreas bajas y cercanas al mar, se caracteriza por inviernos suaves y veranos cálidos, con temperaturas medias anuales superiores a 16 °C, temperaturas máximas del mes más frío superiores a 13 °C, y temperaturas mínimas del mes más frío superiores a 5 °C. Este piso también tiene una temperatura media del mes más frío superior a -3 °C y la media de las mínimas absolutas del mes más frío superior a 9 °C, siendo los meses de heladas posibles de diciembre a febrero (Costa, 1982). Esta región está dominada por matorrales y arbustos resistentes a la sequía, como el esparto y el lentisco, adaptados al calor y a la humedad moderada.

El piso mesomediterráneo, a altitudes intermedias, presenta inviernos más frescos y veranos templados, con temperaturas medias anuales inferiores a 16 °C, temperaturas máximas del mes más frío inferiores a 13 °C, y temperaturas mínimas del mes más frío inferiores a 5 °C. La temperatura media del mes más frío está entre -3 °C y -5 °C, y la media de las mínimas absolutas del mes más frío es inferior a 9 °C, con heladas posibles de noviembre a abril (Costa, 1982). Aquí, los bosques de encinas se mezclan con matorrales densos de plantas aromáticas como el romero y el tomillo.

A mayor altitud encontramos los pisos supramediterráneo y oromediterráneo, donde los inviernos son fríos y los veranos suaves. Los bosques de pinos y robles son característicos de estos pisos, junto con matorrales adaptados a condiciones frescas y húmedas.

La capa vectorial con la superficie de los pisos bioclimáticos ha sido extraída del Banco de Datos para la Naturaleza, publicado en la página web del Ministerio para la Transición Ecológica y el Reto Demográfico. La distribución de estos pisos en la Comunitat Valenciana se puede observar en el mapa 2.



Mapa 2: Pisos bioclimáticos en la Comunitat Valenciana. Fuente: elaboración propia a partir de datos del Banco de Datos para la Naturaleza.

En este proyecto se han utilizado los pisos bioclimáticos para segmentar los datos y diferenciar geográficamente unas parcelas de otras, generando ecuaciones de predicción de HCV para el piso bioclimático termomediterráneo y el mesomediterráneo.

## 2.6. Modelos de combustible

Un modelo de combustible forestal es una herramienta muy útil para la gestión de incendios forestales que ayuda a predecir y comprender el comportamiento del fuego en áreas boscosas. Estos modelos se centran en la caracterización de los diferentes tipos de combustibles presentes en un ecosistema forestal, como la vegetación, la hojarasca, los troncos caídos y otros materiales inflamables. Según sobre qué tipo de combustible actúa un incendio, como el matorral o el

arbolado, hay grandes variaciones en cuanto a la velocidad de propagación y a la peligrosidad de este.


En el caso de la Comunitat Valenciana, esta cartografía está diseñada por el PATFOR. Este organismo ha clasificado los modelos de combustible en grandes grupos (pastos, matorrales, matorrales debajo de arbolado, restos, etc.), y luego los ha subdividido en clases según las características concretas empleando la clasificación de modelos de combustibles de Scott et al. (2005), que modificaron la clasificación original de Rothermel (1972).

El modelo de Rothermel es uno de los primeros y más influyentes modelos matemáticos para predecir la propagación de incendios forestales, centrándose en el análisis de los combustibles disponibles, las condiciones meteorológicas y la topografía del terreno. La clasificación de Scott et al. amplía la tipología de combustibles proporcionando un marco más detallado para entender cómo diferentes tipos de vegetación y condiciones influyen en los incendios.

La información viene en forma de archivo ráster con una resolución espacial de 10 m. Esta capa, perteneciente a la Dirección General de Prevención de Incendios Forestales, tiene una escala de 1/50.000 y fue publicada en el año 2021.

Al igual que con los pisos bioclimáticos, se ha utilizado esta clasificación de suelos para diferenciar entre parcelas de arbolado (TU) y de matorral (SH), generando ecuaciones para ambos grupos forestales.

La distribución de los distintos modelos de combustible en la Comunitat Valenciana se puede ver en el mapa 3.



Mapa 3: Mapa de Modelos de combustible de la Comunitat Valenciana. Fuente: Dirección General de Prevención de Incendios Forestales. Conselleria de Justícia e Interior - Generalitat Valenciana.



## 2.7. Base de datos de entrenamiento

Junto a los datos de HCV de los años 2022 y 2023 y las variables espectrales, meteorológicas y topográficas ya comentadas, se nos ha proporcionado, por parte del SIGIF, otra base de datos con información de HCV tomada en distintas fechas entre junio de 2020 y noviembre de 2021.

Esta base de datos ha sido utilizada en Arcos et al. (2023). Este artículo, elaborado por miembros del CGAT, propone modelos de regresión lineal para predecir valores de HCV en el área mediterránea, concretamente en la Comunitat Valenciana. Las ecuaciones propuestas por este artículo son las que se han validado en este proyecto utilizando los datos del periodo 2022-2023.

Esta base de datos consiste en un archivo Excel con valores de humedad, y datos climatológicos, espectrales y topográficos de un conjunto de 88 parcelas situadas en la Comunitat Valenciana. Junto a ellos viene la FCC de cada especie inventariada, que indica la porción de superficie de parcela que ocupa dicha especie y otras variables llamadas DOY\_COS y DOY\_SIN, cuyo valor es el seno y el coseno del día del año después de haber sido normalizado para que varíe entre 0 y  $2\pi$  radianes.

Las 88 parcelas están situadas por todo el territorio de la Comunitat Valenciana, en las distintas zonas en las que VAERSA ha realizado los muestreos de HCV, tratando de cubrir parcelas y zonas que puedan ser representativas de la diversidad forestal y climática de la Comunitat Valenciana.

Localización	Provincia	Parcelas	Piso bioclimático
Gilet	Valencia	<b>1, 2, 3, 4, 5</b>	Termomediterraneo
Bétera	Valencia	<b>6, 7, 8, 9</b>	Termomediterraneo
Chelva	Valencia	10, <b>11, 12, 13</b> , 14	Mesomediterraneo
Llombai	Valencia	15, 16, <b>17, 18, 19</b>	Termomediterraneo
Buñol	Valencia	<b>20, 21</b> , 22, 23, <b>24, 25</b>	Mesomediterraneo
Cortes	Valencia	<b>26, 27, 28, 29, 30, 31, 32, 33</b>	Mesomediterraneo
Gandía	Valencia	<b>34, 35, 36</b> , 37, <b>38, 39</b> , 40, <b>41, 42</b>	Termomediterraneo
Montanejos	Castellón	<b>43, 44</b> , 45, <b>46</b> , 47, 48, 49, 50	Mesomediterraneo
Eslida	Castellón	51, 52, 53, 54, 55, 56	Mesomediterraneo
Morella	Castellón	57, 58, 59, 60, 61	Mesomediterraneo
Sant Mateu	Castellón	62, <b>63, 64</b> , 65, 66, 67, <b>68</b>	Mesomediterraneo
Torre Maçanes	Alicante	69, 70, <b>71, 72</b> , 73	Mesomediterraneo
Vall Gallinera	Alicante	<b>74, 75, 76, 77, 78, 79</b>	Termomediterraneo
Biar	Alicante	80, 81, <b>82, 83, 84</b>	Mesomediterraneo
Bernia	Alicante	<b>85, 86, 87, 88</b>	Termomediterraneo

Tabla 3: Parcelas muestreadas en el periodo 2020-2021. Fuente: elaboración propia.

En la tabla 3 quedan marcadas en negrita las parcelas que han sido utilizadas para generar las ecuaciones de entrenamiento.



## 3. Metodología

### 3.1. Descarga y procesamiento espectral

En este apartado se ha trabajado con imágenes de Sentinel-2 para obtener los valores de reflectancia de cada parcela de HCV y calcular con ellos diversos índices espectrales. Todo el trabajo se ha realizado en Python, utilizando librerías de Google Earth Engine como ee y geopandas en el proceso de descarga, mientras que para el procesamiento y el manipulado de los datos espectrales se ha utilizado la librería pandas.

#### 3.1.1. Descarga

El proceso de descarga ha comenzado cargando los puntos de muestreo desde un archivo shapefile, que se ha convertido en un objeto compatible con GEE. Luego, se ha filtrado la colección de imágenes Sentinel-2 para obtener solo aquellas que se encuentran dentro del rango de fechas especificado y que cubren los puntos de muestreo.

Una vez filtrada la colección de imágenes, se han aplicado varias funciones para calcular diferentes índices espectrales. Las funciones de cálculo de índices espectrales se han aplicado secuencialmente a cada imagen de la colección. Los índices espectrales calculados y utilizados en este proyecto se pueden ver en la tabla 4.

Índice	Descripción	Fórmula
ARVI	Atmospherically Resistant Vegetation Index	$(B8 - (2 * B4) + B2) / (B8 + (2 * B4) + B2)$ (3)
VARI	Visible Atmospherically Resistant Index	$(B3 - B4) / (B3 + B4 - B2)$ (4)
TCARI	Transformed Chlorophyll Absorption in Reflectance Index	$3 * ((B5 - B4) / 10000 - 0.2 * ((B5 - B3) / 10000)) * (B5 / B4)$ (5)
OSAVI	Optimized Soil-Adjusted Vegetation Index	$(1 + 0.16) * (B8 - B4) / (B8 + B4 + 1600)$ (6)
TCARI_OSAVI		TCARI / OSAVI (7)
NMDI	Normalized Multi-band Drought Index	$(B8A - (B11 - B12)) / (B8A + (B11 - B12))$ (8)
MSI	Moisture Stress Index	$B11 / B8$ (9)
EVI	Enhanced Vegetation Index	$2.5 * ((B8 - B4) / (B8 + 6 * B4 - 7.5 * B2 + 10000))$ (10)
NDVI	Normalized Difference Vegetation Index	$(B8 - B4) / (B8 + B4)$ (11)
SAVI	Soil-Adjusted Vegetation Index	$((B8 - B4) / (B8 + B4 + 5000)) * 1.5$ (12)
NDWI	Normalized Difference Water Index	$(B8 - B12) / (B8 + B12)$ (13)
Vgreen	Green Vegetation Index	$(B3 - B5) / (B3 + B5)$ (14)
RVI	Ratio Vegetation Index	$B8 / B4$ (15)
MCARI	Modified Chlorophyll Absorption in Reflectance Index	TCARI / 3 (16)
MCARI_OSAVI		MCARI / OSAVI (17)
SLA	Specific Leaf Area	$B8 / (B5 + B12)$ (18)
NDMI	Normalized Difference Moisture Index	$(B8 - B11) / (B8 + B11)$ (19)

Tabla 4: Índices espectrales utilizados en el proyecto. Fuente: elaboración propia.

A continuación, se define una función de reducción que toma cada imagen y la reduce sobre los puntos de muestreo utilizando un reductor de la media. Esta función utiliza el método reduceRegions de GEE, que aplica un cálculo del valor medio de cada índice espectral en cada



punto de muestreo. Además, la función añade la fecha de la imagen a cada entrada de datos para proporcionar un contexto temporal.

Finalmente, los resultados se filtran para asegurar que solo se incluyan aquellas parcelas con valores no nulos en los índices espectrales, y estos datos filtrados se preparan para su descarga. La descarga se ha realizado convirtiendo el resultado a un objeto dataframe de pandas y exportándolo un archivo Excel. En el anexo C se puede ver el script utilizado para realizar el proceso de descarga (`getSpectralData2.py`).

### 3.1.2. Filtrados de datos general


El proceso de filtrado se inicia sobre el campo QA60, que proviene de la colección de imágenes de Sentinel-2 en Google Earth Engine. Esta banda es una máscara de calidad que se utiliza para identificar píxeles afectados por nubes y cirros. Los valores de QA60 están codificados en bits específicos: el bit 10 (valor 1024) indica la presencia de nubes, y el bit 11 (valor 2048) indica la presencia de cirros, por lo que se han filtrado en pandas todas las filas del dataframe que contuviesen un valor distinto de 0 en ese campo.

Sobre este dataframe se ha realizado otro filtrado, esta vez relacionado con el campo SCL (Scene Classification Layer), que clasifica diferentes tipos de cobertura del suelo en cada píxel. En este caso, se han considerado erróneos y han sido eliminadas las filas con valores 3, 8, 9, 10 y 11 en el campo SCL, que se corresponden con los valores de sombras de nubes, probabilidad media de nubes, probabilidad alta de nubes, cirros delgados y hielo o nieve. En cualquiera de estos casos, los valores espectrales obtenidos no nos interesan para el posterior análisis.


Valor	Definición
0	Sin datos
1	Píxel saturado o defectuoso
2	Sombras topográficas proyectadas
3	Sombras de nubes
4	Vegetación
5	No vegetado
6	Agua
7	No clasificado
8	Nube probabilidad media
9	Nube alta probabilidad
10	Cirros delgados
11	Nieve o hielo

Tabla 5: Valores de píxel en la banda SCL. Fuente: European Space Agency.

El siguiente filtrado se ha realizado sobre el campo MSK\_CLDPRB, que representa la probabilidad de nubes. Se ha decidido filtrar las filas donde el valor en esta columna es mayor que 5% de probabilidad de nubes. A tenor de lo visto en los datos, se aprecia que incluso en valores bajos de probabilidad de nubes los valores de los índices espectrales se alejan bastante de los obtenidos en un mismo punto en días anteriores y posteriores, lo que indica que se puede tratar de datos anómalos no filtrados en las anteriores condiciones. Esto se puede ver en las gráficas 1 y 2.



Gráfica 1: Relación entre NDVI y MSK\_CLD en Albaida sin filtrar. Fuente: elaboración propia.



Gráfica 2: Relación entre NDVI y MSK\_CLD en Albaida al filtrar por MSK\_CLD inferior o igual a 0.05. Fuente: elaboración propia.

El último filtrado se ha realizado sobre aquellas filas que contenían píxeles erróneos en las bandas del índice de color verdadero (TCI\_B, TCI\_G y TCI\_R) y en la banda espectral B1. Para el TCI, se eliminaron las filas donde los valores RGB estaban saturados (255, 255, 255) o eran anormalmente bajos (1, 1, 1), ya que estas filas indicaban valores espectrales muy altos o muy bajos que resultaban en índices espectrales anómalos en el análisis posterior. Asimismo, se filtraron las filas de la banda espectral B1 donde los valores eran menores o iguales a 1, que indicaban una reflectancia irregular en esta banda.

Con todos los filtrados en conjunto se ha pretendido asegurar la calidad y precisión de los datos espectrales utilizados en los análisis subsecuentes.

### 3.1.3. Filtrado de *outliers*

El segundo filtrado realizado tiene como objetivo la eliminación de las filas que contengan valores anómalos en la serie temporal de los índices espectrales. El proceso de identificación y eliminación de *outliers* se aplica específicamente a los valores de un índice espectral en concreto dentro de los datos espectrales. En este caso se ha aplicado el filtro sobre la serie temporal del NDVI, pero el filtrado afecta a la serie temporal de todos los índices espectrales, eliminando las fechas con *outliers*.

Para eliminar los valores atípicos, se ha definido una función que utiliza el criterio del rango intercuartílico para identificar y eliminar *outliers*. El rango intercuartílico proporciona una medida de la variabilidad de los datos y se utiliza para identificar valores que están significativamente por encima o por debajo de la mayoría de los valores en el conjunto de datos.


La función recorre una ventana temporal a lo largo de los datos de NDVI de cada parcela y calcula los percentiles 25 (Q1) y 75 (Q3) dentro de la ventana. Luego, determina los límites inferior y superior basados en el IQR y un umbral.

$$IQR = Q3 - Q1 \quad (20)$$


$$\text{Límite Inferior} = Q1 - \text{umbral} \times IQR \quad (21)$$

$$\text{Límite Superior} = Q3 + \text{umbral} \times IQR \quad (22)$$

Si un valor de NDVI está fuera de estos límites, se considera un *outlier* y se reemplaza por NaN. Finalmente, se eliminan las filas con valores NaN. La ventana temporal utilizada ha sido de 5 fechas, es decir, para cada fecha de muestreo y parcela se ha realizado la detección de *outliers* comparando los valores de su NDVI con los de las 2 fechas posteriores y las 2 fechas anteriores y el umbral utilizado tiene un valor de 1,5. La diferencia entre el antes y el después de filtrar los *outliers* se puede ver en las gráficas 3 y 4 que representan los valores de NDVI en la parcela de Sant Mateu. El script utilizado en el filtrado de datos se puede ver en el anexo C (filterOutlier\_v2.py).



Gráfica 3: Evolución del NDVI en Sant Mateu antes de filtrar outliers. Fuente: elaboración propia.



Gráfica 4: Evolución del NDVI en Sant Mateu después de filtrar outliers. Fuente: elaboración propia.

Este enfoque se basa en la metodología presentada por Ji et al. (2010), quienes aplicaron un control de calidad para mejorar la precisión de los datos espectrales mediante la eliminación de valores atípicos utilizando el rango intercuartílico. Esta técnica ha demostrado ser eficaz para la detección y eliminación de outliers en series temporales espectrales, mejorando así la calidad y fiabilidad de los datos.

#### 3.1.4. Interpolación y cálculo de los valores medios de los índices espectrales

Después de los filtrados tenemos un conjunto de datos que recogen los valores espectrales de cada punto en distintos días dependiendo de la estación y de los valores que hayan sido filtrados en esta.

En este proyecto se quiere relacionar los valores de la humedad del combustible vivo con los valores de los índices espectrales pero estos valores no tienen por qué coincidir ya que los días de toma de datos del HCV por parte del VAERSA (parcelas de recogida semanal y parcelas de recogida mensual) no se corresponden en muchos casos con los días de toma de imágenes espectrales en nuestra zona de trabajo por parte de Sentinel-2 (aproximadamente una imagen por cada 5 días). Además, después de los filtrados de datos, contamos con menor número de datos espectrales y la probabilidad de que se tengan datos en un mismo día de HCV e índices espectrales es aún menor.

Por ello se antoja necesario realizar una interpolación entre los valores de cada índice espectral de forma que tengamos datos para todo el periodo de la serie temporal estudiada en este proyecto. Este cálculo se ha realizado mediante la lectura de los datos espectrales y la generación de todas las combinaciones posibles de estaciones y fechas dentro del rango temporal de interés. Posteriormente, se ha aplicado una interpolación lineal a los valores faltantes de los índices espectrales para cada estación, buscando los valores de índices espectrales más cercanos (posterior y anterior) e interpolando un valor entre ellos según la distancia temporal. De esta forma se asegura la continuidad de los datos. El script utilizado para realizar la interpolación se puede ver en el anexo C (interpolate\_data.py).



Finalmente se han calculado los valores medios de los índices espectrales en el periodo de estudio, que funcionan como variables en distintas ecuaciones de predicción de HCV. Este cálculo se ha realizado agrupando los datos por estación y calculando la media de cada índice espectral. Las medias de los índices espectrales, denominadas en el proyecto como el nombre del índice espectral más el sufijo *\_mean*, junto con el resto de los datos han sido almacenados en un Excel para ser introducidos posteriormente en la base de datos del proyecto.

### 3.2. Procesamiento meteorológico

El procesamiento meteorológico ha consistido en interpolar sobre un archivo ráster los datos meteorológicos puntuales que nos había proporcionado la AEMET. Sobre esos archivos ráster, que representan distintas variables climatológicas, se han extraído los valores diarios de cada punto de muestreo y se ha calculado la precipitación acumulada y la temperatura media acumulada en distintos conjuntos de días.

Todo el proceso se ha realizado en Python, salvo una pequeña parte que se ha realizado en QGIS. Se han utilizado librerías del lenguaje estadístico R y librerías para tratar datos geoespaciales como gdal para interpolar y generar los archivos ráster, y la librería pandas para calcular las variables acumulativas y manipular los datos.

Este proceso se ha realizado para los datos meteorológicos comprendidos entre noviembre de 2021 y diciembre de 2023, con el objetivo de poder tener datos para calcular variables acumulativas en los primeros días de 2022.

#### 3.2.1. Interpolación y generación de mapas ráster meteorológicos


Este proceso se ha realizado con la ayuda del SIGIF, que nos ha proporcionado un script elaborado por ellos para obtener valores meteorológicos interpolados en la Comunitat Valenciana. Estos datos se emplean posteriormente para generar modelos de predicción del HCV y de riesgo de incendio.

Este script funciona de la siguiente manera:

- En primer lugar, junta los ficheros meteorológicos de temperatura precipitación, humedad y viento en un solo archivo y filtra las fechas para mantener únicamente al periodo temporal del cual se quiere obtener los modelos meteorológicos. En este proyecto se ha ejecutado el código mes a mes, por lo que en cada ejecución se han filtrado los datos pertenecientes a unos 30 días.
- En segundo lugar, utiliza este fichero meteorológico y las capas ráster de altitud, pendiente y orientación para interpolar los valores meteorológicos utilizando la librería *meteoland* de R y sacar modelos ráster de cada una de las variables. Antes de realizar dicha interpolación se divide la superficie de la Comunitat Valenciana en cierto número de cuadrantes para que no colapse el script en la interpolación debido al elevado número de datos.
- Finalmente se unen los todos los ráster de un mismo día y misma variable en un solo mosaico que abarca toda la superficie de la Comunitat Valenciana.

En total, se obtienen 11 ráster (uno por variable) por cada día del periodo temporal asignado. Las variables meteorológicas obtenidas son MaxRelativeHumidity, MinRelativeHumidity, MeanRelativeHumidity, MaxTemperature, MinTemperature, MeanTemperature, PET (Evapotranspiración Potencial), Precipitation, Radiation, WindSpeed y WindDirection. Las variables más importantes son la temperatura media y la precipitación, sobre las cuales se calculan valores acumulados en cierto número de días.

De todas ellas, las variables más importantes son las de temperatura media y precipitación, sobre las que se han calculado valores acumulados en cierto número de días. En el mapa 4 se puede ver el ráster de precipitación para el día 5 de febrero de 2022.



Mapa 4: Precipitación en la Comunitat Valenciana durante el día 05/02/2022. Fuente: elaboración propia.

### 3.2.2. Extracción de valores meteorológicos

Después de obtener los modelos meteorológicos diarios en formato TIF, se ha calculado el valor ráster de cada parcela de HCV utilizando la herramienta *Point Sampling Tool* en QGIS. Se ha ejecutado esta herramienta un total de 11 veces, 1 por cada variable meteorológica calculada, con lo que se ha obtenido una tabla distinta por variable que relaciona los valores extraídos por cada punto de muestreo y día distintos.

En la tabla obtenida se almacenan los valores de cada fecha en columnas, mientras que en la tabla de datos espectrales que hemos generado se almacenan las fechas en fila. Para corregir esto se ha formateado el dataframe para colocar las fechas en una columna junto al nombre de las parcelas, de forma que para cada estación y fecha se obtenga un solo valor de cada variable.

### 3.2.3. Cálculo de variables acumuladas

Además de las 11 variables meteorológicas obtenidas se ha decidido calcular otras variables de precipitación acumulada y temperatura media acumulada en cierto periodo de tiempo. La razón



de añadir estas variables es que ya se utilizaron en los modelos de regresión lineal de HCV para el periodo 2020-2021 que se quieren validar en este trabajo.

Utilizar variables acumuladas, como la precipitación acumulada en los 60 días anteriores y la temperatura media durante ese periodo, es útil porque proporciona una visión más completa y precisa del estado del HCV. La precipitación de un solo día puede no reflejar adecuadamente las condiciones de humedad del suelo y de las plantas, ya que estas dependen de la historia reciente de las condiciones climáticas. El HCV se ajusta lentamente a los cambios en el clima, y un solo evento de precipitación puede no ser suficiente para revertir un período prolongado de sequía o, al contrario, un breve período seco puede no secar completamente un terreno que ha estado húmedo durante semanas. Al considerar las variables acumuladas, se obtiene una medida que refleja mejor el balance hídrico y las condiciones de evaporación y transpiración que afectan la humedad del combustible.

Se ha calculado la precipitación y temperatura acumulada para los 3, 7, 15, 30 y 60 días anteriores para cada estación meteorológica y día. En este número de días anteriores también se cuenta la precipitación del propio día, de forma que la variable acumulada p60 se calcula realizando el sumatorio de la precipitación recogida a la largo de ese día y de los 59 anteriores.


Este cálculo se ha realizado con otro script de Python, que se puede ver el anexo C (calculate\_t60.py). Este script de Python utiliza la librería pandas para calcular la temperatura media acumulada y la precipitación acumulada en diferentes intervalos de tiempo a partir del archivo Excel con los datos de temperatura y precipitación diaria por estación. Sobre cada uno de estos intervalos de tiempo, el script almacena en una columna distinta la temperatura media acumulada o la precipitación acumulada.

Este código también asigna valores nulos a los primeros días de cada lugar en la columna calculada, es decir, para la variable p60 se dejan a nulos los primeros 60 registros de cada estación, ya que consideramos que el dato va a ser erróneo porque no puede hacer el cálculo completo de los 60 días debido a la falta de datos de días anteriores.

### 3.3. Procesamiento topográfico

La altitud ortométrica de cada parcela de HCV se ha obtenido a partir del MDT de 10 metros de resolución de la Comunitat Valenciana, descargado del portal de descargas de la IDEV. A partir de este MDT se han obtenido las capas ráster de pendiente y orientación mediante las herramientas de GDAL *slope* y *aspect* respectivamente. Tanto la pendiente (mapa 5) como la orientación han sido calculadas en grados, ya que las ecuaciones de predicción de HCV utilizadas empleaban coeficientes adaptados a la pendiente y la orientación en grados.

Una vez obtenidos los 3 ráster con información topográfica se ha utilizado la herramienta *Point Sampling Tool* en QGis para extraer los valores de estas 3 variables en cada uno de los puntos de muestreo.



Mapa 5: Mapa de pendiente de la Comunitat Valenciana. Fuente: elaboración propia.

### 3.4. Clasificación de parcelas por piso y combustible

En el presente apartado, se detalla el procedimiento seguido para la clasificación de las parcelas en función del piso bioclimático y el modelo de combustible, un proceso crucial para la caracterizar ambientalmente cada una de las estaciones de muestreo. La clasificación de cada parcela en el piso bioclimático y el modelo de combustible también se ha realizado empleando la herramienta *Point Sampling Tool*, extrayendo el valor de cada punto de muestreo sobre las 2 capas.

La mayoría de los puntos de muestreo están situados en el piso bioclimático mesomediterráneo, que se ha denominado también *G2* en este proyecto. El resto de los puntos están situados entre el piso bioclimático termomediterráneo, denominado *G1* en este proyecto, y el piso bioclimático supramediterráneo, situado en la zona noroccidental de la Comunitat Valenciana.



La clasificación de modelos de combustible es más compleja, puesto que hay 5 categorías y diversas subcategorías, según la altura y la densidad de la vegetación. Las categorías son pasto (GR), matorral (SH), matorral debajo de arbolado (TU), matorral y restos leñosos junto con arbolado adulto (SB) y modelos incombustibles (NB), aunque este proyecto se ha centrado en sacar ecuaciones para los modelos de SH y TU. La mayoría de las parcelas están clasificadas como parcelas de matorral, aunque también hay un número elevado de parcelas de matorral debajo de arbolado.

Casi todas las parcelas están clasificadas entre los modelos de matorral y arbolado salvo 3 casos. Se ha observado que algunas parcelas como 36\_Gandia Umbria, Segorbe (Tristan) y Castielfabib están situadas sobre otros modelos de combustible distintos a SH o TU. La parcela de Gandía estaba situada sobre un píxel de modelo incombustible, mientras que las de Segorbe y Castielfabib están dentro del modelo de pasto. Sin embargo, están situadas muy cerca de píxeles con modelos de combustible de SH o TU, por lo que han sido reclasificadas de forma manual, sabiendo que tienen arbolado y matorral y no pueden entrar en modelos de pasto o modelos incombustibles.

La situación de cada una de las parcelas después de extraer los modelos de combustible y piso bioclimático se puede ver en la tabla 6. La columna piso indica a que categoría pertenece cada parcela, según sea su piso bioclimático, G1 o G2, y su modelo de combustible, S o T. La columna cod\_UPV es un código interno de identificación de puntos de muestreo. Las parcelas con un número inferior a 88 indica que han sido tomadas también en el periodo 2020-2021, y el resto de las parcelas solo han sido tomadas en el periodo 2022-2023. Las parcelas con el código 91, 92, 93 y 107 han sido tomadas de forma semanal.



Nombre	PISO	cod_UPV
Bétera	G1S	7
Chelva Remedio	G2S	12
13_Chelva Granzas	G2S	13
Muela de Cortes	G2T	26
33_Cortes Aljibe	G2S	33
36_Gandia Umbria	G1T	36
Gandia_Parpalló	G1S	40
Montanejos	G2T	43
53_Eslida	G2S	53
63_Sant Mateu	G2S	63
72_Torre Maçanes (Deposito)	G2S	72
77_Villalonga	G2S	77
Biar	G2T	84
85_Altea-Jalón (Bernia Umbria)	G2T	85
87_Altea-Jalón (Bernia Solana)	G2S	87
Requena_semanal	G2S	91
Buñol_semanal	G2S	92
Llombai_semanal	G2S	93
Villargordo	G2T	107
Torre maçanes 2022	G2T	113
Morella	G2S	118
Chovar	G2S	120
Desert Palmes	G1T	121
Ares del Maestrat	G2S	130
Catí	G2S	131
Segorbe (tristan)	G2S	135
Chelva (Nieva)	G2S	137
Gestalgar	G2S	138
Yatova	G2S	139
Dos Aguas	G2S	140
Ayora (La Hunde)	G2T	141
Tous	G2S	142
Enguera	G2T	143
Albaida	G2S	144
Gilet	G1S	305
Altura 2	G2S	311
Llombai Mensual Pinar	G2S	312

Tabla 6: Información de las parcelas. Fuente: elaboración propia.



### 3.5. Obtención de fórmulas de HCV

Las fórmulas de HCV originales utilizadas en este proyecto han sido obtenidas del artículo *Analyzing Independent LFMC Empirical Models in the Mid-Mediterranean Region of Spain Attending to Vegetation Types and Bioclimatic Zones*<sup>2</sup> (Arcos et al. 2023).

Este artículo se enfoca en crear modelos para predecir la humedad del combustible vivo (LFMC por sus siglas en inglés) en una región mediterránea. Utilizando la técnica de regresión lineal múltiple paso a paso, los investigadores desarrollaron estos modelos basándose en datos de HCV recogidos en 88 parcelas de campo entre junio de 2020 y noviembre de 2021.

En ese proyecto se utilizan diversas variables para estimar el contenido de HCV. Las variables incluyen índices espectrales derivados de imágenes del satélite Sentinel-2, con una resolución espacial de 10 metros. Además, se consideran variables meteorológicas, que son interpoladas a partir de datos disponibles, y variables topográficas que describen las características del terreno. Estas variables permiten desarrollar modelos empíricos que reflejan con precisión las variaciones espaciales y temporales del HCV en diferentes bioclimas y tipos de vegetación.

Algunas de las parcelas incluidas en este artículo también se incluyen entre los datos de campo de este proyecto, puesto que el proveedor de la información es el mismo, VAERSA.

En el artículo se calculan 4 ecuaciones distintas, adaptadas a diferentes especies, pisos bioclimáticos y modelos de combustible. Los nombres de las ecuaciones están compuestos por la especie sobre la que actúa, en este caso mp (media ponderada de todas las especies), y los distintos pisos bioclimáticos y modelos de combustible. Como ya se ha comentado, el piso termomediterráneo se ha denominado G1 y el piso mesomediterráneo como G2, mientras que el modelo de combustible de matorral se ha registrado como S (*shrub*) y el de arbolado como T (*tree*).

Las variables utilizadas en cada ecuación siguen la siguiente notación:

- Los índices espectrales vienen recogidos como el nombre del índice espectral más la resolución espacial (por ejemplo, NMDI\_10mS).
- Las medias de los índices espectrales vienen recogidas con el prefijo *Mean\_* más el nombre y la resolución del índice espectral.
- La precipitación y la temperatura media acumulada en los últimos 60 días en el punto de muestreo vienen denominadas como p60 y t60 respectivamente.
- Las variables topográficas vienen recogidas como *slope* (pendiente), *orientation* (orientación) y *altitude* (altitud en m.s.n.m.).

---

<sup>2</sup> <https://www.mdpi.com/1999-4907/14/7/1299>



Estas 4 ecuaciones, junto con las características de las parcelas sobre las que actúan se pueden ver en la tabla 7.

Nombre	Características	Ecuación
mp_G1S	Media ponderada, piso termomediterraneo y modelo de matorral.	$117,811+86,144*NMDI_{10mS}-298,158*Mean\_EVI_{10mS}+110,124*Mean\_VARI_{10mS}-11,211*DOY\_SIN+0,078*p60+0,033*altitude$ (23)
mp_G1T	Media ponderada, piso termomediterraneo y modelo de arbolado.	$131,693+0,033*p60-3,154*slope-80,528*Mean\_MSI_{10mS}+2543,23*Mean\_TCARI_{10mS}$ (24)
mp_G2S	Media ponderada, piso mesomediterraneo y modelo de matorral.	$28,888+144,968*NMDI_{10mS}+8,987*DOY\_COS+0,052*p60-0,641*t60-0,803*slope$ (25)
mp_G2T	Media ponderada, piso mesomediterraneo y modelo de arbolado.	$156,17-5,91*DOY\_SIN+0,06*p60-867,76*Mean\_TCARI_{10mS}+43,07*EVI_{10mS}$ (26)

Tabla 7: Ecuaciones originales de HCV. Fuente: Arcos et al. (2023)

### 3.5.1. Variaciones sobre las ecuaciones originales

Los nuevos modelos de predicción de HCV se han entrenado utilizando los datos meteorológicos y espectrales que hemos calculado para las 88 parcelas durante las fechas del periodo de entrenamiento, que comprende de junio de 2020 a noviembre de 2021. En varias ecuaciones se ha ampliado este conjunto de parcelas, añadiendo también puntos de muestreo en los que se han recogido datos de HCV para el periodo 2022-2023.

En la base de datos de 2020-2021, los valores de precipitación acumulada fueron calculados por interpolación puntual solo en el sitio, mientras que en el código utilizado en el procesamiento meteorológico los datos de precipitación están calculados a nivel ráster en toda la Comunitat Valenciana, con un tamaño de píxel de 500 x 500 m. Para obtener el valor de la precipitación en el punto de muestreo simplemente se ha extraído el valor del píxel sobre el que está situada la estación. De estos datos meteorológicos se han extraído las variables *new\_t60* y *new\_p60*, que hacen referencia a la temperatura media y a la precipitación acumulada de los últimos 60 días. Se utiliza el prefijo *new\_* para denotar que estas variables han sido calculadas empleando este nuevo método de interpolación ráster para toda la Comunitat Valenciana.


Para no provocar distorsiones en el resultado de las ecuaciones de predicción, se han generado también los ráster de precipitación a nivel de píxel del periodo 2020-2021 y se han recalculado los coeficientes de la nueva ecuación empleando esta nueva variable.

Durante la realización del proyecto se ha propuesto realizar algunas mejoras en las ecuaciones para adaptarlas a los condicionantes climatológicos de los años 2022 y 2023, que fueron distintos de los observados en el periodo 2020-2021, en los que fueron tomados los datos de entrenamiento de estas ecuaciones.

En concreto, una de las diferencias se observa en las precipitaciones. El año 2022 tuvo una serie de precipitaciones extraordinarias durante la segunda mitad del mes de marzo, llegando a ser *el mes que más precipitación acumulada ha registrado en toda la serie histórica, superando a octubre de 2000 y octubre de 1957* según la AEMET<sup>3</sup>. En las zonas en las que más agua se recogió

<sup>3</sup>AVANCE CLIMATOLÓGICO DE MARZO DE 2022 EN LA COMUNITAT VALENCIANA  
[https://repositorio.aemet.es/bitstream/20.500.11765/13546/1/ACM\\_VAL\\_202203.pdf](https://repositorio.aemet.es/bitstream/20.500.11765/13546/1/ACM_VAL_202203.pdf)

fue en la parte sur de la provincia de Valencia y en la parte norte de Alicante, aunque los valores de precipitación fueron muy elevados en todo el conjunto de la comunidad autónoma.



Mapa 6: Precipitación acumulada registrada en la Comunitat Valenciana durante marzo de 2022. Fuente: AEMET.

Los eventos extremos de precipitación, como los observados en la Comunitat Valenciana durante marzo de 2022, están cada vez más asociados al cambio climático. Este fenómeno está intensificando tanto la frecuencia como la severidad de tales eventos, lo que se traduce en un incremento de las lluvias intensas y en episodios más prolongados de precipitación. Investigaciones recientes, como las de Clarke et al. (2022) han demostrado que el cambio climático está aumentando la probabilidad y la intensidad de estos eventos extremos debido al calentamiento global, que altera los patrones de circulación atmosférica y aumenta la capacidad de la atmósfera para retener vapor de agua.

Estos eventos extremos afectan a la predicción del HCV. En las ecuaciones originales aparece la variable  $p_{60}$ , que hace referencia a la precipitación acumulada en los últimos 60 días. Durante los meses de abril y mayo de 2022, cuando el  $p_{60}$  es muy elevado, los valores previstos de HCV son, en general, bastante más elevados de lo que indican las observaciones de campo. Para suavizar el efecto del  $p_{60}$  en las ecuaciones se ha propuesto la utilización del logaritmo neperiano de  $p_{60}$  en lugar de utilizar  $p_{60}$  solamente.

La utilización del logaritmo neperiano permite manejar de manera más efectiva estos días de precipitación extrema, ya que suaviza las fluctuaciones abruptas en la magnitud de la precipitación, evitando así valores excesivamente altos de humedad que podrían distorsionar los resultados.

El cálculo de las nuevas ecuaciones se ha realizado en *Statgraphics*. En primer lugar, se ha utilizado la herramienta *Selección de modelos de regresión* para ver que variables aportan más



información según cada caso y eliminar aquellas que son linealmente dependientes e introducen redundancia en el modelo.

Una vez seleccionadas las variables a utilizar se ha utilizado la herramienta *Modelos Lineales Generales* para calcular los coeficientes de la ecuación, colocando las variables en el apartado factores cuantitativos. Esta herramienta también proporciona el VIF de cada una de las variables, lo que vuelve a proporcionar información sobre la multicolinealidad de las variables que nos puede ayudar a seleccionar mejor las variables a utilizar.

#### 3.5.1.1. Ecuación para el piso G1S

El modelo del piso G1S tiene la siguiente ecuación:

$$HCV = 128,678 - 10,2433 * DOY\_SIN + 0,0448845 * altitude - 4,53473 * \cos(orientation) - 30,425 * MSI\_10mS + 6,21036 * \ln(1 + new\_p60) - 152,49 * Mean\_EVI\_10mS \quad (27)$$

Esta ecuación ha sido entrenada utilizando las mismas parcelas que la ecuación original más la parcela de 40\_Gandia, pero incluyendo también información de la parcela de Bétera, perteneciente al periodo 2022-2023. La ecuación está compuesta mayoritariamente por datos del periodo 2020-2021, pero también se han incorporado datos obtenidos en los años 2022 y 2023, con lo que se espera que aumente la robustez de la ecuación y mejore su comportamiento al validar con el conjunto de puntos de muestreo actuales.

#### 3.5.1.2. Ecuación para el piso G1T

La ecuación del piso G1T es la siguiente:

$$HCV = 87,3568 - 0,488693 * slope - 0,0601177 * altitude - 16,4042 * aspect - 28,6042 * \sin(orientation) + 96,594 * EVI\_10mS + 22,0865 * ARVI\_10mS + 3,92681 * \ln(1 + new\_p60) \quad (28)$$

donde la variable *aspect* se ha calculado como:  $(1 + \cos(orientation))/2$ .

La nueva ecuación ha sido entrenada utilizando los mismos puntos de muestreo de HCV que se utilizaron en la ecuación original más los datos de la parcela Desert Palmes, recogidos entre los años 2022 y 2023. Como en el caso anterior, la ecuación está compuesta mayoritariamente por datos del periodo 2020-2021 aunque también se ha añadido dicha parcela con datos más actuales para mejorar el comportamiento de la ecuación y disminuir su error.

#### 3.5.1.3. Ecuación para el piso G2S

La ecuación del piso G2S es la siguiente:

$$HCV = 20,0531 + 119,057 * NMDI\_10mS + 7,94279 * DOY\_COS + 6,11955 * \ln(1 + new\_p60) - 0,878241 * new\_t60 \quad (29)$$

Esta ecuación se ha entrenado de una forma distinta, utilizando solo datos del periodo 2020-2021. Además, algunas de las 88 parcelas que no habían sido incluidas originalmente han sido introducidas o reclasificadas junto con el resto de las parcelas según su piso bioclimático y modelo de combustible. Las parcelas reclasificadas son las siguientes:

- Eslida\_53 se introduce en G2S
- Villalonga\_77 pasa de G1S a G2S
- Altea\_87 pasa de G1S a G2S



Con ello, se quiere observar la influencia que tiene sobre el conjunto de datos el mover de un piso o modelo de combustible a otro a ciertas parcelas situadas en la zona limítrofe, y como puede afectar espacialmente a las parcelas cercanas el hecho de reclasificar una parcela.

#### 3.5.1.4. Ecuación para el piso G2T

La ecuación del piso G2T es la siguiente:

$$\begin{aligned} HCV &= 52,0635 - 1,04213 * slope - 4,41021 * \sin(orientation) + 118,755 * EVI_{10mS} \\ &- 60,7983 * NDMI_{10mS} + 22,1043 * SLA_{10mS} + 1,73302 \\ &* \ln(1 + new\_p60) \end{aligned} \quad (30)$$

Este modelo se ha entrenado utilizando las parcelas que ya se empleaban en las ecuaciones originales añadiendo la parcela de 85\_Altea, pero también se han introducido parcelas nuevas como Biar, Muela de Cortes o Montanejos entre otras, todas ellas con datos pertenecientes al periodo 2022-2023.

#### 3.5.1.5. Ecuación para Gandía

El modelo de predicción de HCV para Gandía es el siguiente:

$$\begin{aligned} HCV &= 128,837 - 5,8311 * DOY_{SIN} - 1,19134 * slope - 0,124102 * altitude \\ &+ 8,58406 * \sin(orientation) + 68,787 * NDMI_{10mS} + 3,69525 \\ &* \ln(1 + new\_p60) \end{aligned} \quad (31)$$

Esta ecuación esta entrenada utilizando únicamente las parcelas situadas en Gandía, tanto las que están en el grupo de 88 parcelas como las nuevas, que se reducen a la parcela 36\_Gandia Umbría y Gandía Parpalló. A diferencia de las otras ecuaciones vistas hasta ahora, en este modelo no se ha diferenciado por modelo de combustible, uniendo tanto arbolado como matorral en una misma ecuación. Esto se ha realizado con el objetivo de comparar los resultados obtenidos con los modelos de los pisos G1S y G1T, con un modelo calculado con datos más cercanos con unas características climáticas específicas.

#### 3.5.1.6. Ecuación para matorral en Gandía

La ecuación de este modelo es la siguiente:

$$\begin{aligned} HCV &= 91,8732 - 7,41776 * DOY_{SIN} - 0,0712757 * altitude - 13,3054 * aspect \\ &+ 40,0582 * EVI_{10mS} + 6,98047 \\ &* \ln(new\_p60) \end{aligned} \quad (32)$$

Esta ecuación esta entrenada también con puntos de muestreo de Gandía, pero solo aquellos que están catalogados como matorral. De las parcelas actuales, la única parcela que ha sido utilizada en este modelo es la parcela de Gandía Parpalló.

#### 3.5.1.7. Ecuación para Yátova-Dos Aguas

La ecuación obtenida después de entrenar el modelo es la siguiente:

$$\begin{aligned} HCV &= 15,554 - 12,605 * DOY_{SIN} + 0,854792 * new\_t30 - 1,18921 * slope + 7,77372 \\ &* \sin(orientation) + 91,4459 * NDMI_{10mS} + 46,981 * ARVI_{10mS} + 2,92955 \\ &* \ln(new\_p60) \end{aligned} \quad (33)$$

Las parcelas que se han utilizado para entrenar el modelo son aquellas situadas en Chelva, Cortes y Buñol, que mayoritariamente contienen datos pertenecientes al periodo 2020-2021. Además, también se han introducido los datos de la parcela de Yátova, que pertenecen al periodo más



reciente. Para la realización de este modelo solo se han utilizado datos provenientes de parcelas de matorral, ya que los puntos de muestreo de Yatova y Dos Aguas pertenecen a ese modelo de combustible. Al igual que en el caso de Gandía se busca calcular un modelo más local con datos de varias localizaciones próximas.

### 3.6. Generación de mapas ráster de HCV

Los mapas en formato ráster del HCV predicho por las ecuaciones se ha realizado empleando diversos scripts del SIGIF, al igual que en el apartado donde se generaban los mapas ráster de variables meteorológicas.

En primer lugar, se debe definir la fecha para la que se quiere realizar la estimación de HCV. Después, este script utiliza la conexión a Google Earth Engine para generar un archivo ráster de cada índice espectral en la fecha más cercana a la fecha definida.

Para los datos meteorológicos, el script utiliza R y los datos de la AEMET para generar mapas de precipitación y temperatura media para la fecha definida y los 59 días anteriores. Una vez tiene todos los ráster descargados los une en un ráster para precipitación acumulada y otro para temperatura media acumulada. Este paso se realiza porque las variables meteorológicas utilizadas tanto en las ecuaciones originales como en las nuevas son variables acumulativas como p60 y t60.

Las variables topográficas como la orientación ya están descargadas de forma local y no es necesario generarlas en cada ejecución, mientras que otras variables como DOY\_SIN se definen al introducir la fecha deseada.

Una vez se tienen todos los ráster descargados, se ha generado un ráster sin información con una resolución espacial del píxel de 100m, que se considera correcta para realizar este proyecto. Después, se ha utilizado la capa vectorial de pisos bioclimáticos y la capa ráster de modelos de combustible para clasificar cada píxel en cada grupo (G1S, G1T, G2S, G2T) o desecharlo y dejarlo a 0. Sobre cada píxel se calcula finalmente la ecuación de su grupo y se le da un valor de HCV estimado utilizando comandos de gdal. Finalmente se exporta a formato TIF y ya se puede trabajar con la capa en cualquier software SIG.

## 4. Resultados


### 4.1. Análisis meteorológico

Debido a las diferencias observadas en los errores según la situación de la situación del punto de muestreo, se ha decidido estudiar las condiciones climatológicas de distintos observatorios de la Comunitat Valenciana durante los años de estudio y años anteriores. Para ello se ha decidido trabajar sobre 4 estaciones: 2 situadas en la provincia de Valencia (Barx y Bétera), una situada en la provincia de Castellón (Sant Mateu) y otra en la provincia de Alicante (Beneixama).

Entre otras cosas, se pretende observar si los años de validación y de entrenamiento han tenido condiciones climáticas muy distintas que puedan haber afectado a los resultados. Como los modelos de predicción utilizan la temperatura media y la precipitación como variables meteorológicas, son estos datos los que se han estudiado.

#### 4.1.1. Análisis pluviométrico 2010-2023

En primer lugar, se ha estudiado la precipitación, que es una parte muy importante de la ecuación de predicción de HCV con la variable p60, que hace referencia a la precipitación recogida en los 60 días anteriores.



Gráfica 5: Precipitación anual según observatorio. Fuente: elaboración propia.

De las 4 estaciones estudiadas, la que más precipitaciones recoge anualmente es la de Barx, que destaca sobre todas las demás con una media de 982 l/m<sup>2</sup> por año. En esta estación se registran las mayores precipitaciones en todos los años salvo en 2014 y 2015, que es superada por Sant Mateu. Es este observatorio precisamente, el segundo de los cuatro que más agua recoge anualmente, con una media de 606 l/m<sup>2</sup> para el periodo 2010-2023. Las estaciones en que menos agua se recoge son las de Beneixama, con una media de 402 l/m<sup>2</sup>, y Bétera, con una media de 403 l/m<sup>2</sup>. Con estos datos se puede ver como en Barx se recoge más del doble de agua que en Bétera, estando ambas estaciones dentro del mismo piso bioclimático, lo que indica que incluso dentro de esta clasificación podemos encontrar puntos con características climatológicas muy distintas.



Los valores de precipitación han ido fluctuando con el paso de los años de distinta forma según la situación de la estación. En la estación de Sant Mateu se observa un volumen relativamente constante de precipitaciones entre 2010 y 2015, sin embargo, a partir de este año se entra una fase de gran variabilidad pluviométrica, alternando años especialmente secos, como 2017 y 2019, con años muy húmedos, como el 2020 donde se registraron 1023 l/m<sup>2</sup>.

A diferencia de Sant Mateu, Barx presenta una gran variabilidad en todo el periodo 2010-2023, con años lluviosos como 2012 y 2016, y años más secos como 2014. Sin embargo, en el periodo 2018-2022, Barx encadena de forma consecutiva 5 años con un gran volumen de precipitaciones. Los años comprendidos entre 2018 y 2022 son los años más húmedos de entre todo el periodo estudiado, especialmente el 2022, donde se alcanzan los 1772 l/m<sup>2</sup>. El año 2023 resulta ser mucho más seco, no llegando a los 600 l/m<sup>2</sup>.

Las estaciones de Beneixama y Bétera presentan menor variabilidad interanual, especialmente la de Bétera, en la que durante el periodo 2010-2015 la precipitación se mantiene estable a lo largo de los años. A partir de ese año se registran algunos picos de precipitación como en el año 2018, donde se superan los 600 l/m<sup>2</sup>, llegando a un valor mínimo de 281 l/m<sup>2</sup> en el año 2023. La estación de Beneixama también presenta un comportamiento parecido, marcando máximos de precipitación en los años 2020 y 2022 y registrando una bajada de las precipitaciones en el año 2023.


Atendiendo a lo observado en las 4 estaciones, no se percibe un aumento o una disminución significativa de las precipitaciones según avanzan los años, pero sí que se observa un aumento en la variabilidad de la precipitación con respecto a los valores de años siguientes. Las razones de este hecho pueden ser muy distintas.

El cambio climático, impulsado por el aumento de gases de efecto invernadero, puede haber alterado significativamente los patrones de precipitación global. Un artículo de Pendergrass et al. (2017) indica que la variabilidad de la precipitación aumenta en un clima más cálido. Este estudio sugiere que a medida que las temperaturas globales aumentan, la capacidad de la atmósfera para retener humedad también aumenta, lo que lleva a eventos de precipitación más intensos y una mayor variabilidad interanual.


Un estudio de Giorgi et al. (2008) analiza cómo el cambio climático podría afectar los patrones de precipitación en la región del Mediterráneo, con un enfoque en fenómenos atmosféricos como la Oscilación del Atlántico Norte (NAO) y El Niño-Oscilación del Sur (ENSO). El estudio señala que el cambio climático podría intensificar la variabilidad de la precipitación en la región mediterránea, provocando un aumento en la frecuencia y la intensidad de los eventos de precipitación extrema. Esta intensificación está vinculada a los cambios proyectados en los patrones de circulación atmosférica asociados con la NAO y ENSO, que desempeñan un papel crucial en la distribución espacial y temporal de las precipitaciones en el Mediterráneo.

El fenómeno de El Niño se refiere a un calentamiento anormal de las aguas del océano Pacífico ecuatorial, lo que altera los patrones climáticos globales y puede provocar cambios en la distribución de las precipitaciones en diferentes regiones del mundo, mientras que la NAO es un fenómeno de variabilidad climática que se refiere a las fluctuaciones en la diferencia de presión atmosférica entre la región subtropical del Atlántico Norte y la región subpolar.


La topografía local y la presencia de microclimas también pueden causar variaciones significativas en la precipitación; por ejemplo, las montañas pueden crear sombras de lluvia y las zonas costeras pueden recibir más lluvia debido a la humedad del mar.




Gráfica 6: Precipitación por meses en Sant Mateu según periodo. Fuente: elaboración propia.



Gráfica 7: Precipitación por meses en Barx según periodo. Fuente: elaboración propia.



Gráfica 8: Precipitación por meses en Bétera según periodo. Fuente: elaboración propia.



Gráfica 9: Precipitación por meses en Beneixama según periodo. Fuente: elaboración propia.

Las 4 estaciones muestran una evolución pluviométrica similar a lo largo de los años en los que disponemos de datos meteorológicos.


En los meses de invierno las precipitaciones han ido aumentando de forma general hasta el periodo 2018-2020, pero disminuyeron notablemente en 2021-2023. En los meses de primavera, las precipitaciones han sido relativamente estables, con un aumento considerable

en 2021-2023, especialmente en el mes de marzo (salvo en la estación de Sant Mateu). Durante el verano, las precipitaciones han sido bajas en general, aunque en el periodo 2021-2023 se produce un ligero aumento en las precipitaciones respecto a los 3 periodos anteriores. Entre los meses de otoño, septiembre muestra un aumento en la pluviometría en el periodo 2021-2023 respecto a los anteriores, mientras que en octubre y noviembre las lluvias tienden a disminuir en el periodo actual respecto a los periodos de 2014-2017 y 2018-2020, indicando que los episodios de gota fría (en los que se recogen gran cantidad de precipitaciones en un corto periodo de tiempo) que tienen lugar durante el otoño tienden a adelantarse en los últimos años. El mes de diciembre también muestra un patrón similar de menos precipitaciones.


En general, el patrón pluviométrico muestra que las precipitaciones se concentran principalmente en los meses de primavera (especialmente marzo) y los meses de otoño (donde destacan septiembre y noviembre). Por otro lado, los meses con menos precipitaciones son los meses del verano y los del invierno a excepción de enero, donde se registraron notables precipitaciones en el periodo 2018-2020.

#### 4.1.2. Análisis pluviométrico 2020-2023


En este apartado se ha analizado, de forma general, las diferencias en cuanto al patrón de precipitaciones *observado* durante los últimos 4 años, que son los que han servido para entrenar y validar los modelos de predicción.




Gráfica 10: Precipitación por meses en Sant Mateu según año. Fuente: elaboración propia.



Gráfica 11: Precipitación por meses en Barx según año. Fuente: elaboración propia.



Gráfica 12: Precipitación por meses en Bétera según año. Fuente: elaboración propia.



Gráfica 13: Precipitación por meses en Beneixama según año. Fuente: elaboración propia.

En el periodo 2020-2023 se ha registrado, en general, una notable variabilidad pluviométrica, alternando periodos muy secos con otros bastante húmedos.

El año 2020 fue un año húmedo, especialmente en la estación de Sant Mateu, mientras que en el año 2021 se registraron menores precipitaciones en todas las estaciones salvo la de Barx. El año 2022 ha sido un año especialmente lluvioso, siendo el más lluvioso del periodo 2020-2023 en todas las estaciones menos la de Sant Mateu. Sin embargo, el año 2023 ha sido un año muy seco, registrándose menos del doble de precipitación que en 2022 en la estación de Barx y reduciendo las precipitaciones registradas en el resto de los observatorios, aunque ha presentado un verano más húmedo que el de los años anteriores.


El modelo de predicción se ha entrenado principalmente con los datos de campo pertenecientes a los años 2020 y 2021, más concretamente con los datos situados entre junio de 2020 y noviembre de 2021. De esta forma, para el verano se han podido utilizar los datos de los años 2020 y 2021, pero para el invierno solo se han utilizado los datos del invierno de 2021.

Sin embargo, los datos con los que se ha validado el modelo pertenecen a los años 2022 y 2023. Estos años registran grandes diferencias con respecto a los años 2020 y 2021, con unas lluvias extraordinarias en el mes de marzo de 2022, que nada tienen que ver con el marzo de 2021 que sirvió de entrenamiento, que resultó ser un mes relativamente seco. Como este caso hay también otros en los que se observan notables diferencias entre los valores de precipitación de un periodo y el mismo periodo de otro año utilizado para entrenar el modelo.

Esta variabilidad en cuanto a las precipitaciones entre los datos de entrenamiento y los de validación puede generar errores en las predicciones. Para limitar la influencia de la cantidad de precipitación en la ecuación de predicción de HCV se ha propuesto la utilización del logaritmo neperiano de  $p_{60}$ . De esta forma, una alta precipitación no hace aumentar tanto el valor predicho como lo haría de no utilizar este logaritmo.

#### 4.1.3. Análisis de temperatura 2010-2023

Después del estudio de la pluviometría, se ha procedido a analizar los valores de temperatura observados en cada estación y la variación que estos han podido experimentar a lo largo del tiempo.



Gráfica 14: Temperatura media anual por estación. Fuente: elaboración propia.

El observatorio de Bétera es el que registra las temperaturas más elevadas a lo largo de los años de forma constante. En contraste, Sant Mateu, Barx y Beneixama muestran en 2010 temperaturas medias 2°C más bajas que las registradas en Bétera en ese mismo año, aunque estas 2 últimas estaciones cierran el año 2023 muy cerca de la temperatura de Bétera, en torno a los 18°C.

La temperatura es una magnitud que está muy relacionada con la altura, por lo que es conveniente comentar las distintas altitudes medias de los observatorios. La estación de Beneixama es la que está situada a mayor altitud, con 661 m.s.n.m. Las estaciones de Barx y Sant Mateu están situadas a 340 y 325 metros, mientras que la estación de Bétera es la que está situada a menor altura con solo 128 m.s.n.m.

Las diferencias de temperatura observadas entre estos observatorios pueden explicarse en cierta medida por la relación entre la altitud y la temperatura, conocida como gradiente térmico adiabático. Este fenómeno indica que la temperatura del aire tiende a disminuir a medida que se asciende en altitud, aproximadamente 6,5°C por cada 1.000 metros de elevación. Por ello, Bétera, al estar a una altitud menor, retiene más calor y registra temperaturas más altas en comparación con Sant Mateu, Barx y Beneixama, que están situadas a mayores altitudes y, por tanto, experimentan temperaturas más bajas debido al enfriamiento asociado con la altitud. Como Beneixama está a mayor altura que las otras estaciones también debería presentar



temperaturas menores a las de los otros observatorios, sin embargo, registra temperaturas similares a las de estos salvo en años puntuales como 2010 o 2013.

Observando la evolución de las temperaturas, se evidencia un aumento gradual en todas las estaciones, arrancando desde el año 2010, que fue el año de temperatura media más baja desde 1996 según AEMET. En Sant Mateu, la temperatura media incrementó de 14,99°C en 2010 a 16,45°C en 2023, con ligeras fluctuaciones en el período intermedio. Barx mostró un incremento constante, desde 15,25°C en 2010 hasta alcanzar 17,97°C en 2023. Bétera, por su parte, experimentó un aumento más imitado, de 17,30°C a 18,21°C en el mismo período. Beneixama también exhibe una tendencia ascendente parecida a la de Barx, pasando de 14,69°C en 2010 a 17,64°C en 2023.

Entre el año 2022 y 2023 las estaciones de Barx y Beneixama, situadas en la mitad sur de la Comunitat Valenciana, muestran una subida de temperaturas de en torno a 0,5°C, mientras que las estaciones de Bétera y Sant Mateu, situadas en la mitad norte, registran un descenso en las temperaturas, especialmente esta última estación donde la temperatura desciende casi 1°C respecto a 2022.


Pese a la subida continua de las temperaturas, se observan algunos años en los que la temperatura desciende notablemente respecto a los anteriores. En 2013, Barx y Bétera registran bajadas de temperatura de en torno a 0,5°C y Beneixama de más de 1°C, indicando posibles anomalías climáticas específicas de ese año. De manera similar, en 2021 se percibe una disminución en las temperaturas de todas las estaciones salvo en Beneixama. Esta bajada se percibe especialmente en la estación de Sant Mateu, donde la temperatura baja más de 0,5°C respecto a la registrada en 2020.

Todas las estaciones muestran una tendencia de aumento en la temperatura media anual, lo que se puede asociar al calentamiento global. Según un informe del IPCC<sup>4</sup> (Panel Intergubernamental del Cambio Climático), *ha sido claro durante décadas que el clima de la Tierra está cambiando, y el papel de la influencia humana en el sistema climático es indiscutible*. Este incremento sostenido refleja el impacto del cambio climático en la región, a pesar de las fluctuaciones ocasionales en años específicos. La NOAA<sup>5</sup> (Oficina Nacional de Administración Oceánica y Atmosférica) también señala *que el año 2023 ha estado 1,18°C por encima de la media del período 1901-2000*, atribuyendo este cambio principalmente a las emisiones de gases de efecto invernadero provocadas por actividades humanas.


---

<sup>4</sup> <https://anue.org/es/2021/08/12/informe-ipcc-codigo-rojo-para-el-calentamiento-global/>


<sup>5</sup> <https://www.ncei.noaa.gov/access/monitoring/monthly-report/global/202312>




Gráfica 15: Temperatura media mensual en Sant Mateu según periodo. Fuente: elaboración propia.



Gráfica 16: Temperatura media mensual en Barx según periodo. Fuente: elaboración propia.



Gráfica 17: Temperatura media mensual en Bétera según periodo. Fuente: elaboración propia.



Gráfica 18: Temperatura media mensual en Beneixama según periodo. Fuente: elaboración propia.

Las 4 estaciones estudiadas presentan un comportamiento muy parecido en cuanto a la variación de las temperaturas a lo largo del tiempo. En todos los casos, se observa un aumento continuo de las temperaturas (mínimas, medias y máximas), siendo el periodo 2021-2023 el más caluroso de todos. En los observatorios de Bétera y Barx, se percibe un buen aumento de las



temperaturas máximas, pero no se registra el mismo aumento en las temperaturas mínimas, resultando en un aumento en la amplitud térmica diaria.

Comparando con los datos pluviométricos ya comentados se puede ver cómo la pluviometría, que se puede ver afectada por eventos meteorológicos extremos como tormentas o frentes fríos es mucho más variable que la temperatura.


Sin embargo, las temperaturas medias tienden a ser más estables debido a la inercia térmica del clima, donde los grandes cuerpos de agua (en este caso, el mar Mediterráneo) y la atmósfera actúan como moderadores, absorbiendo y liberando calor lentamente. Además, la variabilidad de la temperatura es menor en comparación con la precipitación, ya que factores como la latitud, altitud y proximidad al mar influyen, pero no cambian drásticamente de un año a otro.

El observatorio de Beneixama presenta un comportamiento ligeramente distinto a de los otros, con unas temperaturas mínimas más bajas y unas temperaturas máximas más altas que en el resto de las estaciones, resultando en el observatorio con mayor amplitud térmica de todos. Esto se explica por la situación geográfica del observatorio, situado en el interior de la provincia de Alicante lejos de la influencia térmica del mar Mediterráneo, que contribuye a moderar tanto las temperaturas máximas como las mínimas.


Los meses con mayor temperatura media son los del verano, en concreto los meses de julio y agosto. Por otro lado, los meses de enero, febrero y diciembre son los de menor temperatura media en todas las estaciones.

#### 4.1.4. Análisis de temperatura 2020-2023


En este apartado se han comentado, de forma general, las diferencias en cuanto a la temperatura media durante los últimos 4 años, que son los que han servido para entrenar y validar los modelos de predicción.




Gráfica 19: Temperatura media mensual en Sant Mateu según año. Fuente: elaboración propia.



Gráfica 20: Temperatura media mensual en Barx según año. Fuente: elaboración propia.



Gráfica 21: Temperatura media mensual en Bétera según año. Fuente: elaboración propia.



Gráfica 22: Temperatura media mensual en Beneixama según año. Fuente: elaboración propia.

En el periodo 2020-2023 se observa una subida ligera de la temperatura en todas las estaciones. Los años 2020 y 2021 son, de media, más fríos que los años 2022 y 2023, especialmente en los meses de verano, donde esta diferencia se acrecienta. El año 2022 es más caluroso que 2023 en



la estación de Sant Mateu, mientras que en las demás estaciones hay pocas diferencias entre las temperaturas medias de ambos años. El año 2023 tiene un patrón de temperaturas distinto al de los otros años, con un febrero más frío que el del resto de años, pero con unos meses de marzo y abril bastante más calurosos que los del resto de años.

La variabilidad de las temperaturas es mucho menor que la observada en el estudio de la pluviometría, por lo que la diferencia entre los años de validación y los de entrenamiento es pequeña, salvo en algún caso como el comentado en los meses de febrero, marzo y abril de 2023. De todas formas, esta variabilidad debe ser estudiada con un mayor número de años para reflejar la influencia sobre el HCV del aumento de temperaturas asociado al cambio climático. Recordemos que uno de los objetivos de este TFM es comparar las diferencias climáticas entre el periodo de entrenamiento de los modelos de estimación de la HCV (2020-2021) y el periodo de validación (2022-2023) de los mismos.


#### 4.2. Análisis de HCV

En este apartado se analizan distintos aspectos relacionados con la evolución del HCV a lo largo del tiempo, tanto del HCV observado en los muestreos en campo como del HCV predicho por los modelos de predicción originales y los nuevos que hemos generado.

Se han calculado las predicciones de HCV con los modelos descritos en la sección 3.5 y calculado el error cometido con los valores observados en campo. Son los denominados errores de validación. Los valores predichos de HCV según el modelo original se han calculado siguiendo las ecuaciones de la tabla 7 y los valores predichos según el modelo nuevo se han realizado siguiendo las ecuaciones del apartado 3.5.1, diferenciando entre pisos bioclimáticos, modelos de combustible o zonas como Gandía y Yatova-Dos Aguas.

##### 4.2.1. Evolución del HCV entre el 2020 y el 2023

En este proyecto, se han analizado datos de HCV tomados en dos periodos distintos: el primero abarca fechas entre junio de 2020 y noviembre de 2021, y el segundo desde enero de 2022 hasta diciembre de 2023. En algunos casos, las parcelas muestreadas en el segundo periodo también fueron muestreadas en el primer periodo, lo que permite comparar temporalmente los valores de HCV y observar cómo han evolucionado a lo largo del tiempo. Estos datos nos proporcionan una visión general de la evolución del HCV en este periodo de tres años y medio.



Gráfica 23: Evolución del HCV por parcela en el periodo 2021-2023. Fuente: elaboración propia a partir de los datos suministrados por VAERSA.


Como se puede ver en la gráfica 23, el valor de HCV ha descendido de forma general en casi todas las parcelas respecto al año 2021. En algunas parcelas como 87\_Altea o 63\_SantMateu los valores de HCV tienen fluctuaciones estacionales alrededor de una media que no presenta diferencias entre los distintos años. Sin embargo, otras parcelas, como 53\_Eslida, muestran grandes cambios en su contenido de humedad, pasando de un HCV de 133 en enero de 2021 a un valor de 52 en diciembre de 2023.

Este descenso general en los valores de HCV a lo largo del tiempo podría estar influenciado por factores como el cambio climático, que provoca temperaturas más altas y un aumento en la evaporación del HCV, reduciendo así la cantidad de humedad en la vegetación, pero también por el patrón irregular de precipitaciones con inviernos más secos.

Cunill Camprubí et al. (2022) menciona que, en las regiones mediterráneas, el cambio climático está provocando un aumento de las temperaturas y períodos de sequía más prolongados, lo que puede reducir significativamente la humedad del combustible vivo. Esta reducción en la humedad del combustible vivo aumenta la duración de la temporada de incendios y la frecuencia de eventos de incendios de alta intensidad, lo que sugiere que el cambio climático está afectando negativamente los niveles de humedad del combustible en estas áreas.

#### 4.2.2. Modelo de matorral en el piso G1

Dentro del piso termomediterráneo se recogen datos de campo en 3 parcelas de matorral distintas; Bétera, Gandia Parpalló y Gilet, todas ellas situadas dentro de la provincia de Valencia. La situación de estos puntos de muestreo se puede ver en el mapa 7.



Mapa 7: Parcelas de matorral situadas en el piso G1. Fuente: elaboración propia.


Las parcelas con menor error en la validación son las parcelas de Bétera y Gilet, con un RMSE de 12,2 y 11,5 respectivamente, mientras que la parcela con mayor error es la de Gandía Parpalló, que registra un RMSE de 16,3, todas ellas utilizando el modelo nuevo, denominado TFM. El RMSE medio obtenido con la ecuación original es de 18,4, mientras que el registrado con la ecuación v4 es de 13,3.

El RMSE calculado para el modelo original en Arcos et al. (2023) con los datos de calibración es igual a 13,1 con lo cual el RMSE de la tabla 8 para las nuevas fechas es superior a dicho número y en cambio el RMSE obtenido con el modelo nuevo está más cercano al mismo.

Parcela	Código UPV	RMSE_ORIG_G1S	RMSE_TFM_G1S
Betera	7	15,3	<b>12,2</b>
Gandía_Parpalló	40	24,7	<b>16,3</b>
Gilet	305	15,2	<b>11,5</b>

Tabla 8: RMSE según modelo para las parcelas de matorral situadas en el piso G1. Fuente: elaboración propia.

La parcela de Gandía Parpalló no fue utilizada como parcela de entrenamiento para generar las ecuaciones de predicción originales, a pesar de que se encontraba entre las 88 parcelas originales, debido a que se observaban discrepancias en los valores del FCC de las especies y se prefirió dejar fuera del cálculo de la ecuación. Sin embargo, los valores registrados en esta parcela se han utilizado en la ecuación nueva, lo que disminuye el error en la parcela para ese modelo.




Gráfica 24: Evolución del HCV en la parcela de Gandía Parpalló según modelo. Fuente: elaboración propia.

Para la parcela de Gandía, la ecuación que mayor error presenta es la ecuación original, donde la fecha de mayor error tiene lugar en marzo de 2022 y se relaciona con el episodio extraordinario de lluvias que fueron especialmente fuertes en la comarca de la Safor, a la que pertenece Gandía. Quitado de este periodo, en el resto de los meses ambas ecuaciones presentan un comportamiento parecido.

Estas lluvias extraordinarias contribuyeron a que los valores previstos de humedad para mayo y junio de 2022 fuesen mucho más elevados de los que se registraron realmente en la parcela. La ecuación v4 predice mejor el valor de humedad para estas fechas, debido a que esta ecuación utiliza el logaritmo neperiano de la precipitación acumulada en vez de solo la precipitación acumulada. Esto ayuda a disminuir la subida del valor predicho cuando los valores de precipitación son más altos, acercándose más a los valores observados.

El otro periodo en el que se registran los errores más grandes es en el otoño de 2022 y el invierno de 2023, donde se llegan a registrar valores observados de HCV mayores a los registrados durante las lluvias de marzo de 2022. Sin embargo, esta subida no se relaciona con un aumento de la precipitación o con cambios súbitos en los índices espectrales, por lo que los valores calculados se alejan bastante de los reales en este periodo.




Gráfica 25: HCV observado en Gandia Parpalló según especie. Fuente: elaboración propia.

Esos altos valores de humedad durante el invierno de 2023 están relacionados por un súbito aumento del HCV en la especie *Rosmarinus officinalis*, mientras que el resto de las especies mantienen valores de HCV relativamente constantes (gráfica 25). Si este aumento de humedad no va relacionado con un aumento en la precipitación acumulada o en los valores de los índices espectrales es normal que aparezcan diferencias entre resultados reales y previstos.

Cuando el HCV aumenta en el matorral que crece debajo del arbolado, pero no se observa un incremento en el HCV del propio arbolado, este cambio en el matorral no es detectado por las imágenes espectrales de satélite. Esto se debe a que las imágenes satelitales generalmente captan información a nivel de la cubierta forestal superior, sin distinguir las variaciones de humedad en las capas inferiores del matorral, lo que limita su capacidad para reflejar cambios específicos en la estructura del combustible vegetal más denso a nivel del suelo. Este hecho puede explicar que el modelo no se adapte correctamente a los valores reales de HCV cuando tienen lugar estas circunstancias.


En matorrales de bajo porte, como el *Rosmarinus officinalis*, los valores de humedad tienen mayor variabilidad que en especies de arbolado como el *Pinus halepensis* o el *Pinus pinaster*. En el romero, los episodios de lluvia tienen un rápido efecto sobre el HCV, y en los meses de sequía los niveles también bajan más rápidamente. En el observatorio de Barx, cercano a Gandía, se registran bastantes lluvias en febrero de 2023, que hacen aumentar rápidamente el HCV durante esas fechas. El descenso en el HCV del romero durante el verano de 2022 también se relaciona con unos meses donde escasearon las precipitaciones. Por otro lado, especies de arbolado o de matorral como la coscoja los cambios de humedad de combustible son más lentos y la recuperación tras las lluvias es más suave.



Gráfica 26: Evolución del HCV en la parcela de Bétera según modelo. Fuente: elaboración propia.

En el caso de Bétera (gráfica 26), las 2 ecuaciones de predicción funcionan muy bien durante el año 2022 pero empiezan a fallar a partir de la primavera de 2023, donde la variabilidad del HCV observado se mantiene, pero el rango de variabilidad de los valores predichos se reduce.

En el año 2023 la ecuación TFM se adapta mejor que la original al HCV observado, prediciendo correctamente las subidas y las bajadas, aunque no la magnitud de estas. La ecuación original presenta mayor error, tendiendo a sobreestimar los valores de HCV entre febrero y septiembre.



Gráfica 27: Evolución del HCV en la parcela de Gilet según modelo. Fuente: elaboración propia.

En otras parcelas como Gilet (gráfica 27), la ecuación TFM modela bastante bien el comportamiento del HCV a lo largo del periodo de estudio, presentando los mayores errores durante los inviernos de 2022 y 2023, en los que tanto la ecuación original como la nueva sobreestiman los valores observados de HCV.



Para los meses de invierno, la ecuación original esta entrenada con datos del invierno de 2021 mientras que la ecuación TFM esta entrenada con datos de distintos inviernos, aunque también predominan las parcelas muestreadas en el invierno de 2021. Como los inviernos de 2022 y 2023 han sido más secos en Gilet que el invierno del periodo de entrenamiento, las ecuaciones tienden a fallar en este periodo debido a ese cambio en las condiciones climatológicas.

La ecuación original presenta además un elevado error en la primavera de 2022, donde las copiosas lluvias hacen que los valores predichos por la ecuación estén muy por encima de los valores observados de HCV, que no se ven tan afectados por las abundantes precipitaciones. Esta ecuación también sobreestima de forma general los valores de HCV durante el año 2023, mientras que la ecuación nueva se adapta mejor a los cambios de tendencia en el HCV.

Algunas de las parcelas se encuentran cerca del límite entre el piso termomediterráneo y el mesomediterráneo, por lo que se ha decidido comprobar si al utilizar las ecuaciones del piso mesomediterráneo se observa una disminución en los valores del error cuadrático. La parcela de Bétera muestra un error parecido al obtenido con las ecuaciones del piso G1, con un RMSE de 12,2, mientras que Gandia Parpalló tiene un error mayor al obtenido con la ecuación nueva del piso G1, con un RMSE de 22,4.


Parcela	Código UPV	RMSE_ORIG_G2S	RMSE_TFM_G2S
Betera	7	13,7	<b>12,2</b>
Gandia_Parpalló	40	27,3	<b>22,4</b>
Gilet	305	<b>9,4</b>	10,9

Tabla 9: RMSE según modelo del piso G2S para las parcelas de matorral situadas en el piso G1. Fuente: elaboración propia.

La parcela de Gilet sí que muestra una ligera mejora al utilizar las ecuaciones del piso mesomediterráneo, que no utilizan medias espectrales ni datos de altitud, pero si valores medios de temperatura y de pendiente. Con estos cambios el error disminuye, obteniendo un RMSE de 9,4 en la ecuación original.

La ecuación del grupo G1S muestra fluctuaciones más pronunciadas en comparación con G2S. Esto sugiere que la ecuación del piso termomediterráneo es más sensible a los cambios en las condiciones que afectan la humedad del combustible.

Las 2 ecuaciones funcionan de forma parecida durante el año 2022, mostrando valores más bajos en la ecuación G1S. A partir del 2023, la ecuación G1S alterna periodos en los que sobreestima el contenido en humedad, con bajadas súbitas del HCV que aumentan el error, mientras que la ecuación G2S muestra unas variaciones más estables. Esto demuestra que en las parcelas limítrofes de los pisos bioclimáticos no existen cambios importantes entre usar uno u otro modelo.



Gráfica 28: Evolución del HCV en Gilet según ecuaciones de los pisos G1S y G2S. Fuente: elaboración propia.

#### 4.2.3. Modelo de arbolado en el piso G1

El piso bioclimático termomediterráneo solo contiene 2 parcelas de arbolado, una situada en Gandía (Valencia) y otra en el Desert de les Palmes (Castellón). La situación de las parcelas se puede ver en el mapa 8.




Mapa 8: Parcelas de arbolado situadas en el piso G1. Fuente: elaboración propia.

La ecuación original funciona bien en la parcela de Gandía, con un RMSE de 15,3, pero falla en la parcela de Desert Palmes que tiene un elevado RMSE de 35,8. Al utilizar la ecuación nueva, el error en Desert Palmes baja mucho llegando a solo 7,8, mientras que la parcela de Gandía registra un RMSE parecido al obtenido en la ecuación original. El RMSE medio obtenido con la ecuación original es de 25,5, mientras que este valor mejora al utilizar la ecuación TFM, llegando a 12,4.

Parcela	Código_UPV	RMSE_ORIG_G1T	RMSE_TFM_G1T
36_Gandia umbria	36	15,3	16,9
Desert Palmes	121	35,7	7,8

Tabla 10: RMSE según modelo para las parcelas de arbolado situadas en el piso G1. Fuente: elaboración propia.


En la parcela de Gandía (gráfica 29), los 2 modelos subestiman de forma general los valores de HCV, salvo en casos puntuales como la primavera de 2022, donde al utilizar la precipitación acumulada como variable en un periodo de lluvias extraordinarias se disparan los valores previstos. En la ecuación original es donde más sube este valor previsto, al utilizar la precipitación acumulada como variable.



Gráfica 29: Evolución del HCV en la parcela de Gandía Umbria según modelo. Fuente: elaboración propia.

En gran parte del periodo de estudio es la ecuación nueva la que se acerca más a los valores reales de HCV, pero a partir de marzo de 2023 los valores predichos por ambas ecuaciones empiezan a diferir y la ecuación TFM registra una gran variabilidad que no se corresponde con la evolución real del HCV. En los meses finales de 2023, los valores predichos por la ecuación nueva bajan mucho, debido a un descenso en los valores de los índices espectrales utilizados para el cálculo. Esta bajada es especialmente notoria en el ARVI, pero también en el EVI.


En estas parcelas de arbolado la señal espectral no recoge los valores de HCV del matorral debajo del arbolado. Esta parcela está localizada en una zona de umbría, lo que afecta todavía más a los valores de media ponderada, los cuales tienen en cuenta todas las especies predominantes en la parcela.



Gráfica 30: Evolución del ARVI y el EVI en la parcela de Gandía Umbria. Fuente: elaboración propia.

En la parcela de Desert Palmes (gráfica 31), se aprecian grandes diferencias entre las 2 ecuaciones. La ecuación original presenta en esta parcela valores muy altos de HCV predicho en todo el periodo, sobreestimando de forma sistemática los valores reales de HCV. Además, tiene un rango de variabilidad menor del observado en la evolución del HCV real durante el periodo de estudio. Todo ello hace que tenga un RMSE de 35,7, un valor muy elevado que indica que la ecuación utilizada no funciona para esta parcela. Esta parcela no cuenta con datos en el periodo 2020-2021 y por tanto no pudo ser usada para construir el modelo original. En cambio, sí que ha aportado información al modelo nuevo.

La ecuación nueva predice muy bien la evolución del HCV y se adapta correctamente tanto a las épocas de mayor humedad, como a las de mayor sequía, obteniendo un RMSE de tan solo 7,8. El momento en el que se observan mayores diferencias es en los meses finales de 2023, donde el valor real del HCV desciende a 80 pero los valores estimados se mantienen en torno a 100.



Gráfica 31: Evolución del HCV en la parcela de Desert Palmes según modelo. Fuente: elaboración propia.

De la misma forma que en las parcelas de matorral, se ha comprobado si al utilizar las ecuaciones del piso mesomediterráneo se observa una disminución en los valores del error cuadrático. En la parcela de Gandía Umbria se obtiene un RMSE de 15,3 con la ecuación nueva, muy parecido al obtenido con las ecuaciones del piso G1, mientras que la parcela de Desert Palmes registra un RMSE de 16,2 con la ecuación TFM, lo que genera un resultado peor que el obtenido con la ecuación del piso termomediterraneo.


Aun así, visto los resultados obtenidos, se puede decir que las ecuaciones nuevas del piso G2T funcionan razonablemente bien sobre estas parcelas. Sin embargo, las ecuaciones originales registran un RMSE más alto en ambos puntos de muestreo, indicando que esta ecuación no funciona para las estaciones situadas en el piso bioclimático más cercano a la costa.

Parcela	Código_UPV	RMSE_ORIG_G2T	RMSE_TFM_G2T
36_Gandia umbria	36	21,8	<b>15,3</b>
Desert Palmes	121	31,0	<b>16,2</b>

Tabla 11: RMSE según modelo del piso G2T para las parcelas de arbolado situadas en el piso G1. Fuente: elaboración propia.

#### 4.2.4. Modelo de matorral en el piso G2

El piso bioclimático mesomediterraneo contiene 24 parcelas de matorral, situadas entre las distintas provincias de la Comunitat Valenciana. La situación de estas parcelas se puede ver en el mapa 9.



Mapa 9: Parcelas de matorral situadas en el piso G2. Fuente: elaboración propia.


La ecuación nueva es la que menor RMSE registra para la mayoría de las parcelas de muestreo, siendo la mejor ecuación para 16 parcelas, mientras que la ecuación original es la que mejor se adapta al comportamiento del HCV en 9 parcelas. El RMSE medio obtenido con la ecuación original es de 17,4 mientras que el registrado con la ecuación TFM es de 15,5.



Parcela	Código_UPV	RMSE_ORIG_G2S	RMSE_TFM_G2S
13_Chelva Granzas	13	<b>13,94</b>	14,02
33_Cortes Aljibe	33	<b>14,24</b>	14,60
53_Eslida	53	26,53	<b>22,70</b>
63_Sant Mateu	63	<b>12,73</b>	15,42
72_Torre Maçanes (Deposito)	72	<b>11,99</b>	<b>11,99</b>
77_Villalonga	77	29,83	<b>23,63</b>
87_Altea-Jalón (Bernia Solana)	87	22,78	<b>14,69</b>
Albaida	144	20,84	<b>10,48</b>
Altura 2	311	<b>11,04</b>	11,45
Ares del Maestrat	130	19,10	<b>17,79</b>
Buñol_semanal	92	14,99	<b>11,36</b>
Catí	131	14,64	<b>13,20</b>
Chelva (Nieva)	137	13,72	<b>11,13</b>
Chelva Remedio	12	16,84	<b>13,21</b>
Chovar	120	28,76	<b>18,55</b>
Dos Aguas	140	<b>22,16</b>	22,90
Gestalgar	138	11,20	<b>9,30</b>
Llombai Mensual Pinar	312	9,24	<b>7,07</b>
Llombai_semanal	93	18,52	<b>17,92</b>
Morella	118	<b>11,75</b>	17,73
Requena_semanal	91	10,69	<b>10,52</b>
Segorbe (tristan)	135	22,48	<b>16,26</b>
Tous	142	<b>11,90</b>	13,64
Yatova	139	<b>28,34</b>	31,27

Tabla 12: RMSE según modelo para las parcelas de matorral situadas en el piso G2. Fuente: elaboración propia.


Las parcelas utilizadas para generar las ecuaciones de entrenamiento (aquellas que tienen un número delante de su nombre) tienen un RMSE bajo a excepción de las parcelas de Eslida y Villalonga. Estas 2 parcelas, en concreto, no se usaron para entrenar los modelos en las ecuaciones originales de Arcos et al. (2023).



Gráfica 32: Evolución del HCV en la parcela de 53\_Eslida según modelo. Fuente: elaboración propia.

La ecuación nueva se adapta bien a los valores reales hasta octubre de 2022, pero comete grandes errores en el periodo que va desde ese momento a marzo de 2023, periodo donde los valores de humedad se disparan, pero los valores predichos no aumentan de la misma forma. Se puede ver como la ecuación sí que registra bien las subidas y las bajadas, pero no se adapta a la magnitud de estos cambios, por ello falla en una parcela con una variabilidad de HCV tan alta.

La mejora de la ecuación v4 respecto a la otra se debe a la inclusión de la parcela en las ecuaciones de entrenamiento para el piso G2S, después de no ser introducida en las ecuaciones originales.




Gráfica 33: HCV observado en 53\_Eslida según especie. Fuente: elaboración propia.

En este caso la variabilidad del HCV se debe al elevado peso que tienen en la parcela el *Rosmarinus officinalis* y el *Cistus ladanifer*, dos matorrales de bajo porte que se caracterizan por rápidas subidas y bajadas en el contenido de humedad. Cuando esos súbitos cambios no se ven relacionados con un cambio de la misma magnitud en las variables climatológicas la ecuación tiende a fallar.


La parcela de Villalonga (gráfica 34) muestra un comportamiento parecido, con un súbito aumento del HCV a partir del otoño de 2022 que ninguna de las ecuaciones puede predecir, a pesar de que la ecuación nueva sigue siendo la que mejor funciona. La ecuación original falla especialmente en el mes de marzo de 2022, cuando se recogen precipitaciones muy importantes en Villalonga que hacen aumentar el valor previsto de HCV muy por encima del valor de real de humedad. El modelo TFM se comporta mejor en este periodo al utilizar el logaritmo neperiano de la precipitación.

La parcela de Villalonga también ha sido cambiada de piso en la ecuación nueva, pasando del piso termomediterráneo al mesomediterráneo. Originalmente se situó en el piso termomediterráneo debido a que se sitúa en una zona de transición entre ambos pisos bioclimáticos y comparte características de ambos. Al utilizar la ecuación del modelo TFM el RMSE de esta parcela desciende, pasando de 29,83 a 23,63.



Gráfica 34: Evolución del HCV en la parcela de 77\_Villalonga según modelo. Fuente: elaboración propia.


La parcela de Altea Jalon (gráfica 35) también ha sido cambiada del piso bioclimático G1 al G2 en la ecuación v4, de la misma forma que la parcela de Villalonga. En este caso la ecuación nueva sí que se adapta mucho mejor que el otro modelo, especialmente en el periodo de mayor error. Como en otros casos este periodo comprende los últimos meses de 2022 y los primeros meses de 2023.



Gráfica 35: Evolución del HCV en la parcela de 87\_Altea Jalon según modelo. Fuente: elaboración propia.

Las parcelas nuevas tienen valores de RMSE variados y dependiendo del caso también cambia la ecuación que mejor se adapta a la fluctuación del HCV.


La inclusión de las parcelas de Villalonga y Altea Jalón (situadas en el norte de Alicante) en el piso G2 ha hecho que las parcelas cercanas a estas también muestren un mejor comportamiento en la ecuación de predicción nueva. Esto se puede ver bien en la parcela de Albaida (gráfica 36), que tiene un error alto en la ecuación original, pero el error se rebaja mucho al utilizar la ecuación TFM.




Gráfica 36: Evolución del HCV en la parcela de Albaida según modelo. Fuente: elaboración propia.

De entre las parcelas nuevas destacan por su elevado error las parcelas de Yátova (gráfica 37) y Dos Aguas (gráfica 38), separadas por tan solo 3 km. La parcela de Yátova tiene un error de 28,34 en la ecuación original, mientras que la parcela de Dos Aguas tiene un RMSE de 22,16 en la misma ecuación.

Ambas parcelas muestran un comportamiento similar, con unos resultados muy parecidos entre todas las ecuaciones, aunque ligeramente mejores en la ecuación original. Los valores más altos de HCV se observan durante la primavera de 2022, donde después de las lluvias de marzo de 2022 se alcanzan valores muy altos de HCV, muy superiores a los valores previstos por cualquiera de las 2 ecuaciones. Durante el resto del periodo las ecuaciones siguen subestimando los valores del HCV, observándose los mayores errores entre el otoño de 2022 y el inicio del verano de 2023.




Gráfica 37: Evolución del HCV en la parcela de Yatova según modelo. Fuente: elaboración propia.



Gráfica 38: Evolución del HCV en la parcela de Dos Aguas según modelo. Fuente: elaboración propia.

Los valores del HCV muestra una gran variabilidad pasando de momentos con gran humedad a un periodo más seco en muy pocos meses. Como en el caso de Eslida, la variabilidad del HCV se puede deber al elevado peso de los matorrales de bajo porte, cuyos valores de humedad pueden oscilar rápidamente. Como se puede ver en la gráfica, las especies de *Cistus albidus* y *Cistus*

*salviifolius* ocupan gran parte de la parcela de Dos Aguas y tienen una gran influencia sobre la media ponderada de HCV.




Gráfica 39: HCV observado en Dos Aguas según especie. Fuente: elaboración propia.

Otra de las parcelas con un elevado RMSE es la de Chovar, con valores muy altos de RMSE en la ecuación original, pero obteniendo un resultado mucho mejor en el modelo nuevo. Esta parcela tiene un comportamiento muy parecido al que se observaba en la parcela de Albaida, donde al incluir las parcelas cercanas de Villalonga y Altea en el piso mesomediterráneo se obtenían unos errores mucho más bajos que en la ecuación original. Sobre la parcela de Chovar tiene una gran influencia espacial la parcela de Eslida, que está situada a solo 1 km de distancia de la parcela, por lo que al incluir la parcela de Eslida entre las parcelas de entrenamiento el error disminuye drásticamente.

El comportamiento del HCV y de las ecuaciones también son muy parecidos a los observados en Eslida, siendo Chovar una parcela caracterizada por una gran variabilidad en el HCV y concentrando los errores entre otoño de 2022 y la primavera de 2023. Todas las ecuaciones subestiman el contenido en humedad, aunque la ecuación v4 tiene valores más altos que se acercan los reales.


Los mayores errores se producen en valores altos de HCV que son los que tienen poca importancia en la prevención de incendios. Los errores se reducen en los periodos secos, especialmente en verano, lo cual es importante para prevenir el riesgo de incendio en esas épocas.



Gráfica 40: Evolución del HCV en la parcela de Chovar según modelo. Fuente: elaboración propia.

#### 4.2.5. Modelo de arbolado en el piso G2

En el piso bioclimático mesomediterráneo se han utilizado 8 parcelas de arbolado para validar los resultados, situadas principalmente entre las provincias de Valencia y Alicante. La situación de los puntos de muestreo se puede ver en el mapa 10.



Mapa 10: Parcelas de arbolado situadas en el piso G2. Fuente: elaboración propia.



Como en los casos anteriores, la ecuación nueva vuelve a ser la que más se aproxima a los valores reales del HCV, siendo la ecuación con menor error en todas las estaciones. En todos los puntos de muestreo se registra un RMSE menor a 14, ya sea con una ecuación o con otra, lo que indica que la ecuación ideada funciona correctamente para todas las parcelas repartidas por la Comunitat Valenciana. El RMSE medio obtenido con la ecuación original es de 18,0, mientras que el registrado con la ecuación TFM es de tan solo 11,0.


Parcela	Código_UPV	RMSE_ORIG_G2T	RMSE_TFM_G2T
85_Altea-Jalón	85	25,96	<b>10,27</b>
Ayora (La Hundede)	141	16,09	<b>12,40</b>
Biar	114	15,68	<b>11,76</b>
Enguera	143	20,24	<b>12,52</b>
Montanejos	117	21,02	<b>13,60</b>
Muela de Cortes	112	15,25	<b>11,17</b>
Torre maçanes 2022	113	10,68	<b>9,97</b>
Villargordo	107	19,16	<b>6,27</b>

Tabla 13: RMSE según modelo para las parcelas de arbolado situadas en el piso G2. Fuente: elaboración propia.

Las parcelas en las que se aprecia mayor diferencia entre las 2 ecuaciones son las parcelas de Altea y Villargordo, en las que la utilización de la ecuación nueva disminuye mucho los errores registrados al emplear la ecuación original.

En Altea (gráfica 41), la ecuación original subestima de forma sistemática los valores reales de HCV salvo en la primavera de 2022, donde se disparan los valores predichos. Esto se produce porque la ecuación de predicción utiliza como variable la precipitación acumulada, y en la primavera de 2022 se registraron elevadísimas precipitaciones. La ecuación nueva utiliza el logaritmo neperiano de la precipitación, lo que mejora la predicción en los meses de gran precipitación.

La ecuación nueva, que tiene un RMSE de 10,3, está muy cerca del valor real en casi todo el periodo de estudio, adaptándose correctamente a los aumentos y descensos del HCV en esta parcela, que tiene un rango de variabilidad bajo comparado con otras parcelas.




Gráfica 41: Evolución del HCV en la parcela de 85\_Altea Jalon según modelo. Fuente: elaboración propia.

Al igual que Altea, la parcela de Villargordo (gráfica 42) tiene un error elevado en la ecuación original, con un RMSE de 19,2, pero la ecuación TFM predice mejor los valores de HCV, llegando a un RMSE de tan solo 6,3.


De nuevo se observa que la ecuación original sobreestima los valores reales de HCV de forma sistemática, lo que está relacionado con el valor medio del índice TCARI, que se utiliza como variable en esta ecuación. Al ser un valor constante, una posible anomalía en el valor medio del TCARI hace que se desplace hacia arriba en el eje Y todo el conjunto de valores predichos.

Sin embargo, la ecuación nueva predice muy bien los valores observados de HCV, aunque estos valores predichos tienen un rango de variabilidad menor del que registran los datos reales.



Gráfica 42: Evolución del HCV en la parcela de Villargordo según modelo. Fuente: elaboración propia.

En la parcela de Torre Maçanes (gráfica 43) es en la que menos diferencia hay entre el RMSE de ambas ecuaciones, aunque como en los casos anteriores, la ecuación nueva es la que menor error registra. Este RMSE más alto en la ecuación original esta provocado por un valor predicho muy elevado durante la primavera de 2022, pero durante el resto del periodo se aproxima más a los valores reales que la ecuación TFM. Esta última ecuación funciona bien cuando los valores observados de HCV son bajos, pero en general subestima los valores de HCV.



Gráfica 43: Evolución del HCV en la parcela de Torre Maçanes según modelo. Fuente: elaboración propia.


Como en los casos anteriores, algunas de las parcelas se encuentran cerca del límite entre el piso G1 y el G2 y se quiere comprobar si al utilizar las ecuaciones del piso termomediterraneo se observa una disminución en los valores del error cuadrático. En la mayoría de los casos utilizar las ecuaciones del piso G1 resulta en un RMSE notablemente más elevado, como se puede ver en las parcelas de Enguera o Ayora. Sin embargo, al utilizar la ecuación del piso G1 se observa una ligera mejora en los valores predichos para la parcela de Montanejos.

Parcela	Código_UPV	RMSE_ORIG_G1T	RMSE_TFM_G1T
85_Altea-Jalón	85	31,35	<b>21,39</b>
Ayora (La Hundede)	141	39,57	<b>39,36</b>
Biar	114	<b>23,67</b>	47,26
Enguera	143	<b>37,52</b>	<b>38,99</b>
Montanejos	117	18,81	<b>12,34</b>
Muela de Cortes	112	<b>24,59</b>	41,98
Torre maçanes 2022	113	<b>11,55</b>	26,23
Villargordo	107	27,38	<b>25,54</b>

Tabla 14: RMSE según modelo del piso G1T para las parcelas de arbolado situadas en el piso G2. Fuente: elaboración propia.

La parcela de Montanejos (grafica 44) obtenía un RMSE de 13,6 al utilizar la ecuación del piso G2, pero este RMSE mejora al utilizar la ecuación del piso G1, alcanzando un error de 12,3. Ni la ecuación del piso termomediterraneo ni la del piso mesomediterráneo predicen el elevado rango de variabilidad de la parcela de Montanejos, pero cuando los valores reales de HCV son


más bajos, la ecuación del piso G1T se aproxima más a los valores reales, resultando en un menor error. Hay periodos de mayor error en ambas ecuaciones como el final de la primavera de 2022, donde los valores reales de HCV se disparan.



Gráfica 44: Evolución del HCV en la parcela de Montanejos según modelo. Fuente: elaboración propia.

Como ya se ha visto anteriormente, la gran variabilidad en los valores de humedad de una parcela está relacionado con el elevado peso que pueda tener en esta el matorral de bajo porte, que reacciona rápidamente ante los episodios de lluvia, pero conserva la humedad durante menos tiempo. En este caso, el matorral responsable de modificar la media ponderada es el *Rosmarinus officinalis*, que registra altos valores de HCV después de las lluvias de primavera del 2022.


Por otro lado, la señal espectral responde a la evolución del HCV en el *Pinus halepensis*. Sin embargo, la evolución del HCV en el matorral no es captada correctamente por la señal de satélite, ya que está cubierta por la copa del arbolado.



Gráfica 45: HCV observado en Montanejos según especie. Fuente: elaboración propia.

#### 4.2.6. Modelos locales

Después de calcular las ecuaciones de predicción por piso bioclimático y modelo de combustible y analizar su RMSE, se ha revisado la distribución geográfica de los errores para ver si hay zonas que concentren varias parcelas con error elevado. Esto puede indicar que las ecuaciones de predicción de HCV no funcionan sobre ciertas zonas, y sería conveniente calcular nuevas ecuaciones de carácter local para mejorar los resultados en estos sitios.



Mapa 11: Parcelas sobre las que se ha realizado un nuevo modelo local. Fuente: elaboración propia.

De los resultados obtenidos hemos destacado 2 zonas en las que las ecuaciones de predicción parecen no funcionar del todo bien: las parcelas de Gandía, situadas en la comarca de la Safor, y el conjunto de parcelas Yatova-Dos Aguas, situadas en la comarca de la Hoya de Buñol.


Estas 2 zonas, situadas en la provincia de Valencia, presentan un RMSE superior a 15 y mayor que el registrado en la gran mayoría de parcelas.

Parcela	Código UPV	Grupo	RMSE_ORIG	RMSE_TFM
Gandia_Parpalló	40	G1S	26,2	<b>16,3</b>
36_Gandia umbria	36	G1T	<b>15,3</b>	16,9
Dos Aguas	140	G2S	<b>22,2</b>	22,9
Yatova	139	G2S	<b>28,3</b>	31,3

Tabla 15: RMSE de las parcelas sobre las que se ha realizado un nuevo modelo local. Fuente: elaboración propia.

#### 4.2.6.1. Modelo para parcelas de Gandía

La utilización de la ecuación diseñada para Gandía (gráfica 46) reduce bastante el error que tenía los modelos originales y los nuevos, registrando un RMSE de tan solo 11,5. La ecuación se adapta bien a los cambios en el HCV de la vegetación, solventando el error que se registraba en la ecuación original por las abundantes lluvias de la primavera de 2022, y el error que se producía en la ecuación TFM en los últimos meses de 2023, debido a una bajada en los valores de los índices ARVI y EVI.




Gráfica 46: Evolución del HCV en la parcela de Gandía Umbria según modelo. Fuente: elaboración propia.

En la parcela de Gandía Parpalló (gráfica 47), la utilización de la ecuación de Gandía no mejora el error registrado por la ecuación TFM, que tenía un RMSE de 16,3 por el 16,8 de la ecuación de Gandía. En esta parcela, la ecuación de Gandía muestra un comportamiento parecido al de la ecuación TFM, presentando valores ligeramente más altos en casi todo el periodo.



Parcela	Código UPV	RMSE_ORIG_G1T	RMSE_TFM_G1T	RMSE_Gandia
36_Gandia umbria	36	15,3	16,9	<b>11,5</b>
		RMSE_ORIG_G1S	RMSE_TFM_G1S	RMSE_Gandia
Gandia_Parpalló	40	26,2	<b>16,3</b>	16,8
		RMSE_ORIG_G2S	RMSE_TFM_G2S	RMSE_Gandia
77_Villalonga	77	29,8	23,6	<b>15,6</b>
Albaida	144	20,8	<b>10,5</b>	27,7
Tous	142	<b>11,9</b>	13,6	47,2

Tabla 16: RMSE según modelo para las parcelas cercanas a Gandía. Fuente: elaboración propia.



Gráfica 47: Evolución del HCV en la parcela de Gandía Parpalló según modelo. Fuente: elaboración propia.

En general esta ecuación no funciona del todo bien para las parcelas de matorral, y solo disminuye el error en la parcela de Villalonga, en la que registra un RMSE de 15,6, que sigue siendo mayor al observado en la parcela de arbolado. Sin embargo, en Albaida y Tous se observan errores bastante elevados.


Este error más elevado en las parcelas de matorral se debe a que en el modelo de Gandía hemos mezclado parcelas de arbolado con parcelas de matorral y el modelo ha suavizado los valores de estas parcelas. Para solventar esto, se ha realizado un nuevo modelo enfocado a las parcelas de matorral de la zona de Gandía.

4.2.6.2. Modelo para matorral de Gandía

La ecuación de matorral de Gandía se adapta ligeramente mejor que la ecuación de arbolado y matorral en Gandía Parpalló, presentando un RMSE de 16,2. El comportamiento de esta ecuación es muy parecido al registrado en la ecuación TFM para el piso G1S, que en esta parcela registra un RMSE de 16,3. Este comportamiento similar entre 2 ecuaciones que utilizan variables distintas demuestran la robustez de la metodología a la hora de calcular nuevas ecuaciones de predicción de HCV.


Parcela	Código UPV	RMSE_ORIG_G1S	RMSE_TFM_G1S	RMSE_Gandia	RMSE_Gandia_SH
Gandia_Parpalló	40	26,2	16,3	16,8	<b>16,2</b>
		RMSE_ORIG_G2S	RMSE_TFM_G2S	RMSE_Gandia	RMSE_Gandia_SH
77_Villalonga	77	29,8	23,6	<b>15,6</b>	24,6
Albaida	144	20,8	<b>10,5</b>	27,7	26,7
Tous	142	11,9	13,6	47,2	<b>9,5</b>

Tabla 17: RMSE según modelo para las parcelas de matorral cercanas a Gandía. Fuente: elaboración propia.



Gráfica 48: Evolución del HCV en la parcela de Gandía Parpalló según modelo. Fuente: elaboración propia.

Las parcelas de Villalonga y Albaida presentan un elevado RMSE, que no mejora los resultados obtenidos al utilizar otras ecuaciones, pero la parcela de Tous sí que tiene obtiene un RMSE muy bajo que indica que la ecuación funciona especialmente bien en esta parcela, mejorando a la ecuación original del piso G2S.



Gráfica 49: Evolución del HCV en la parcela de Tous según modelo. Fuente: elaboración propia.

La ecuación de matorral para Gandía presenta en Tous (gráfica 49) un comportamiento parecido al de la ecuación G2S pero adaptándose mejor a los valores observados de HCV, especialmente en el otoño de 2022 y el invierno de 2023, en los que la ecuación original del piso G2S subestimaba los valores reales de HCV. Ambas ecuaciones funcionan mucho mejor que la ecuación de matorral y arbolado para Gandía, que sobreestima de forma sistemática los valores de HCV.

En las parcelas de Villalonga y Albaida se observan errores elevados con esta ecuación, denotando que el modelo no funciona sobre estos puntos de muestreo. Este modelo, al igual que el anterior, se ha confeccionado con unas pocas parcelas próximas a Gandía y no sirve para predecir resultados en zonas más alejadas a las parcelas de entrenamiento.

#### 4.2.6.3. Modelo para Yátova-Dos Aguas

El modelo de Yátova-Dos Aguas consigue disminuir el RMSE en las 2 parcelas para las que está diseñada. La parcela de Dos Aguas alcanza un error medio de 15,8, mientras que el RMSE registrado en Yátova es de 19,2. En el resto de las parcelas, la utilización de la nueva ecuación no mejora la predicción del HCV salvo en 33\_Cortes Aljibe, en la que el RMSE desciende hasta los 9,1.


Parcela	Código UPV	RMSE_ORIG_G2S	RMSE_TFM_G2S	RMSE_Yatova
33_Cortes Aljibe	33	14,2	14,6	<b>9,1</b>
Buñol_semanal	92	15,0	<b>11,4</b>	22,8
Dos Aguas	140	22,2	22,9	<b>15,8</b>
Muela de Cortes	112	<b>11,7</b>	12,9	16,9
Requena_semana	91	10,7	<b>10,5</b>	19,1
Yatova	139	28,3	31,3	<b>19,2</b>

Tabla 18: RMSE según modelo para las parcelas de matorral cercanas a Yátova-Dos Aguas. Fuente: elaboración propia.


El comportamiento de la ecuación de predicción de Yátova-Dos Aguas es muy parecida tanto en Dos Aguas (gráfica 50) como en Yátova (gráfica 51). Los valores predichos por la ecuación son sistemáticamente más altos que los de las ecuaciones original y TFM, y por ello se acercan más



a los valores reales de HCV. Al igual que en las otras ecuaciones, los puntos de mayor error se producen en los meses de primavera de 2022, donde los valores observados de HCV aumentan súbitamente sin que las ecuaciones puedan adaptarse a una subida tan abrupta. La ecuación sí que sirve para disminuir los elevados errores que se producían entre septiembre de 2022 y marzo de 2023 con los modelos original y TFM para el piso G2S.



Gráfica 50: Evolución del HCV en la parcela de Dos Aguas según modelo. Fuente: elaboración propia.




Gráfica 51: Evolución del HCV en la parcela de Yatova según modelo. Fuente: elaboración propia.

En Cortes (gráfica 52) se observa un caso parecido, donde los modelos original y TFM del piso G2S subestiman los valores reales de HCV y la nueva ecuación para Yatova-Dos Aguas calcula valores predichos más altos, que reducen bastante el error. Durante el año 2022, el modelo de




Yatova-Dos Aguas funciona razonablemente bien, pero falla en el periodo situado entre febrero y mayo de 2023, donde los valores reales del HCV descienden, pero los valores predichos por la ecuación se mantienen altos. La nueva ecuación también mejora la predicción en los meses finales del 2023, en los que las ecuaciones original y TFM del piso G2S fallan especialmente.



Gráfica 52: Evolución del HCV en la parcela de 33\_Cortes según modelo. Fuente: elaboración propia.

### 4.3. Mapa de predicción de HCV con el nuevo modelo


El mapa ráster generado con el modelo nuevo (mapa 12) muestra que, para el 5 de abril de 2023, las zonas costeras tienen un mayor nivel de HCV que las zonas de interior. La simbolización del mapa se ha realizado dividiendo los valores de HCV en 5 clases utilizando percentiles y utilizando una rampa de color que va del rojo al verde, utilizando el rojo para los píxeles con menor HCV y el verde para las zonas con mayor humedad.



Mapa 12: HCV estimado con la ecuación nueva para el día 05/04/2023. Fuente: elaboración propia.

La zona con mayor HCV se corresponde con las zonas costeras del sur de la provincia de Valencia y del norte de Alicante. Como se ha visto en el análisis pluviométrico, la estación de Barx, situada al sur de la provincia de Valencia, suele recoger grandes precipitaciones durante los meses de marzo y abril. En el año 2023 no se recogen apenas precipitaciones en estos meses, pero en el mes de febrero se recogen casi 200 mm que contribuyen a elevar el HCV estimado durante el mes de abril. También se registran altos niveles de HCV en la zona de Bicorp y Quesa, en el oeste de la comarca del Alt Palancia, cerca del límite con Teruel, y en la parte norte de la provincia de Castellón.

Las zonas en las que se registra un menor nivel de HCV son las del interior de la provincia de Valencia, principalmente en las comarcas dels Serrans, la Plana d'Utiel y la Vall de Cofrents. También se puede observar cómo generalmente las laderas de orientación norte tienen un mayor nivel de HCV que las de orientación sur, debido a que estas últimas reciben mayor cantidad de luz solar en el hemisferio norte y se calientan más, lo que favorece la evaporación de la humedad. Estas diferencias se pueden ver el mapa 13.




Mapa 13: Detalle del HCV estimado con la ecuación nueva para el día 05/04/2023. Fuente: elaboración propia.

Según técnicos del SIGIF cuando el HCV está por debajo de 80 o cerca de este, valores que se corresponden con los píxeles de color rojo, el riesgo de incendio y la velocidad de propagación de este pueden aumentar exponencialmente, por lo que resulta conveniente tener controladas estas zonas.

Los valores de HCV predichos por el modelo nuevo son, en general, ligeramente mayores que los que se obtenían con la ecuación original. Las zonas en las que mayor diferencia positiva hay entre el modelo nuevo y el antiguo son las zonas costeras y el norte de la provincia de Alicante, donde los valores predichos por la ecuación nueva son más altos que los predichos por la ecuación original. Estas diferencias se pueden ver en el mapa 14.

El caso contrario se observa en algunas zonas del interior del piso mesomediterráneo, donde se observa que el modelo nuevo genera valores predichos más bajos de los que se obtenían con la ecuación antigua. Estas diferencias negativas se concentran en la zona de Montanejos y en el noroeste de la provincia de Valencia, especialmente en la comarca de Els Serrans.



Mapa 14: Diferencia entre valores predichos de HCV en el modelo nuevo y el modelo original para el 05/04/2023. Fuente: elaboración propia.

Los 2 modelos se han validado sobre un conjunto de estaciones en las que se han recogido datos de HCV para una fecha cercana al 5 de abril de 2023. Los valores de HCV de ambas capas ráster se han extraído utilizando la herramienta *Point Sampling Tool* en QGIS. El resultado de la validación se puede ver en la tabla 19.

Parcela	Fecha	HCV	HCV_v1	HCV_new	RMSE_v1	RMSE_new
36 (Gandia Umbria)	04/04/2023	117,23	108,48	<b>120,83</b>	18,74	12,11
77 (Villalonga)	04/04/2023	129,71	89,55	<b>102,24</b>		
85 (Altea)	04/04/2023	106,11	101,59	<b>103,22</b>		
87 (Altea)	04/04/2023	109,75	83,04	<b>103,83</b>		
91 (Requena)	03/04/2023	92,15	<b>91,16</b>	87,05		
91 (Requena)	11/04/2023	85,85	91,16	<b>87,05</b>		
92 (Buñol)	03/04/2023	75,94	96,29	<b>89,82</b>		
92 (Buñol)	11/04/2023	65,24	96,29	<b>89,82</b>		
93 (Llombai)	03/04/2023	94,85	91,10	<b>91,15</b>		
93 (Llombai)	11/04/2023	97,34	91,10	<b>91,15</b>		
107 (Villargordo)	03/04/2023	80,26	79,41	<b>79,99</b>		
107 (Villargordo)	11/04/2023	72,41	<b>79,41</b>	79,99		
110 (Gandia Parpalló)	04/04/2023	112,88	119,81	<b>113,12</b>		
117 (Montanejos)	30/03/2023	78,18	108,80	<b>95,77</b>		

Tabla 19: Validación de los 2 modelos respecto a los valores reales de HCV. Fuente: elaboración propia.



El RMSE muestra que el nuevo modelo funciona mejor que el antiguo para esa fecha en concreto, alcanzando un valor de 12,1, que es un valor bastante bueno teniendo en cuenta que estamos comparando el HCV estimado para el 05/04/2023 con el HCV observado en distintas fechas cercanas. En casi todas las estaciones, el valor del HCV estimado por el nuevo modelo se acerca más al valor real que el predicho por el modelo original.



## 5. Conclusiones

En este proyecto se ha realizado un análisis sobre la influencia que tiene el cambio en el patrón de precipitaciones y aumento de temperaturas ocurrido en los años 2022 y 2023 en los valores observados de HCV y en los modelos de predicción implementados en el SIGIF, los cuales fueron desarrollados por el grupo de investigación CGAT-UPV al que pertenece el tutor de este proyecto. Dichos modelos utilizan datos meteorológicos, espectrales y topográficos para predecir los valores de HCV en toda la superficie forestal de la Comunitat Valenciana y fueron entrenados usando datos de campo recogidos durante los años 2020 y 2021. Todo ello se ha realizado para actualizar los modelos de predicción del SIGIF, teniendo en cuenta la información de campo obtenida en los años 2022 y 2023.

Junto a estos análisis, se ha efectuado un estudio puntual de precipitación y temperatura para el periodo 2010-2023 en distintos observatorios de la Comunitat Valenciana, para poder ver como el cambio climático ha modificado estas variables meteorológicas en los últimos años. Este análisis indica que se mantiene una cantidad de precipitación parecida durante todo el periodo, pero se observa un aumento en la variabilidad pluviométrica en los últimos años, alternando años muy secos con años bastante húmedos, donde la precipitación llega a ser más del doble de la obtenida en el año anterior. En cuanto a la temperatura, los resultados han mostrado un aumento sostenido de esta en todas las estaciones para el periodo estudiado.

Para crear los nuevos modelos de predicción de HCV se ha actualizado una parte de la metodología del SIGIF que obtiene datos espectrales de Sentinel-2, mejorando filtros para eliminar valores anómalos e interpolando datos entre fechas para cada punto de muestreo y fecha mediante código Python. También, se ha creado una base de datos meteorológicos para poder usar los modelos en los años 2022 y 2023 en las parcelas donde se han observado datos de HCV en campo y poder calcular errores de predicción.

Se ha evaluado el comportamiento de dichos modelos de predicción de HCV entrenados con datos de los años 2020-2021, calculando errores en parcelas donde se han obtenido valores de HCV medidos en campo en algunas fechas de los años 2022 y 2023. Al validar con dichos datos más recientes se ha obtenido un RMSE más elevado que el que se obtuvo al validar estas ecuaciones con datos de HCV del periodo 2020-2021, lo que indica que estos modelos no se adecuan del todo a la evolución actual de la HCV, por lo que se ha decidido generar nuevos modelos que se adapten mejor a los datos de HCV del periodo 2022-2023. En estos modelos, se ha modificado la variable de precipitación acumulada, pasando a calcular el logaritmo neperiano de la precipitación acumulada, lo que mejora la predicción del HCV en momentos de precipitación elevada.

Estas nuevas ecuaciones, una por cada piso bioclimático y modelo de combustible, se adaptan mejor al comportamiento del HCV en el periodo 2022-2023, obteniendo un RMSE más reducido en la mayoría de los puntos de muestreo. En el piso G1S (litoral y matorral) se pasa de un RMSE medio de 18,8 a uno de 13,3 y en el piso G1T (litoral y arbolado) se pasa de 25,5 a 12,4. Las parcelas de Gandía presentan un error más elevado en estas ecuaciones, por lo que se ha calculado otro modelo centrado en estas parcelas que mejora los resultados.

En las parcelas del interior también disminuyen los errores, pasando de un RMSE medio en el piso G2T (interior y arbolado) de 18,0 a 11,0 y en el piso G2S (interior y matorral) de 17,4 a 15,5. Este último modelo es el que menos disminuye el RMSE, presentando errores más elevados en distintos puntos geográficos como la zona de Yatova-Dos Aguas. Para esta zona también se ha generado un nuevo modelo que mejora los resultados de forma local.



Los valores de HCV han ido descendiendo de forma continua en el periodo 2021-2023, de la misma forma que las temperaturas han subido también en ese periodo, lo que provoca un aumento en la evaporación del agua, que reduce el contenido de humedad de la vegetación. También se ha comprobado cómo puede fluctuar la media ponderada del HCV según las especies, observándose una gran variabilidad en especies de matorral de bajo porte como *Rosmarinus officinalis* y una variabilidad reducida en especies de arbolado como *Pinus halepensis* o *Pinus pinaster*, que suelen mantener un valor constante de HCV a lo largo del año.

Se han generado 3 mapas de HCV en toda la superficie forestal de la Comunitat Valenciana para comparar los nuevos modelos creados en este proyecto con los modelos antiguos en una fecha de primavera del año 2023. El error cometido con la predicción del nuevo modelo en dicha fecha respecto a datos tomados en campo en fechas cercanas ha alcanzado un valor de  $RMSE=12,1$ , que es un valor bastante bueno teniendo en cuenta que los valores de campo pueden variar en una misma fecha entre diferentes plantas de una misma parcela y además el valor de la Fracción de Cobertura de las especies se ha obtenido de manera visual para calcular el promedio ponderado de HCV en cada parcela. Además, dicho error es similar al RMSE que alcanzan los modelos de predicción en los datos de entrenamiento, los cuales pueden verse en el anexo A de este trabajo.

### 5.1. Posibles mejoras

Como se ha visto en este proyecto, al validar con datos más recientes modelos entrenados con datos antiguos se producen errores, por lo que sería recomendable aumentar el número de datos de entrenamiento para añadir consistencia al modelo. Además, debido a que el cambio climático continúa modificando los condicionantes meteorológicos, será necesario realizar ajustes en el futuro en lo referente a las variables meteorológicas.

También sería conveniente explorar la utilización de datos espectrales provenientes de otros satélites como Landsat 8 o Sentinel-3, que a pesar de tener menor resolución espacial que Sentinel-2, posee un radiómetro con el que toma la temperatura en superficie de la cubierta terrestre.

Se debería usar una metodología más precisa para calcular la Fracción de Cobertura de las especies en cada parcela forestal.

Se debería explorar con detalle los cambios que puede producir la actualización de valores medios de índices espectrales en los modelos de predicción. A este respecto, se ha hecho una primera comparativa la cual se presenta en el anexo B.



## 6. Presupuesto

<b>DESARROLLO DEL TRABAJO</b>		
CONCEPTO	UNIDADES	PRECIO (€/h)
Analista y programador	1	39,11
Ordenador gráfico con monitor de 23" y periféricos	1	0,15
<b>Precio total (€)</b>		<b>39,26</b>

<b>SOFTWARE</b>		
CONCEPTO	UNIDADES	PRECIO (€)
Visual Studio Code (Python)	1	0,00
QGis	1	0,00
Statgraphics XVIII	1	30,00(licencia estudiante 6 meses)
RStudio (R)	1	0,00
Microsoft Office	1	69,00 (licencia personal 1 año)
<b>Precio total (€)</b>		<b>99,00</b>

<b>DIRECCIÓN DEL TRABAJO</b>		
CONCEPTO	UNIDADES	PRECIO (€/h)
Consultor senior especialista	1	49,05
Ordenador gráfico con monitor 21" y periféricos	1	0,14
<b>Precio total (€)</b>		<b>49,19</b>

<b>IMPUTACIÓN DE HORAS AL ESTUDIO</b>	
CONCEPTO	DEDICACIÓN (h)
Desarrollo del proyecto	300
Dirección del proyecto	70

<b>COSTE SUBTOTAL</b>		
CONCEPTO	Precio (€/h)	Precio total (€)
Desarrollo del proyecto	39,26	11788,00
Dirección del proyecto	49,19	3.443,30
Software	-	99,00
<b>Precio total (€)</b>		<b>15320,30</b>

**SUBTOTAL.....15.320,30 €**

IVA 21%.....3217,26 €

**PRESUPUESTO GENERAL.....18.537,56 €**

Asciende el presupuesto general del proyecto al total de DIECIOCHO MIL QUINIENTOS TREINTA Y SIETE EUROS CON CINCUENTA Y SEIS CÉNTIMOS (18.537,56 €).



## 7. Bibliografía



- Arcos, M.A., Edo-Botella, R., Balaguer-Beser, Á., & Ruiz, L.Á. (2023). Analyzing Independent LFM Empirical Models in the Mid-Mediterranean Region of Spain Attending to Vegetation Types and Bioclimatic Zones. *Forests*, 14, 1299. <https://doi.org/10.3390/f14071299>
- Clarke, B., Otto, F., Stuart-Smith, R., & Harrington, L. (2022). Extreme weather impacts of climate change: an attribution perspective. *Environmental Research: Climate*, 1(1).
- Costa, M. (1982). Pisos bioclimáticos y series de vegetación en el área valenciana. *Cuadernos de Geografía*, 31, 129-142. [https://www.uv.es/cuadernosgeo/CG31\\_129\\_142.pdf](https://www.uv.es/cuadernosgeo/CG31_129_142.pdf)
- Cunill Camprubi, A., González-Moreno, P., Bonet, J. A., & de Caceres, M. (2022). Live fuel moisture content mapping in the Mediterranean Basin using random forests and combining MODIS spectral and thermal data. *Remote Sensing*, 14(13), 3162. <https://doi.org/10.3390/rs14133162>
- Driscoll, D., Lindenmayer, D.B., Bennett, A.F., Bode, M., Bradstock, R.A., Cary, G.J., Clarke, M.F., Dexter, N., Fensham, Rod., Friend, G., Gill, M., James, S., Kay, G., Keith, D.A., Macgregor, C., Russell-Smith, J., Salt, D., Watson, J.E.M., Williams, R.J., York, A. (2010). Fire management for biodiversity conservation: Key research questions and our capacity to answer them. *Biological Conservation*, 143(9), 1928-1939.
- Freire Quintanilla, K.G. (2019). Estimación de la humedad del combustible vivo usando imágenes Sentinel-2 en parcelas forestales de la Comunidad Valenciana. Universitat Politècnica de València. <http://hdl.handle.net/10251/164634>
- Giorgi, F., & Lionello, P. (2008). Climate change projections for the Mediterranean region. *Global and Planetary Change*, 63(2-3), 90-104. <https://doi.org/10.1016/j.gloplacha.2007.09.005>
- Ji, M., Fan, J., Li, T., Zhao, X., & Ai, B. (2010). Research on visualized data quality control methods of ground object spectrum in Yanzhou mining area. In *Proceedings of the 2nd International Conference on Computer Engineering and Technology*, Chendu, China (pp. 457-462).
- Moritz, M.A.; Batlloria, E.; Bradstock, R.A.; Gill, A.M.; Handmer, J.; Hessburg, P.F.; Leonard, J.; McCaffrey, S.; Odion, D.C.; Schoennagel, T.; Syphard, A.D. 2014. Learning to coexist with wildfire. *Nature*. 515(6):58-66. [https://lpfw.org/wp-content/uploads/2018/06/2014\\_Moritz-et-al\\_Learning-to-Coexist-with-Wildfire.pdf](https://lpfw.org/wp-content/uploads/2018/06/2014_Moritz-et-al_Learning-to-Coexist-with-Wildfire.pdf)
- Pachacama Vallejo, K.R. (2022). Modelización del contenido de humedad de combustible vivo en la Comunitat Valenciana usando índices espectrales extraídos de Sentinel-2 durante los meses de verano y otoño desde 2019 hasta 2021. Universitat Politècnica de València. <http://hdl.handle.net/10251/186774>
- Pendergrass, Angeline & Knutti, Reto & Lehner, Flavio & Deser, Clara & Sanderson, Benjamin. (2017). Precipitation variability increases in a warmer climate. *Scientific Reports*.
- Quan, X., Yebra, M., Riaño, D., He, B., Lai, G., & Liu, X. (2021). Global fuel moisture content mapping from MODIS. *International Journal of Remote Sensing*. <https://www.sciencedirect.com/science/article/pii/S0303243421000611>



- Rothermel, R.C. (1972). A Mathematical Model for Predicting Fire Spread in Wildland Fuels, Vol. 115. Intermountain Forest & Range Experiment Station, Forest Service, US Department of Agriculture, Ogden.
- Scott, J. Y., & Burgan, R. (2005). Standard Fire Behavior Fuel Models: A Comprehensive Set for Use with Rothermel's Surface Fire Spread Model. United States Department of Agriculture, Forest Service, Rocky Mountain Research Station, General Report RMRS-GTR-153.
- Sharma, P. K., Kumar, D., & Srivastava, H. S. (2018). Assessment of different methods for soil moisture estimation: A review. *Journal of Remote Sensing*, 12(3), 256-273. [https://www.researchgate.net/publication/325568808\\_Assessment\\_of\\_Different\\_Methods\\_for\\_Soil\\_Moisture\\_Estimation\\_A\\_Review](https://www.researchgate.net/publication/325568808_Assessment_of_Different_Methods_for_Soil_Moisture_Estimation_A_Review)
- Yebra, M., Dennison, P.E., Chuvieco, E., Riaño, D., Zylstra, P., Hunt, E.R., Danson, F.M., Qi, Y., 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, 455–468. <https://www.sciencedirect.com/science/article/pii/S0034425713001831>



## 8. Cartografía




ESTIMACION DE HCV PARA EL 05/04/2023 UTILIZANDO LA ECUACIÓN NUEVA DE MATORRAL	
Nombre: Javier Urrecho Torres	Fecha: septiembre de 2024
Sistema de referencia: ETRS89 UTM Zona 30N	Escala: 1:2.000.000
Nº plano: 1	Firma:
	
<b>ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA GEODÉSICA CARTOGRÁFICA Y TOPOGRÁFICA</b>	

600000

700000

800000

900000




600000

700000

800000

900000





**ESTIMACION DE HCV PARA EL 05/04/2023  
UTILIZANDO LA ECUACIÓN ORIGINAL DE  
MATORRAL**

Nombre: Javier Urrecho Torres	Fecha: septiembre de 2024
Sistema de referencia: ETRS89 UTM Zona 30N	Escala: 1:2.000.000
Nº plano: 2	Firma:




**ESCUELA TÉCNICA SUPERIOR  
DE INGENIERÍA GEODÉSICA  
CARTOGRÁFICA Y TOPOGRÁFICA**



### DIFERENCIA ESTIMACIÓN DE HCV ENTRE ECUACIÓN NUEVA Y ECUACIÓN ORIGINAL PARA EL 05/04/2023

Nombre:	Fecha:
Javier Urrecho Torres	septiembre de 2024
Sistema de referencia:	Escala:
ETRS89 UTM Zona 30N	1:2.000.000
Nº plano:	Firma:
3	



**ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA GEODÉSICA CARTOGRÁFICA Y TOPOGRÁFICA**

## Anexo A

### Estadísticos de los nuevos modelos con los datos de entrenamiento

#### Piso G1S




Imagen 1: Captura en Statgraphics del nuevo modelo del piso G1S, con valores de error y gráfica de observados vs predichos. Fuente: elaboración propia.

La ecuación tiene un R-Cuadrado ajustado del 55,0 % y un error estándar del estimador de 13,6, valores parecidos a los que obtenía la ecuación original. Ambos datos indican que la ecuación funciona razonablemente bien sobre los datos de entrenamiento, pero hay que comprobar que tal se comportan sobre los datos de validación. En la imagen 1 se puede ver como la relación entre valores observados y valores predichos se acerca a la situación ideal.



Piso G1T




Imagen 2: Captura en Statgraphics del nuevo modelo del piso G1T, con valores de error y gráfica de observados vs predichos. Fuente: elaboración propia.

La ecuación tiene un R-Cuadrado ajustado del 54,7%, lo que indica que la ecuación explica el 54,7% de la variabilidad del HCV, por lo que se adapta razonablemente bien a los valores observados. El error estándar del estimador para este modelo es de 11,2, que es un valor relativamente bajo tratándose de predicciones de HCV. Estos valores son ligeramente peores a los obtenidos en las ecuaciones originales para el mismo piso bioclimático y modelo de combustible.



## Piso G2S




Imagen 3: Captura en Statgraphics del nuevo modelo del piso G2S, con valores de error y gráfica de observados vs predichos. Fuente: elaboración propia.

El R-cuadrado ajustado de este modelo llega al 28,5%, mientras que el error estándar del estimador es de 16,8. El R-cuadrado es bastante bajo y peor que el que se obtenía en las ecuaciones originales, lo que indica que puede haber problemas al utilizar esta ecuación. Sin embargo, esto se debe valorar después de validar el modelo con los datos del periodo 2022-2023.

En la imagen 3 se puede ver como los errores aumentan cuando los valores observados son altos, ya que los valores predichos no crecen de la misma forma

Piso G2T




Imagen 4: Captura en Statgraphics del nuevo modelo del piso G2T, con valores de error y gráfica de observados vs predichos. Fuente: elaboración propia.

El modelo para este piso funciona mejor que el anterior, con un R-cuadrado del 55,0%, y un error estándar del estimador de 11,4, valores parecidos a los que se obtuvieron en el entrenamiento de la ecuación original. En la grafica de valores observados y valores predichos (imagen 4) se puede ver como los valores se vuelven a agrupar en torno a la recta de mejor ajuste, lo que indica un resultado con menos errores.

## Ecuación para Gandía




Imagen 5: Captura en Statgraphics del nuevo modelo para Gandía, con valores de error y gráfica de observados vs predichos. Fuente: elaboración propia.

El valor del R-cuadrado es del 59,4% y el error estándar del estimador es de 10,2, lo que indica que la ecuación funciona bien sobre los datos de entrenamiento. Este modelo funciona mejor que los que se han generado anteriormente, pero también hay que tener en cuenta que es un modelo probado localmente que tiene utilidad en Gandía y alrededores, mientras que los otros modelos trabajaban sobre toda la Comunitat Valenciana.

## Ecuación para matorral de Gandía




Imagen 6: Captura en Statgraphics del nuevo modelo para matorral de Gandía, con valores de error y gráfica de observados vs predichos. Fuente: elaboración propia.

Este modelo obtiene un R-cuadrado del 59,6% y un error estándar del estimador de 9,4, valores parecidos a los que se observaban en la ecuación anterior, aunque ligeramente mejores. Sin embargo, para ver cual se adecua mejor a las parcelas de Gandía y alrededores es necesario validar con todos los puntos de muestreo cercanos a Gandía que presenten datos para el periodo 2022-2023.



## Ecuación para Yatova-Dos Aguas




Imagen 7: Captura en Statgraphics del nuevo modelo para Yatova-Dos Aguas, con valores de error y gráfica de observados vs predichos. Fuente: elaboración propia.

Este modelo presenta un R-cuadrado ajustado de 59,6% y un error estándar del estimador de 10,2, valores parecidos a los obtenidos en las anteriores ecuaciones que indican que el modelo funciona correctamente sobre los puntos de muestreo utilizados como datos de entrenamiento. En la gráfica que compara valores observados y predichos (imagen 7), los puntos se concentran a lo largo de la recta de mejor ajuste, indicando que los errores son bajos.

## Anexo B

### Efecto sobre el HCV de utilizar medias actuales o antiguas

El calentamiento global ha influido significativamente en los índices espectrales, como el NDVI y el EVI, modificando sus patrones observados. El incremento en la temperatura media global, junto con la intensificación de fenómenos meteorológicos extremos, como las sequías prolongadas y las lluvias torrenciales, han afectado la estructura y función de los ecosistemas vegetales. Estos factores climáticos alteran la productividad y la distribución de la vegetación, lo que se puede ver reflejado en las fluctuaciones temporales de estos índices espectrales.


En este proyecto se han calculado los valores espectrales medios en cada punto de muestreo para el periodo 2022-2023, pero los valores espectrales medios utilizados en las ecuaciones de entrenamiento pertenecen al periodo 2020-2021, por lo que se ha querido analizar la repercusión sobre los resultados de utilizar los índices de un periodo o de otro. En la mayoría de los casos, al utilizar las medias de los índices espectrales del periodo 2020-2021 se obtiene un menor error, debido a que los coeficientes de la ecuación v1 están adaptados a esas medias.

#### Piso G1S

Parcela	Código_UPV	RMSE_NewMed_G1S	RMSE_ORIG_G1S
Betera	7	15,9	<b>15,3</b>
Gandia_Parpalló	40	26,2	<b>24,7</b>
Gilet	305	<b>15,0</b>	15,2

Tabla 20: RMSE en las parcelas de matorral del piso G1 según el uso de las medias espectrales actuales o antiguas. Fuente: elaboración propia.

Las parcelas pertenecientes al grupo G1S no presentan grandes diferencias en cuanto al RMSE dependiendo de si se utilizan medias u otras, resultando más apropiada la utilización de las medias espectrales antiguas en Bétera y Gandía, pero empeorando ligeramente el resultado al utilizarlo en Gilet.



Gráfica 53: Evolución del HCV en Bétera según el uso de las medias espectrales actuales o antiguas. Fuente: elaboración propia.

El valor medio de cada índice espectral es una constante en todo el periodo, por lo que la utilización de este dato como variable contribuye a subir o bajar en el eje Y a todo el conjunto de datos previstos, pero no provoca diferencias en cuanto a la magnitud de las variaciones previstas del HCV entre una fecha u otra.


La parcela de Bétera presenta valores previstos de HCV más bajos al emplear la ecuación con las medias espectrales antiguas, acercándose más a los valores reales de HCV que la ecuación que utilizaba las medias espectrales actuales, pero las diferencias entre ambas ecuaciones no son significativas en las parcelas de este modelo de combustible y piso bioclimático.

#### Piso G1T

Parcela	Código_UPV	RMSE_NewMed_G1T	RMSE_ORIG_G1T
36_Gandía umbria	36	13,6	15,3
Desert Palmes	121	27,7	35,7


Tabla 21: RMSE en las parcelas de arbolado del piso G1 según el uso de las medias espectrales actuales o antiguas. Fuente: elaboración propia.

Las parcelas del grupo G1T presentan un mejor comportamiento al utilizar la ecuación con medias espectrales actuales, reduciendo el RMSE tanto en Gandía como en el punto de Desert Palmes. El resultado mejora especialmente en Desert Palmes, donde pasa de un RMSE de 35,7 a uno de 27,7, que aun así sigue evidenciando un elevado error en esta parcela.



Gráfica 54: Evolución del HCV en Gandía Umbria según el uso de las medias espectrales actuales o antiguas. Fuente: elaboración propia.

Al utilizar las medias espectrales del periodo 2020-2021 se obtienen unos valores predichos más elevados de los que se obtienen con las medias actuales. Como esa ecuación ya subestima los valores reales de HCV, la utilización de las medias antiguas genera un resultado peor para esta parcela. Como se comenta en este estudio, el año 2022 fue muy lluvioso en la comarca de Gandía, resultando en que las medias de los índices espectrales actuales son mayores que las obtenidas en el periodo 2020-2021 para esta misma parcela.



Gráfica 55: Evolución del HCV en Desert Palmes según el uso de las medias espectrales actuales o antiguas. Fuente: elaboración propia.

En el caso de Desert Palmes, la utilización de las medias antiguas también empeora el resultado, aunque en este caso al revés, aumentando el valor predicho y alejándolo de los valores reales. Al contrario que en el caso de Gandía, en Desert Palmes las medias de los índices espectrales han disminuido, posiblemente debido a la disminución de las lluvias y al aumento de las temperaturas en esta zona.


#### Piso G2T

Parcela	Código UPV	RMSE_NewMed_G2T	RMSE_ORIG_G2T
85_Altea-Jalón (Bernia Umbria)	85	19,82	25,96
Ayora (La Hunde)	141	23,80	16,09
Biar	114	20,48	15,68
Enguera	143	22,30	20,24
Montanejos	117	26,78	21,02
Muela de Cortes	112	17,74	15,25
Torre maçanes 2022	113	18,14	10,68
Villargordo	107	49,39	19,16


Tabla 22: RMSE en las parcelas de arbolado del piso G2 según el uso de las medias espectrales actuales o antiguas. Fuente: elaboración propia.

Los resultados en las parcelas del grupo G2T muestran que, de forma general, la utilización de las medias espectrales del periodo de entrenamiento (2020-2021) genera un RMSE menor que el que se registra al utilizar las medias del periodo de estudio y validación (2022-2023).

La utilización de estas medias antiguas disminuye parte del error sistemático del modelo, como se puede observar en las gráficas de parcela como Ayora o Villargordo (graficas .....). Con ellas se obtienen unos valores previstos más bajos, que son más cercanos a los valores reales del HCV. Como las medias espectrales son constantes, no afectan a la variabilidad de los valores predichos, pero suben o bajan en el eje Y todo el conjunto de valores.



Gráfica 56: Evolución del HCV en Ayora según el uso de las medias espectrales actuales o antiguas. Fuente: elaboración propia.



Gráfica 57: Evolución del HCV en Villargordo según el uso de las medias espectrales actuales o antiguas. Fuente: elaboración propia.

En la ecuación para parcelas de arbolado del piso mesomediterráneo se utiliza el índice TCARI multiplicado por un coeficiente negativo, por lo que a más alto sea el valor del índice más bajo serán los valores predichos de HCV. El periodo 2020-2021 fue, en general, más frío que el periodo 2022-2023 y también más húmedo en ciertas partes del interior de la provincia de Valencia, por lo que es normal que los valores de TCARI hayan descendido en el periodo más actual.



## Anexo C

### Scripts

#### getSpectralData2.py

```
def getSpectralData2(self, date_start, date_end, year):
    ee.Initialize()
    puntos_muestreo =
geemap.shp_to_ee(os.path.join(self.geom_folder,'101puntos_4326.shp'),encoding='utf-8') #
ISO-8859-1, utf-8
    #filtra la colección de imagenes según fecha y situación de los puntos
    sent2a=ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED").filterDate(date_start,
date_end).filterBounds(puntos_muestreo)
    #calculo de indices
    col=sent2a.map(CalcularARVI)
    col=col.map(CalcularVARI)
    col=col.map(CalcularTCARI)
    col=col.map(CalcularOSAVI)
    col=col.map(CalcularTCARI_OSAVI)
    col=col.map(CalcularNMDI)
    col=col.map(CalcularMSI)
    col=col.map(CalcularEVI)
    col=col.map(CalcularVgreen)
    col=col.map(CalcularSLA)
    col=col.map(CalcularMCARI)
    col=col.map(CalcularMCARI_OSAVI)
    col=col.map(CalcularNDVI)
    col=col.map(CalcularNDWI)
    col=col.map(CalcularRVI)
    col=col.map(CalcularSAVI)
    col=col.map(CalcularNDMI)
    #funcion para calcular el promedio del índice sobre cada punto)
    def reduce_function(image):
        date = image.date().format('YYYY-MM-dd')
        return image.reduceRegions(
            collection=puntos_muestreo,
            reducer=ee.Reducer.mean(),
            scale=self.res #20
        ).map(lambda feature: feature.set('date', date))
    results = col.map(reduce_function).flatten().filter(ee.Filter.notNull(['NDVI']))
    # divide el resultado en intervalos más pequeños y aplica la función de reducción
    results_list = results.toList(results.size())
    num_features = results.size().getInfo()
    intervalo = 4800
    # lista para almacenar los DataFrames intermedios
    dfs_list = []
    for start in range(0, num_features, intervalo):
        end = min(start + intervalo, num_features)
        subset_results = results_list.slice(start, end)
        # convierte los resultados a un DataFrame de pandas
        subset_df = geemap.ee_to_pandas(ee.FeatureCollection(subset_results))
        subset_df.to_excel(os.path.join(self.my_results_path, "espectral", "datos_gee",
f"index_values_{start}_{end}.xlsx"), index=True)
```



```
dfs_list.append(subset_df)
combined_df = pd.concat(dfs_list)
# guarda el DataFrame combinado en un archivo Excel final
combined_df.to_excel(os.path.join(self.my_results_path, "espectral", "datos_gee"
,year+".xlsx"), index=True)
```

### **filterOutlier\_v2.py**

```
def filterOutlier_v2(self):
    spectral_data = os.path.join(self.my_results_path, "espectral", "datos_gee",
"filtered1_gee_data.xlsx")
    df = pd.read_excel(spectral_data)
    # busca nombres únicos de lugar
    lugares_unicos = df['PuntoMue_1'].unique()
    def eliminar_atipicos_iqr(data, tamaño_ventana=5, umbral=1.5):
        data_filtrada = data.copy()
        for i in range(tamaño_ventana, len(data) - tamaño_ventana + 1):
            ventana = data.iloc[i - tamaño_ventana:i + tamaño_ventana + 1]
            # define los límites superior e inferior según parámetro
            Q1 = np.percentile(ventana['NDVI'], 25)
            Q3 = np.percentile(ventana['NDVI'], 75)
            IQR = Q3 - Q1
            límite_inferior = Q1 - umbral * IQR
            límite_superior = Q3 + umbral * IQR
            # filtra las filas con el NDVI situado entre ambos límites
            if data['NDVI'].iloc[i] < límite_inferior or data['NDVI'].iloc[i] > límite_superior:
                data_filtrada.loc[data.index[i], 'NDVI'] = np.nan
            # filtra filas con el NDVI erróneo
            data_filtrada = data_filtrada.dropna(subset=['NDVI'])
        return data_filtrada
    df_resultado = pd.DataFrame()
    # se realiza el proceso para cada parcela
    for lugar in lugares_unicos:
        df_lugar = df[df['PuntoMue_1'] == lugar]
        df_filtrado = eliminar_atipicos_iqr(df_lugar)
        # se juntan los resultados en un dataframe final
        df_resultado = pd.concat([df_resultado, df_filtrado])
    ruta_exportacion = os.path.join(self.my_results_path, "espectral", "datos_gee",
"filtered2_gee_data.xlsx")
    df_resultado.to_excel(ruta_exportacion, index=False)
    print("Filtrado de outliers realizado")
```



### interpolate\_data.py

```
def interpolateSpectralData(self):
    df = pd.read_excel(os.path.join(self.my_results_path, "espectral", "datos_gee",
"filtered2_gee_data.xlsx"))
    # convierte la columna 'date' a tipo datetime
    df['date'] = pd.to_datetime(df['date'], errors='coerce')
    # crea un DataFrame con todas las combinaciones de estación y fecha
    estaciones = df['PuntoMue_1'].unique()
    fechas_completas = pd.date_range(start=df['date'].min(), end=df['date'].max(), freq='D')
    combinaciones = pd.MultiIndex.from_product([estaciones, fechas_completas],
names=['PuntoMue_1', 'date'])
    df_completo = pd.DataFrame(index=combinaciones).reset_index()
    # combina el DataFrame completo con tus datos originales
    df_interpolado = pd.merge(df_completo, df, on=['PuntoMue_1', 'date'], how='left')
    df_interpolado.sort_values(['PuntoMue_1', 'date'], inplace=True)
    columnas_interpolacion = ['ARVI', 'EVI', 'MCARI', 'MCARI_OSAVI', 'MSI', 'NDMI', 'NDVI',
'NDWI', 'NMDI', 'OSAVI',
'RVI', 'SAVI', 'SLA', 'TCARI', 'TCARI_OSAVI', 'VARI', 'Vgreen']
    # interpola los valores faltantes en cada columna
    for columna in columnas_interpolacion:
        df_interpolado[columna] =
df_interpolado.groupby('PuntoMue_1')[columna].transform(lambda x: x.interpolate())
    columnas_salida = ['PuntoMue_1', 'date'] + columnas_interpolacion
    # guarda solo las columnas seleccionadas en un nuevo DataFrame
    df_salida = df_interpolado[columnas_salida]
    # guarda el resultado en un nuevo archivo Excel
    df_salida.to_excel(os.path.join(self.my_results_path, "espectral", "datos_gee",
"interpolated_data.xlsx"), index=False)
    print("interpolación realizada")
```



### calculate\_media.py

```
import pandas as pd
import numpy as np
# lee el archivo original con HCV por especie
df = pd.read_excel("G:/TFM/LFM_22_23.xlsx")
# busca combinaciones de parcela y fecha
combinaciones_unicas = df[['Punto de muestreo', 'Fecha']].drop_duplicates()
# dataframe donde se almacenan los resultados
df_resultado = pd.DataFrame(columns=df.columns)
for idx, row in combinaciones_unicas.iterrows():
    punto_muestreo = row['Punto de muestreo']
    fecha = row['Fecha']
    # filtrar el archivo original por punto_muestreo y fecha
    df_subset = df[(df['Punto de muestreo'] == punto_muestreo) & (df['Fecha'] == fecha)]
    valores_fcc = df_subset['FCC'].values.astype(float)
    valores_humedad = df_subset['Humedad'].values.astype(float)
    #calcula la media ponderada
    media_ponderada = np.sum(valores_humedad * valores_fcc) / np.sum(valores_fcc)
    #crea la nueva fila con el valor de la media ponderada
    nueva_fila_ponderada = pd.DataFrame({'Punto de muestreo': [punto_muestreo],
                                         'Fecha': [fecha],
                                         'Especie': ['MediaPonderada'],
                                         'FCC': ["NA"],
                                         'Peso bruto': [np.nan],
                                         'Peso bote': [np.nan],
                                         'Peso húmedo': [np.nan],
                                         'Peso seco': [np.nan],
                                         'Bote': [np.nan],
                                         'Humedad': [media_ponderada]})
    # añade la fila
    df_resultado = pd.concat([df_resultado, df_subset, nueva_fila_ponderada,
                              nueva_fila_arbolado, nueva_fila_matorral], ignore_index=True)
df_resultado.sort_values(by=['Fecha', 'Punto de muestreo'], inplace=True)
df_resultado.reset_index(drop=True, inplace=True)
nombre_archivo_salida = "G:/TFM/HCV_calc_medias.xlsx"
# guarda el resultado en un excel
df_resultado.to_excel(nombre_archivo_salida, index=False)
print(f'Archivo "{nombre_archivo_salida}" creado exitosamente.')
```



### calculate\_t60.py

```
import pandas as pd
# periodos de tiempo (en días) sobre el que se quiere realizar el calculo
variable_a_calcular = [3, 7, 15, 30 ,60]
for element in variable_a_calcular:
    nombre_variable = "t"+str(element)
    archivo_excel = 'G:/TFM/meteo/results/MeanTemperature.xlsx'
    df = pd.read_excel(archivo_excel)
    # convertir la columna 'Fecha' a tipo datetime
    df['Fecha'] = pd.to_datetime(df['Fecha'], format='%d/%m/%Y')
    # crea la columna que representa la precipitación acumulada de los últimos días
    df[nombre_variable] = df.groupby('Lugar')['MeanTemperature'].rolling(window=element,
min_periods=1).mean().reset_index(level=0, drop=True)
    df[['Lugar','Fecha',nombre_variable]].to_excel
('G:/TFM/meteo/results/'+nombre_variable+'.xlsx', index=False, na_rep='None')
    print("ya esta: "+str(element))
```