

# WATER4CAST

## *Integrated Forecasting System for Water and the Environment*

*Plataforma que integra las predicciones meteorológicas, ecohidrológicas, agronómicas, medioambientales y de gestión de recursos hídricos.*

### Deliverable D4.1

## Evaluación mejorada de las necesidades de riego de los cultivos y estrés hídrico a partir de teledetección

### WP4 D4.1Tasks 4.1-4.2

Fecha (29/11/2022)

Project Acronym	WATER4CAST
Project Title	Integrated Forecasting System for Water and the Environment
Project Coordinator	Manuel Pulido & Félix Francés
Project Duration	01.01.2021 – 31.12.2023

Tipo de entregable		
R	Document, report	
DEM	Demonstrator, pilot, prototype, plan designs	
DEC	Websites, patents filing, press & media actions, videos, etc.	
OTHER	Software, technical diagram, etc.	

Nivel de diseminación		
PU	Público, en abierto.	
CO	Confidencial, restringido a un número de personas	
CI	Clasificado, secreto, cerrado a autores y revisores	

Deliverable No.	D4.1
Work Package	WP 4 - Agricultural forecasting
Task	T 4.1 - Use of time series for crop classification
	T4.2- Calculation of vegetation indices (VI) and Surface Energy Balance methods (SEB) to feed the irrigation scheduling model for different crops

Quality procedure			
Fecha	Versión	Revisores	Comentarios
20/01/2023	1	Miguel Ángel Jiménez Bello	Primera versión
29/11/2023	2	Alberto García Prats	Segunda versión del documento
29/11/2023	2	Juan Manuel Carricondo	Revisión
15/01/2024	2	Dariana Isamel Avila Velasquez	Revisión
	2	Héctor Macian Sorribes	Revisión

## Resumen ejecutivo

El paquete de trabajo 4 (en adelante WP4) tiene por objeto el uso de imágenes obtenidas de diferentes plataformas de teledetección, con el ánimo de mejorar las estimaciones de las necesidades de agua de riego y la detección de estrés hídrico, combinando éstas con predicciones meteorológicas. Siguiendo el plan de trabajo de la memoria científico-técnica del proyecto, el WP4 se divide en 5 Tareas. El presente *Deliverable* (D 4.1) desarrolla el nivel de ejecución y funcionamiento de las tareas 1 y 2 (T4\_01 y T4\_02 respectivamente). En un futuro *Deliverable* (D 4.2) se procederá a desarrollar el nivel de ejecución y funcionamiento de las tareas 3, 4 y 5 (T4\_03, T4\_04 y T4\_05 respectivamente).

La T4\_01 lleva por título “*Uso de series temporales para la clasificación de cultivos*” y tiene por objeto la identificación del cultivo existente en las parcelas previo a la determinación de las necesidades de riego. A efectos de clasificación de cultivos se ha aprovechado la alta resolución temporal (un pase cada 5 días) y espacial (píxel de 10m) de la constelación de satélites de la Agencia Espacial Europea *Sentinel 2* junto con la utilización de las técnicas de clasificación más novedosas basadas en inteligencia artificial, como son las “Redes Neuronales Bidireccionales” o los “Random Forest” para poder desarrollar un sistema de identificación de cultivos.

La T4\_02 lleva por título “*Cálculo de índices de vegetación (VI) y métodos de Balance Energético Superficial (SEB) para alimentar el modelo de programación de riego para diferentes cultivos*”.

Se han aplicado con éxito dos tipos generales de enfoques del uso de la teledetección para estimar la evapotranspiración (ET), en función si ésta se refiere a la estimación de las necesidades potenciales de agua requeridas por el cultivo (ETc) para los días anteriores al día de cálculo, o si se trata de obtener la evapotranspiración que realmente se ha observado desde el satélite (ETo). Cuando el objetivo es la estimación de las necesidades de riego de los días anteriores al día de cálculo, el primer paso es la estimación de los coeficientes de cultivo (Kc) a partir de índices de vegetación derivados de datos de reflectancia de la superficie (teledetección). Este método produce un mapa de Kc que refleja la etapa de crecimiento del cultivo y con el apoyo de datos de evapotranspiración de referencia (ETo) obtenidos de una estación meteorológica cercana, se pueden estimar las necesidades de agua del cultivo.

El segundo enfoque se usa para determinar la evapotranspiración real del cultivo (ETr) mediante teledetección, el cual requiere el empleo de modelos que calculen el calor latente como residuo del balance de energía superficial (SEB), para lo cual se requieren constelaciones que dispongan de banda térmica. La plataforma Landsat hoy en día genera imágenes de ETr, mediante el procedimiento SEB, ya procesadas y disponibles para los usuarios de manera gratuita y siendo totalmente automatizable su descarga. De esta forma se obtiene la ETr del cultivo y no la potencial como en el caso anterior.

Finalmente, el ratio ETr/ETc es un indicador del estrés hídrico de los cultivos.

# ÍNDICE

## Contents

<b>Resumen ejecutivo</b> .....	3
Lista de figuras.....	5
Lista de tablas.....	6
1. Antecedentes e introducción del documento.....	7
2. Alcance y objetivos .....	8
3. Metodología .....	8
3.1. Modulo T4_01.....	10
3.2. Modulo T4_02.....	12
4. Algoritmos para Identificación de cultivos.....	16
4.1. Creación de capas de entrenamiento y validación en la identificación de cultivos .....	16
4.2. Algoritmos de clasificación .....	16
4.2.1. Random Forest .....	16
4.2.2. Redes Neuronales .....	18
5. Modelos agronómicos para la determinación de Kc. ....	21
5.1. Mapas de Kc a partir de imágenes satelitales .....	21
6. Mecanismo de control en tiempo quasi real del estrés hídrico de los cultivos. ....	22
6.1. Surface energy balance algorithm for land (SEBAL).....	22
7. Resultados de la tarea WorkPackage 4 (T4_01 y T4_02). ....	23
7.1. T4_01 (CC.exe) .....	24
7.2. T4_02 (Shrotterm.exe) .....	25
7.3. T4_02 (CropWaterStress.exe).....	26
8. CONCLUSIONES .....	27
References .....	28

## Lista de figuras

Figure 1- Esquema general de funcionamiento del WP4 .....	10
Figure 2-Esquema general de funcionamiento del módulo T4_01 .....	11
Figure 3-Esquema general de funcionamiento del módulo T4_02 Shrotterm.exe para el cálculo de Kc .....	13
Figure 4-Esquema de funcionamiento de T4_02 CropWaterStress.exe .....	15
Figure 5-Estructura de una neurona LSTM .....	19
Figure 6-Etapas de LSTM. 1) Forget gate layer, 2) Input Gate, 3) Output Gate y 4) Estado de Celda Actualizado. ....	20
Figure 7- Balance de Energía en SEBAL (Fuente manual de SEBAL) .....	23
Figure 8- Mapa de Parcelas de interés con los cultivos de estudio agrupados de la comarca de la Ribera Baja .....	24
Figure 9-Parcelas clasificadas según la correcta o incorrecta clasificación de cultivos por parte del modelo predictivo Random Forest .....	24
Figure 10-Parcelas clasificadas según la correcta o incorrecta clasificación de cultivos por parte del modelo predictivo red neuronal Bi-LSTM .....	25
Figure 11- Coeficientes de cultivo Kc derivados de NDVI .....	25
Figure 12-Coeficientes de cultivo Kc derivados de NDVI por parcela .....	26
Figure 13- Estrés hídrico por UDA el 10 de julio de 2023 .....	26
Figure 14-Estrés hídrico por parcela el 10 de julio de 2023 .....	27

## Lista de tablas

Table 1- Fórmulas de Kc en función de NDVI.....	22
---	----

## 1. Antecedentes e introducción del documento

El paquete de trabajo 4 (en adelante WP4) tiene por objeto el uso de imágenes obtenidas de diferentes plataformas de teledetección, con el ánimo de mejorar las estimaciones de las necesidades de agua de riego y la detección de estrés hídrico, combinando éstas con predicciones meteorológicas. Siguiendo el plan de trabajo de la memoria científico-técnica del proyecto, el WP4 se divide en 5 Tareas. El presente Deliverable (D 4.1) desarrolla el nivel de ejecución y funcionamiento de las tareas 1 y 2 (T4\_01 y T4\_02 respectivamente). En un futuro Deliverable (D 4.2) se procederá a desarrollar el nivel de ejecución y funcionamiento de las tareas 3, 4 y 5 (T4\_03, T4\_04 y T4\_05 respectivamente).

La T4\_01 lleva por título “Uso de series temporales para la clasificación de cultivos” y tiene por objeto la identificación del cultivo existente en las parcelas previo a la determinación de las necesidades de riego. A efectos de clasificación de cultivos se ha aprovechado la alta resolución temporal (un pase cada 5 días) y espacial (píxel de 10m) de la constelación de satélites de la Agencia Espacial Europea Sentinel 2 junto con la utilización de las técnicas de clasificación más novedosas basadas en inteligencia artificial, como son las “Redes Neuronales Bidireccionales” o los “Random Forest” para poder desarrollar un sistema de identificación de cultivos.

La T4\_02 lleva por título “Cálculo de índices de vegetación (VI) y métodos de Balance Energético Superficial (SEB) para alimentar el modelo de programación de riego para diferentes cultivos”.

Se han aplicado con éxito dos tipos generales de enfoques del uso de la teledetección para estimar la evapotranspiración (ET), en función si ésta se refiere a la estimación de las necesidades potenciales de agua requeridas por el cultivo (ETc) para los días anteriores al día de cálculo, o si se trata de obtener la evapotranspiración que realmente se ha observado desde el satélite (ETo). Cuando el objetivo es la estimación de las necesidades de riego de los días anteriores al día de cálculo, el primer paso es la estimación de los coeficientes de cultivo (Kc) a partir de índices de vegetación derivados de datos de reflectancia de la superficie (teledetección). Este método produce un mapa de Kc que refleja la etapa de crecimiento del cultivo y con el apoyo de datos de evapotranspiración de referencia (ETo) obtenidos de una estación meteorológica cercana, se pueden estimar las necesidades de agua del cultivo.

El segundo enfoque se usa para determinar la evapotranspiración real del cultivo (ETr) mediante teledetección, el cual requiere el empleo de modelos que calculen el calor latente como residuo del balance de energía superficial (SEB), para lo cual se requieren constelaciones que dispongan de banda térmica. La plataforma Landsat hoy en día genera imágenes de ETr, mediante el procedimiento SEB, ya procesadas y disponibles para los usuarios de manera gratuita y siendo totalmente automatizable su descarga. De esta forma se obtiene la ETr del cultivo y no la potencial como en el caso anterior.

Finalmente, el ratio  $ETr/ETc$  es un indicador del estrés hídrico de los cultivos.

## 2. Alcance y objetivos

El objetivo principal del WP4 es utilizar las imágenes obtenidas de las diferentes plataformas de teledetección disponibles para mejorar la estimación de las necesidades de agua junto con las previsiones meteorológicas y la detección del estrés hídrico. Los objetivos específicos son:

1. Uso de series temporales para la clasificación de cultivos.
2. Cálculo de índices de vegetación (VI) para alimentar el modelo de programación de riego para diferentes cultivos.
3. Asimilación de las predicciones climáticas proporcionadas por diferentes servicios climáticos en el modelo de datos desarrollado.
4. Simulación del balance hídrico a través de modelos agrohídrológicos alimentados por imágenes satelitales.
5. Escalamiento de los resultados a diferentes escalas de gestión del agua.

En el presente D 4.1 se presentan los avances realizados en los puntos 1 y 2 del presente apartado.

## 3. Metodología

Las tareas, T4\_01 y T4\_02 de la memoria científico-técnica del proyecto se ha materializado en 3 “scripts” programados en lenguaje Python V3.x en el entorno Spyder V5.x y compilados en ejecutables .exe que son lanzados siguiendo el esquema general de funcionamiento descrito en la Figura 1, con el fin de generar la información que después se muestra en el visor web WATER4CAST. Cada ejecutable toma uno o varios archivos de entrada y con ellos, genera otros archivos de salida. Los archivos de entrada pueden ser datos de partida (datos físicos de la CHJ, SIGPAC...) o datos provenientes de otros procesos desarrollados en este WP4. Los ficheros de salida pueden ser a su vez resultados finales para mostrar en el visor WATER4CAST o resultados intermedios necesarios en otros procesos. El motivo de que la tarea se divida en 3 ejecutables no es otro que contemporizar la producción de ficheros necesarios hacia/desde los procesos que se describen en los diagramas de flujo. En los siguientes párrafos y con la ayuda de varios esquemas se muestra tanto el funcionamiento general del del WP4 así como el funcionamiento particular de los scripts denominados CC.exe (identificación de cultivos) para T4\_01 y Shrotterm.exe (obtención de Kc desde satélite) y CropWaterStress.exe (estrés hídrico) para T4\_02. A su vez, algunos de estos scripts pueden funcionar en tiempo *quasi* real cuando se trabaja con imágenes de satélite, a corto plazo (CP: 16 días), en subestacional (MP:55 días) o de forma estacional (LP: hasta 8 meses), lo cual se indica en cada caso junto al nombre del módulo. Por último, indicar que el esquema general del WP4 (Figura 1) está expresado en términos de script, entrada y salida de archivos de la Tarea con la que se interactúa, teniendo por objeto facilitar la comprensión global de la Tarea, mientras que en los esquemas particulares de los módulos CC.exe, Shrotterm.exe



y CropWaterStress.exe (Figuras 2 a 14), además se describe cada función de cálculo desarrollada en cada uno de ellos, teniendo por objeto la comprensión de los algoritmos aplicados en respuesta a los objetivos del proyecto.

La primera tarea que se desarrolla es T4\_01, responsable de la identificación de cultivos mediante teledetección e inteligencia artificial (IA), generando un fichero con el mapa vectorial de cultivos, exportable en formato shapefile (\*.shp) el cual puede ser cargado a un sistema de información geográfica (SIG). En estos momentos el módulo se ha desarrollado en dos partes, la primera de ellas se produce mediante un script implementado en la aplicación Google Earth Engine Code Editor y éste realiza la descarga de los valores de los píxeles de las series temporales de imágenes desde 2018 hasta 2022, ambos inclusive.

Con este código obtenemos los valores de reflectancia de cada una de las bandas de la constelación Sentinel 2, así como el índice de vegetación de las diferencias normalizadas (NDVI) y la desviación típica de este píxel frente al valor de sus píxeles colindantes como proxy de la entropía del NDVI. La segunda parte de T4\_01 se realiza mediante el Módulo CC.exe (Crop Classification) desarrollado en lenguaje de programación Python v3.x. El resultado de la clasificación de cultivos se entrega a los procesos siguientes de T4\_02 (Shrotterm.exe y CropWaterStress.exe) mediante capas vectoriales de formato shapefile obtenidos del Sistema Geográfico Nacional de Parcelas Agrícolas (SIGPAC). En un desarrollo futuro se podrán introducir las capas obtenidas mediante la T4\_01 para que sean empleadas directamente. La herramienta desarrollada se ha aplicado con éxito en la comarca de la Ribera Baja en Valencia y el resultado es parte del Trabajo Final de Máster titulado *“Identificación de cultivos mediante teledetección y técnicas de machine learning en el ámbito territorial de la comarca de la Ribera Baja, Valencia”*, desarrollado por David Cerezo Rebé en 2022 para la obtención del título de Ingeniero Agrónomo en la Escuela Técnica Superior de Ingeniería Agronómica y del Medio Natural de la UV, quedando pendiente su extensión a la totalidad del territorio.

En segundo lugar, se ejecutan en paralelo los scripts Shrotterm.exe y CropWaterStress.exe de la T4\_02 cuyo resultado son datos intermedios necesarios para el cálculo de necesidades de riego a CP: mapa de coeficientes de cultivo ( $K_c$ ) derivado de técnicas de teledetección y el cálculo del estrés hídrico mediante el cálculo de la evapotranspiración del cultivo ( $E_{To} \times K_c = E_{Tc}$ ) y de la  $E_{Tr}$  generada por el algoritmo SEBAL y que se encuentra disponible como producto C2 Level 2 provisional en la web de Landsat.

Así mismo, Shrotterm.exe también generará las predicciones a CP, sin embargo, el desarrollo de esa parte del algoritmo se realizará en el D 4.2.

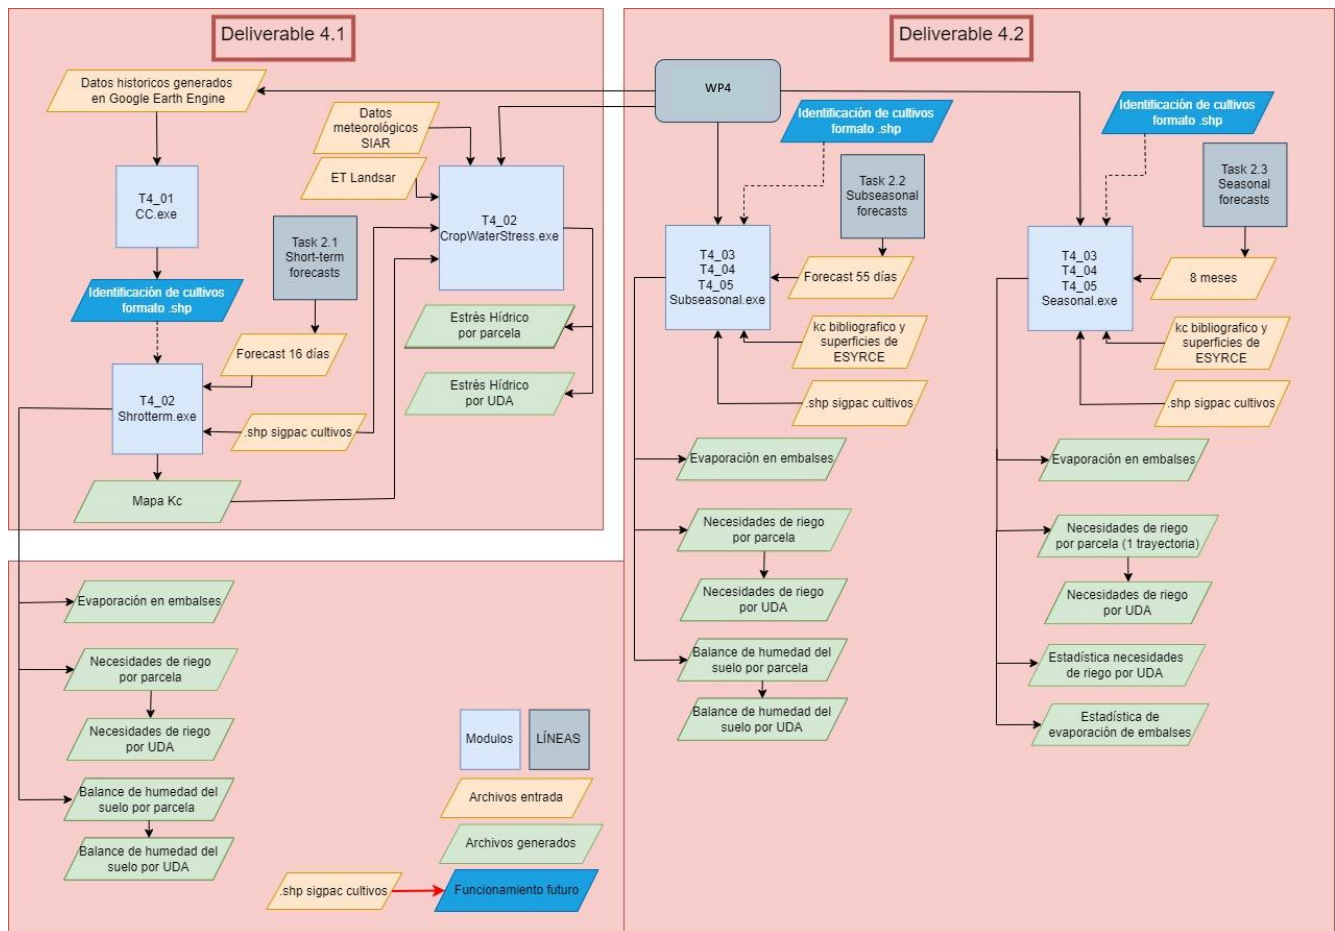


Figure 1- Esquema general de funcionamiento del WP4

### 3.1. Modulo T4\_01

En el módulo T4\_01, se realiza el subproceso, que se ha denominado identificación de cultivos. En los siguientes esquemas se definen funcionalmente dicho subproceso.

La identificación de cultivos se basa en la combinación de técnicas de teledetección e inteligencia artificial (IA). Para la teledetección se emplean imágenes de la constelación Sentinel 2 por ser el de mayor resolución espacial -10m- dentro de los productos disponibles de forma libre. Para cubrir la demarcación se emplean 7 imágenes Sentinel 2. De aquí se obtienen las series temporales para los años 2018-2022, agrupando las imágenes en un total de 24 imágenes por año (una imagen cada 15 días) para cada uno de los 7 *Tiles* de los cuales está formada la imagen final de la cuenca del río Júcar. En caso de existir píxeles con nubes o sombras de las propias nubes, el algoritmo los elimina. A continuación, se genera una imagen única por fusión del mosaico de 7 imágenes. De estas 24 imágenes por año de la cuenca del río Júcar se obtiene el valor de los píxeles, el valor de NDVI y la desviación típica de este píxel frente al valor de sus píxeles colindantes, con todo ello se generan archivos .csv los cuales se descargan a un ordenador en local y posteriormente son usados para el entrenamiento de los algoritmos de IA *red neuronal BiLSTM* y *Random Forest*. Los resultados muestran un *accuracy* del

92,02% en la identificación a nivel de parcela mediante *redes neuronales BiLSTM* y de un *accuracy* del 87,79% en la identificación a nivel de parcela mediante *Random Forest* en la zona de la comarca de la Ribera Baja.

La validación de los resultados se ha realizado empleando datos proporcionados por el Fondo de Garantía Agraria (FEGA) del gobierno de España. Este organismo es el encargado de realizar la cartografía de las parcelas agrícolas mediante los datos que se extraen de las subvenciones de la Política Agraria Común (PAC), pudiendo ser usada esta base de datos como verdad terreno para la zona de la cuenca del río Júcar. Estos datos se encuentran en formato *shapefile* y en ellos se indican los cultivos de las parcelas agrícolas entre otros datos.

Con todo ello en la Figura 2 muestra el esquema general de funcionamiento del módulo T4\_01, identificación de cultivos.

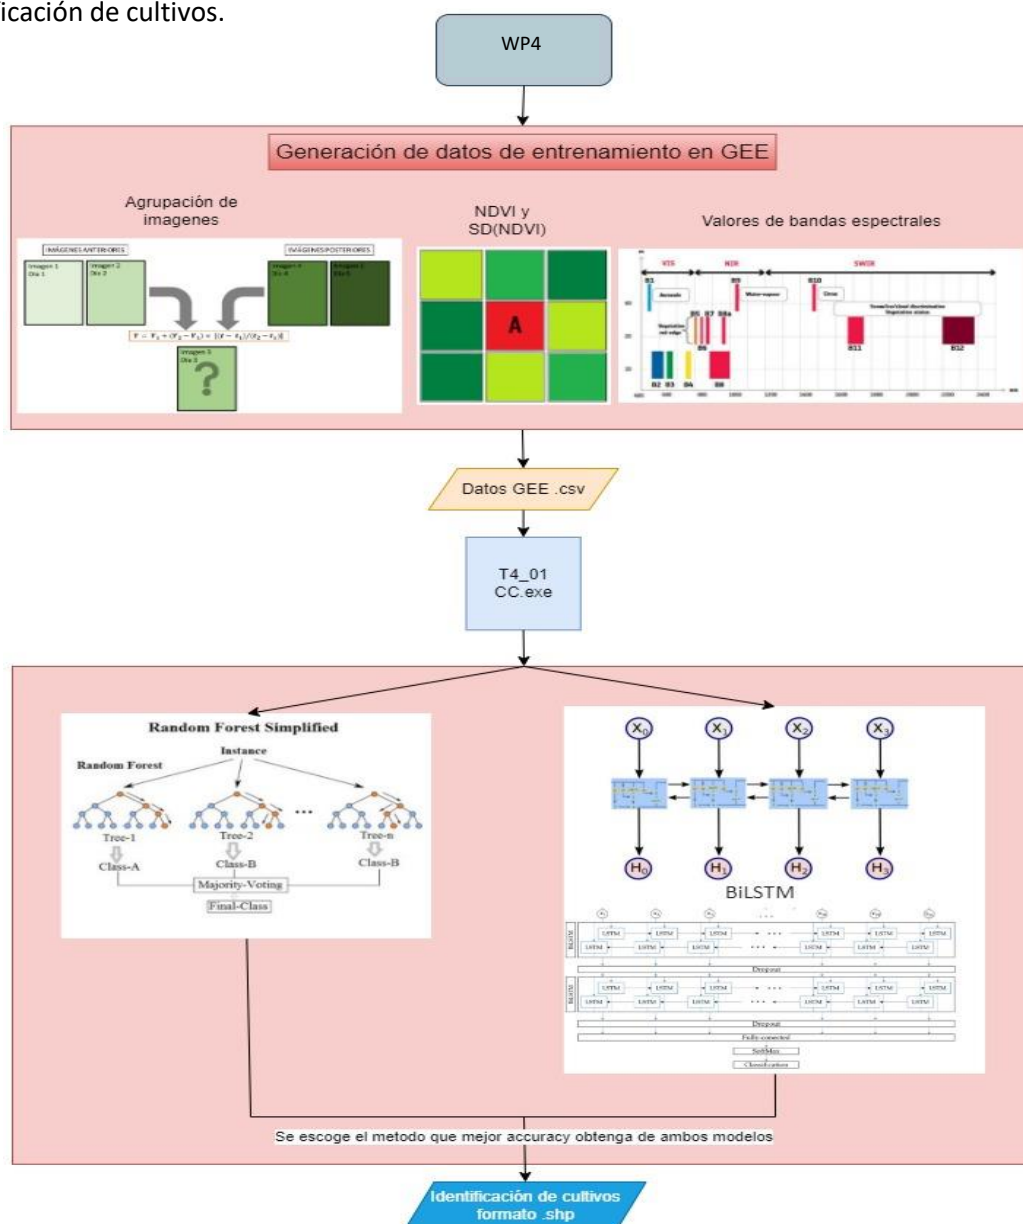


Figure 2-Esquema general de funcionamiento del módulo T4\_01

Para cada uno de estos procesos de clasificación de imágenes, se evalúa su desempeño o bondad de ajuste mediante el *accuracy* que se obtiene relacionando las parcelas verdad terreno y los resultados obtenidos, con objeto de seleccionar el algoritmo que proporcione los resultados más precisos.

Con el modelo óptimo seleccionado, se genera un fichero en formato *shapefile*. El mejor *accuracy* fue el obtenido por las redes neuronales *BiLSTM*. Dicho fichero se transforma en polígonos (*shapefile*) y se interseca con los límites de las diferentes Unidades de Demanda Agraria (UDAs). El resultado de dicho geoprocesamiento alimentará a los procesos denominados T4\_02 y T4\_03.

### 3.2. Modulo T4\_02

El proceso T4\_02 se divide en dos subprocesos, Shrotterm.exe y CropWaterStress.exe, los cuales se ejecutan en paralelo. Ambos ejecutables se encuentran realizados en el lenguaje de programación Python 3.x.

T4\_02 Shrotterm.exe se inicia con la descarga de imágenes satelitales de la constelación Sentinel 2 para derivar el coeficiente de cultivo  $K_c$  a partir del NDVI, para posteriormente obtener las necesidades de riego a CP en T4\_02 Shrotterm.exe (el cálculo de las necesidades se describe en el D 4.2). Este coeficiente de cultivo derivado de un índice de vegetación podríamos decir que es un valor de  $K_c$  “observado”, ya que se deriva de la fenología del cultivo y de su grado de desarrollo.

Para cubrir la cuenca del río Júcar se emplean 7 imágenes de Sentinel 2 de la fecha de cálculo y 7 imágenes de una fecha inmediata anterior (14 imágenes en total). En caso de existir píxeles con nubes, se eliminan de la imagen más actual y se recurre a los píxeles concretos de la imagen anterior para conseguir una imagen limpia de nubes. A continuación, se genera una imagen única por fusión del mosaico de 7 imágenes y de ésta se deriva el coeficiente de cultivo  $K_c$  por píxel. Los valores de  $K_c$  son limitados, no pudiendo ser superiores a los valores de  $K_c$  estimados por los diferentes servicios de regadío como son Instituto Valenciano de Investigaciones Agrarias (IVIA).

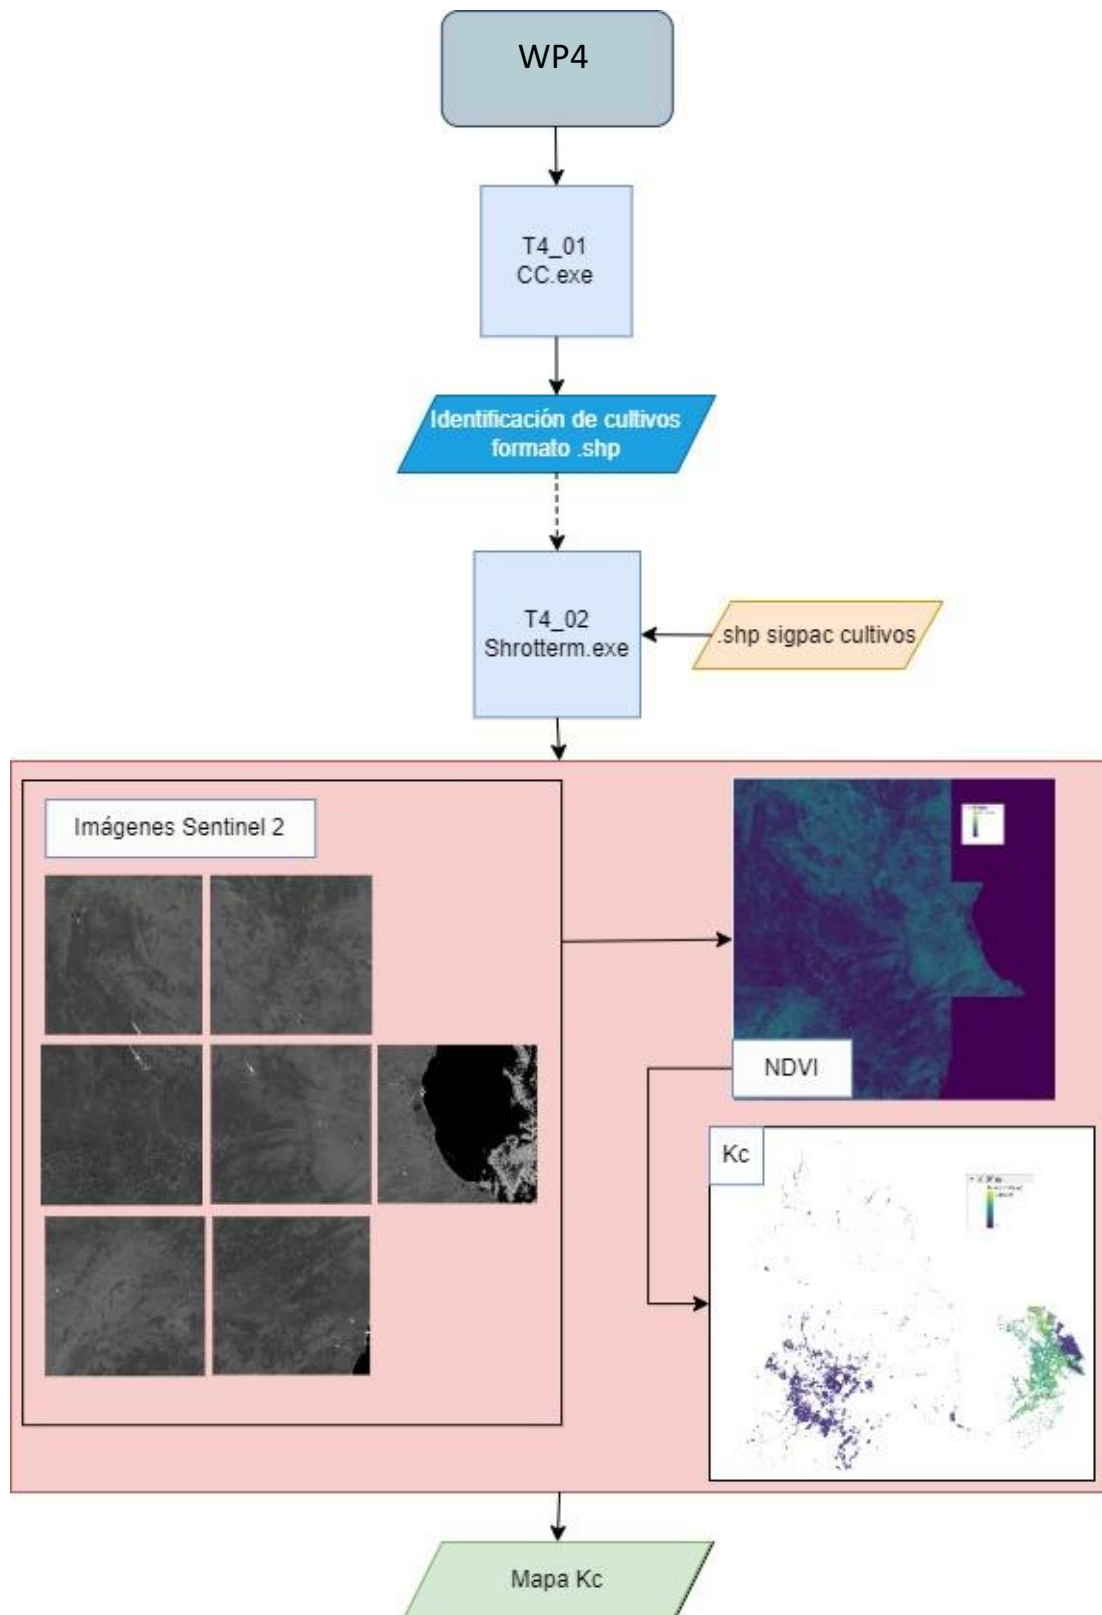


Figure 3—Esquema general de funcionamiento del módulo T4\_02 Shrotterm.exe para el cálculo de Kc.

T4\_02 CropWaterStress.exe se inicia con la descarga de datos meteorológicos de la red de estaciones SIAR, la cual se automatiza mediante la API de SIAR (Siar 0.6). Con los datos meteorológicos observados se realiza un cálculo diario, espacialmente distribuido de evapotranspiración de referencia para toda la cuenca del río Júcar, con el objetivo de determinar la ETo (mm) entre las estaciones meteorológicas y con ello poder ajustar la ETo en las parcelas agrícolas. Para disponer de valores de ETo se generan mapas que describen la variación espacial de los parámetros meteorológicos que conforman la ETo, temperatura media (°C), temperatura máxima (°C), temperatura mínima (°C), humedad máxima (%), humedad mínima (%), radiación neta ( $\text{MJm}^{-2}\text{día}^{-1}$ ) y velocidad del viento a 2m ( $\text{ms}^{-1}$ ), empleando la metodología desarrollada específicamente para este fin en García-Prats et al. (2023) como resultado de WATER4CAST. (DOI: [10.1016/j.agwat.2023.108415](https://doi.org/10.1016/j.agwat.2023.108415)).

Estos mapas se realizan para la ventana temporal que transcurre entre la fecha más reciente y la más antigua de las 3 imágenes de ETr generadas por Landsat y que son necesarias para cubrir la cuenca del río Júcar.

Para determinar el estrés hídrico se obtiene la Kc dividiendo los valores de los píxeles de la imagen de ETr de Landsat entre los valores de la imagen de ETo generada mediante datos meteorológicos observados (dmo). Al disponer de los valores de Kc para cada píxel, podemos calcular los valores diarios de ETc interpolando la ETr a escala diaria ( $\text{ETo}_{(\text{dmo})} \times \text{Kc}_{(\text{Landsat})} = \text{ETr}_{(\text{diaria})}$ ) para la ventana temporal ya descrita.

Por otro lado, mediante la imagen de  $\text{ETo}_{(\text{dmo})}$  y los valores de Kc obtenidos mediante la derivación del NDVI y limitados a los Kc de diferentes servicios de regadío se pueden obtener imágenes de ETc ( $(\text{ETo}_{(\text{dmo})} \times \text{Kc}) = \text{ETc}_{(\text{diaria})}$ ). Una vez que tenemos las imágenes de ETr y ETc para la ventana temporal se obtiene los valores de estrés hídrico dividiendo ETr y ETc ( $\text{EH} = \text{ETr} / \text{ETc}$ ). Estos valores discurren entre 0 y 1, siendo 0 para píxeles con estrés hídrico y 1 para píxeles sin estrés hídrico. Los resultados se muestran a nivel de parcela y de UDA.

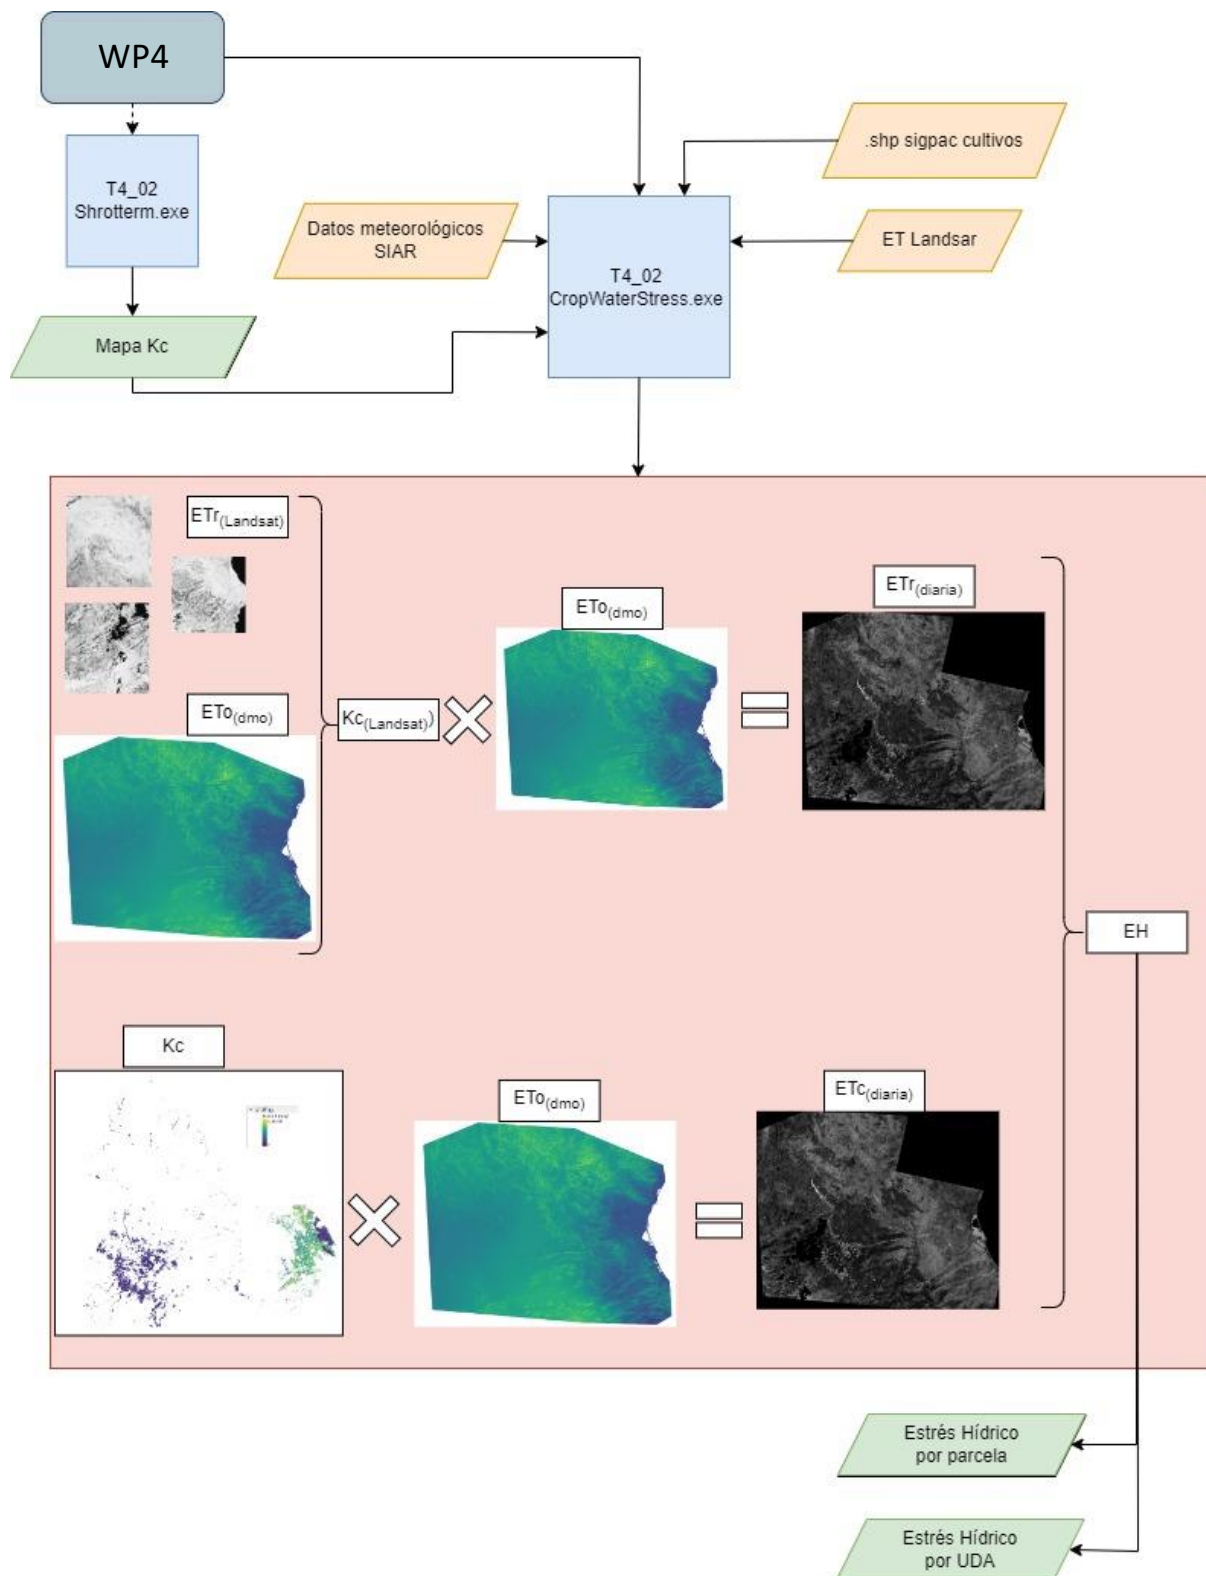


Figure 4–Esquema de funcionamiento de T4\_02 CropWaterStress.exe.



## 4. Algoritmos para Identificación de cultivos

Una vez descrito el funcionamiento del WP4, se procede a describir con más detalle los algoritmos principales que se aplican en cada función de cálculo mostrada en los esquemas. Se trata siempre de algoritmos que existen en la literatura científica y/o están en la práctica habitual del cálculo de necesidades de riego.

### 4.1. Creación de capas de entrenamiento y validación en la identificación de cultivos

A partir de las capas de información espacial proporcionadas por el FEGA, se ha seleccionado imágenes del periodo 2018/19/20/21/22 para realizar la capa de entrenamiento de los algoritmos de clasificación de cultivos. Para ello, se han llevado a cabo los siguientes pasos:

- Reclasificación de la capa de cultivos regados de la CHJ, transformando la clasificación de FEGA a [Viñedo], [Cítricos], [Frutos secos], [Frutales], [Invernaderos y cultivos bajo plástico], [Olivar], [Huerta] e [Tierras arables].
- Asignación de la codificación de cultivos mediante la creación del campo 'cultivo', con los siguientes 6 códigos: [Viñedo= 0], [Cítricos = 1], [Frutos secos= 2], [Frutales = 3], [Invernaderos y cultivos bajo plástico = 4], [Olivar=5], [Huerta=6] e [invernaderos y cultivos bajo plástico =7].

Para el caso de estudio de la Ribera Baixa se han creado [Cítricos = 0], [Arroz = 1], [Caqui= 2], [Barbecho sin producción= 3] e [Barbecho tradicional= 4].

*Con los valores de cada píxel de la serie histórica de las imágenes se asocia cada valor a una de las parcelas y a un tipo de cultivo del caso de estudio. De aquí se utilizaron los años 2018 a 2021, ambos inclusive para el entrenamiento de los algoritmos y el año 2022 para la validación de la T4\_01.*

### 4.2. Algoritmos de clasificación

En W4C se han implementado dos de los modelos de IA más populares y ampliamente utilizados en este campo de la clasificación de imágenes como son *Random Forest* (Bosque Aleatorio) y las Redes Neuronales.

#### 4.2.1. Random Forest

*Random Forest* es un algoritmo de aprendizaje supervisado que se basa en la idea de combinar múltiples árboles de decisión para realizar predicciones. Cada árbol en el bosque se entrena con una muestra aleatoria de los datos y produce una predicción individual. Luego, las predicciones de todos los árboles se combinan mediante votación o promediado para obtener una predicción final. Este enfoque de combinación de múltiples árboles ayuda a reducir el sobreajuste y mejora la precisión y estabilidad del modelo. *Random Forest* es conocido por su capacidad para manejar conjuntos de datos



grandes y complejos, así como por su capacidad para capturar relaciones no lineales y variables importantes.

El proceso de construcción de un *Random Forest* implica los siguientes pasos:

- **Creación de los árboles de decisión:** Un *Random Forest* se compone de múltiples árboles de decisión. Cada árbol se entrena de forma independiente utilizando una porción aleatoria del conjunto de datos de entrenamiento. Esta porción aleatoria se conoce como “bootstrap sample”, y se obtiene mediante el muestreo con reemplazo del conjunto de datos original.
- **Selección de características:** Antes de construir cada árbol, se selecciona un subconjunto aleatorio de características del conjunto de datos. Esta selección de características aleatoria ayuda a evitar el sesgo y mejora la diversidad de los árboles en el bosque.
- **Construcción de los árboles:** Cada árbol se construye dividiendo recursivamente el conjunto de datos de entrenamiento en subconjuntos más pequeños basados en las características seleccionadas. El objetivo es maximizar la pureza de los nodos resultantes, es decir, asegurar que las instancias de una misma clase se agrupen en el mismo nodo. Para cada división, se utiliza un criterio como la ganancia de información o la impureza de Gini.
- **Votación y predicción:** Una vez que todos los árboles se han construido, el *Random Forest* realiza una votación para la clasificación o promedio para la regresión. Para la clasificación, cada árbol emite su voto para la clase de la instancia en cuestión, y la clase con más votos se selecciona como la predicción final. Para la regresión, cada árbol emite una predicción numérica y se toma el promedio de todas las predicciones.

Una vez está clara la estructura y funcionamiento del modelo *Random Forest*, se procede a explicar su creación y puesta en marcha mediante el uso del lenguaje Python.

En esta etapa, es necesario preparar los datos de entrenamiento y predicción antes de introducirlos en el *Random Forest*. El modelo *Random Forest* requiere que los datos estén en formato matricial, por lo que es crucial asegurarse de que los datos estén correctamente ordenados.

Los datos se dividirán en cuatro matrices principales: la matriz X de entrenamiento, la matriz Y de entrenamiento, la matriz X de predicción y la matriz Y de predicción.

- **La matriz X de entrenamiento:** contendrá únicamente los datos relevantes de cada píxel que aporten información útil para el modelo *Random Forest*, como las distintas bandas de estudio, el índice NDVI y la desviación estándar del NDVI. Estos datos serán seleccionados específicamente para los años destinados al entrenamiento.
- **La matriz Y de entrenamiento:** incluirá los datos relativos al número de cultivo correspondiente a cada píxel. Estos datos también se seleccionarán para los años de entrenamiento.
- **La matriz X de predicción:** contendrá los datos relevantes de cada píxel que se utilizarán para la predicción. Al igual que en la matriz de entrenamiento, se incluyen las bandas de estudio, el índice NDVI y la desviación estándar del NDVI. Sin embargo, solo se incluyen los datos correspondientes al año seleccionado para la predicción.
- **La matriz Y de predicción:** incluirá los datos relativos al número de cultivo correspondiente a cada píxel, pero solo para el año de predicción. Es importante destacar que estos datos no se

introducirán en el modelo *Random Forest*, sino que se utilizarán posteriormente para evaluar el porcentaje de acierto en la predicción.

La segmentación de los datos en estas matrices garantiza que los datos correspondientes a cada píxel ocupen la misma posición vertical en ambas matrices, lo que facilita la correlación entre los datos de entrada y los resultados esperados.

#### 4.2.2. Redes Neuronales

Por otro lado, las *Redes Neuronales* son un modelo de aprendizaje automático inspirado en el funcionamiento del cerebro humano. Estas redes están compuestas por capas de nodos interconectados llamados neuronas, que procesan la información y la transmiten a través de conexiones ponderadas. Cada neurona aplica una función de activación a la suma ponderada de las entradas para producir una salida. Las *Redes Neuronales* son altamente flexibles y pueden adaptarse a patrones complejos y no lineales en los datos.

Es importante destacar que el rendimiento y la precisión de los modelos predictivos dependen de la calidad de los datos de entrada, la selección de características relevantes y la adecuada calibración y validación del modelo. Además, la mejora continua de los modelos a través de la retroalimentación y la actualización de los datos de entrenamiento contribuye a su robustez y capacidad predictiva a lo largo del tiempo.

La red neuronal seleccionada para este proyecto es una red *Bidireccional Long Short-Term Memory (BiLSTM)*. Estas redes neuronales son una variante de las *redes neuronales recurrentes (RNN)* que se utilizan para el procesamiento de secuencias de datos en ambas direcciones. A diferencia de las *RNN* tradicionales, que solo consideran la información pasada en una secuencia, las *BiLSTM* también tienen en cuenta la información futura al procesar la secuencia.

La arquitectura de una *BiLSTM* se compone de dos capas *LSTM*, una que procesa la secuencia en orden ascendente (*forward LSTM*) y otra que procesa la secuencia en orden descendente (*backward LSTM*). Cada capa *LSTM* tiene una estructura interna compuesta por unidades de memoria y puertas de control que les permiten aprender y mantener información a largo plazo, así como actualizarla según la relevancia de los datos entrantes.

Durante el procesamiento de una secuencia, la capa *forward LSTM* procesa los datos en orden ascendente, comenzando desde el inicio de la secuencia, mientras que la capa *backward LSTM* procesa los datos en orden descendente, comenzando desde el final de la secuencia. Cada capa *LSTM* genera una salida que captura la información contextual de su respectiva dirección. Estas salidas se combinan de alguna manera, como la concatenación o la suma, para obtener una representación final de la secuencia que captura tanto la información pasada como la futura.

Una ventaja clave de las redes *BiLSTM* es su capacidad para capturar dependencias a largo plazo en los datos secuenciales en ambas direcciones. Esto les permite modelar relaciones complejas entre elementos distantes en la secuencia y tener en cuenta el contexto global al realizar predicciones o análisis en los datos, factor que es de especial interés en la interpretación de los datos de series temporales como las de este proyecto.

Para comprender el funcionamiento de las redes neuronales *LSTM*, es útil observar la estructura básica de una neurona *LSTM*. La característica clave de las redes *LSTM* es el estado de las celdas ( $C_t$ ), representado por la línea roja horizontal en el diagrama de la Figura 5.




Figure 5—Estructura de una neurona *LSTM*

Este estado de la celda se propaga directamente a lo largo de todo el diagrama, interactuando de manera lineal en cada paso. El estado de la celda tiene la capacidad de eliminar y agregar información mediante el control por parte de estructuras llamadas puertas. Estas puertas permiten el flujo de información en la red. En el caso de las *LSTM*, se utilizan tres puertas, compuestas por una capa de red neuronal sigmoide ( $\sigma$ ) y una operación puntual de multiplicación, como se muestra en las líneas verdes de la Figura 5.

Las redes neuronales *LSTM* están compuestas por cuatro etapas principales, tal como se muestra en la Figura 6.

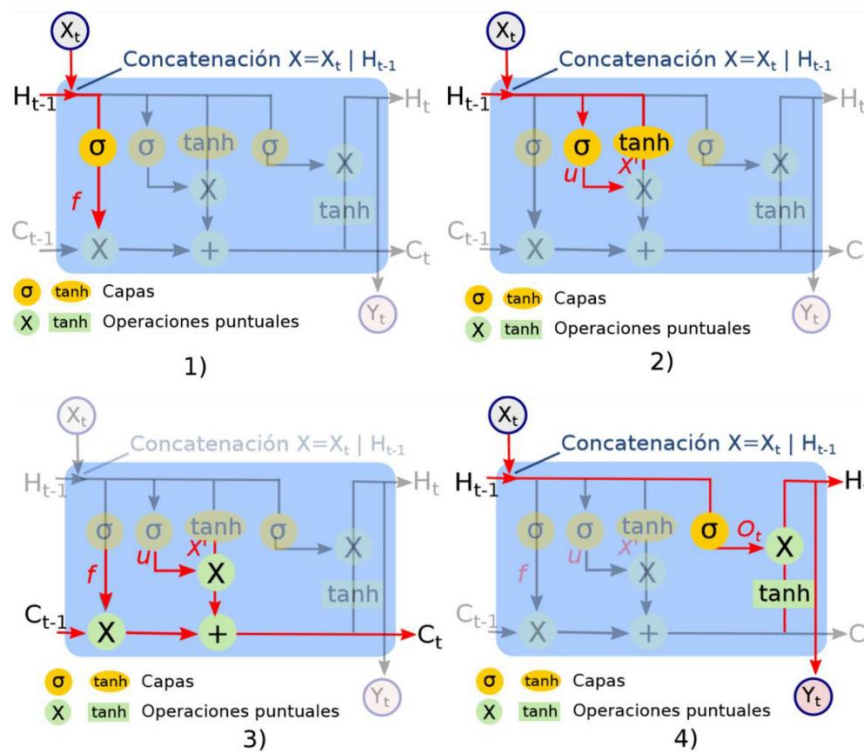


Figure 6—Etapas de LSTM. 1) Forget gate layer, 2) Input Gate, 3) Output Gate y 4) Estado de Celda Actualizado.

Cada etapa desempeña un papel específico en el procesamiento de la información en una red *LSTM*.

A continuación, se describe brevemente cada una de las etapas:

- **Etapas de Olvido (Forget Gate):** Esta etapa se encarga de decidir qué información debe ser olvidada o descartada del estado de la celda anterior. Se utiliza una función de activación sigmoide para generar un número entre 0 y 1 para cada unidad de memoria en el estado de la celda. Un valor cercano a 0 indica que la información se olvidará, mientras que un valor cercano a 1 indica que se retendrá.
- **Etapas de Actualización (Input Gate):** En esta etapa, se determina qué nueva información se agregará al estado de la celda. Se utilizan dos funciones de activación: una función sigmoide para determinar qué valores se actualizarán y una función tangente hiperbólica para calcular los posibles nuevos valores. Estos valores se combinan para obtener la actualización del estado de la celda.
- **Etapas de Salida (Output Gate):** En esta etapa, se decide qué información del estado de la celda se utilizará como salida de la neurona *LSTM*. Se utiliza una función de activación sigmoide para determinar qué parte del estado de la celda se enviará como salida y luego se aplica una función tangente hiperbólica para obtener la salida final de la neurona *LSTM*.
- **Etapas de Estado de Celda Actualizado:** En esta etapa, se actualiza el estado de la celda anterior con la información obtenida de la etapa de actualización y la etapa de olvido. El estado de la celda actualizado se utiliza como entrada para la siguiente iteración de la red *LSTM*.

Cada una de estas etapas desempeña un papel fundamental en el procesamiento de la información en una red *LSTM*, permitiendo capturar y retener información relevante a largo plazo. El uso de funciones de activación y operaciones matemáticas específicas en cada etapa garantiza un procesamiento eficiente y preciso de las secuencias de datos en las redes neuronales *LSTM*.

Teniendo en cuenta este funcionamiento que se corresponde con el de una red *LSTM*, podemos ahora explicar cómo se aplica y funciona en una red *Bidireccional LSTM*.

Las *redes neuronales BiLSTM* consisten en dos capas principales: una capa que aprende representaciones previas y otra capa que retrocede en el tiempo, lo que nos permite analizar datos tanto hacia adelante como hacia atrás. Esta arquitectura mejora el rendimiento de las *RNN* al capturar información contextual de manera más completa. En el caso de las *LSTM* bidireccionales, se entrenan dos *LSTM* en la secuencia de entrada. La primera *LSTM* opera de manera similar a lo explicado anteriormente (*forward LSTM*), mientras que la segunda *LSTM* es una copia invertida de la secuencia de entrada (*backward LSTM*).

Este enfoque bidireccional proporciona a la red un contexto adicional y permite un aprendizaje más rápido y completo. Por ejemplo, al predecir un dato faltante en una secuencia, una *LSTM* unidireccional solo consideraría el contexto izquierdo, mientras que una *LSTM* bidireccional tendría en cuenta tanto el contexto izquierdo como el derecho. Esto se logra mediante la lectura de las variables de izquierda a derecha en una capa, mientras que en la otra capa se recibe una copia invertida para leerla de derecha a izquierda. Ambas capas generan un vector de salida para cada dato, y estos dos vectores de salida se concatenan en un solo vector que modela tanto el contexto derecho como el izquierdo. Esta combinación de información de contexto de ambas direcciones mejora la capacidad de la red para capturar patrones complejos y mejorar el rendimiento en tareas de procesamiento.

## 5. Modelos agronómicos para la determinación de $K_c$ .

### 5.1. Mapas de $K_c$ a partir de imágenes satelitales

Los coeficientes de cultivos obtenidos en ensayos en campo están ligados a las condiciones de la parcela. Es por ello que los centros de investigación publican sus recomendaciones tras realizar múltiples ensayos. Dentro de un mismo cultivo, distintos marcos de plantación, variedades y formas de manejo generarían distintos valores de  $K_c$ , siendo los valores recomendados, valores que mejor representan la realidad promedio del entorno. Es por ello que desde la década de los años 90 del siglo pasado se inició una intensa labor investigadora para derivar valores de  $K_c$  mediante teledetección. Estos valores generalmente van asociados a índices espectrales de vegetación que están a su vez relacionados con el grado de desarrollo del cultivo. Con diferencia, el índice de vegetación más empleado es el índice de vegetación de las diferencias normalizadas o NDVI, propuesto por primera vez en 1969 por Kriegler et al., el cual se obtiene cómo:

$$NDVI = \frac{NIR - RED}{NIR + RED}$$

Donde RED = reflectancia en la banda del infrarrojo cercano (0.6-0.7  $\mu\text{m}$ ), y NIR = reflectancia en la banda del rojo (0.75-1.5  $\mu\text{m}$ ).

El NDVI puede oscilar entre -1 y 1. Los valores negativos corresponden a láminas de agua y nubes, mientras que los valores positivos son característicos del terreno, valores inferiores a 0,1-0,2 para suelos desnudos, y valores tanto más altos cuanto mayor densidad y desarrollo de la vegetación.

Así, encontramos en la literatura científica multitud de trabajos que derivan valores de  $K_c$  en función del NDVI observado mediante el análisis de imágenes satelitales:

Table 1- Fórmulas de  $K_c$  en función de NDVI

Fórmula	Cultivo	Autor
$K_c = 1.25 \cdot NDVI + 0.1$	Hortícolas	Calera, 2014
$K_c = 1.296 \cdot NDVI + 0.019$	Cítricos	Whitfield et al., 2011
$K_c = 1.44 \cdot NDVI - 0.1$	Frutales	Campos et al., 2010
$K_c = 1.494 \cdot NDVI + 0.028$	Frutos secos, Olivar	Whitfield et al., 2011
$K_c = 1.44 \cdot NDVI - 0.1$	Vid	Campos et al., 2010

## 6. Mecanismo de control en tiempo quasi real del estrés hídrico de los cultivos.

### 6.1. Surface energy balance algorithm for land (SEBAL)

Para evaluar el estrés hídrico de los cultivos se requiere por un lado estimar las necesidades potenciales de los cultivos ( $ET_c$ ,  $\text{mm} \cdot \text{d}^{-1}$ ) y por otro medir la evapotranspiración real ( $ET_r$ ,  $\text{mm} \cdot \text{d}^{-1}$ ).

Cuando el cultivo se produce en condiciones reales de manejo en las que en ocasiones no se atiende totalmente a las necesidades de agua, aparece el estrés hídrico. En este caso la  $ET_r$  será inferior a la potencial ( $ET_c$ ). Este estrés hídrico se materializa en un coeficiente reductor de la  $ET_c$ . El coeficiente de estrés  $K_s$  (sin dimensiones) varía de 0 a 1.

$$ET_r = ET_c \cdot K_s = (ET_o \cdot K_c) \cdot K_s$$

Por ello para realizar el cálculo del estrés hídrico (EH) se debe de obtener el cociente entre la evapotranspiración que realmente ha tenido el cultivo y la evapotranspiración que hubiese tenido disponiendo de agua suficiente para cubrir sus necesidades ( $K_s=1$ )

$$EH = \frac{ET_r}{ET_c}$$

El cociente entre ambos términos ( $ET_r/ET_c$ ) nos proporciona un valor que oscila teóricamente entre 0 y 1, aunque en la práctica lo hace entre 0 y un valor que puede ser ligeramente superior a 1, debido a que los valores de  $K_c$  que se recomiendan desde los centros de investigación generalmente obedecen a situaciones promedio, y no a la realidad exacta de cada parcela.

Para la determinación de la  $ET_r$  en WATER4CAST se usa el producto de  $ET_r$  C2-Level 2 provisional generado por Landsat y que se pueden descargar automáticamente (<https://espa.cr.usgs.gov>). El algoritmo que aplica es una versión de SEBAL. Básicamente el método consiste en realizar un balance de energía sobre la superficie del dosel de vegetación. La energía residual del balance se destina a evapotranspirar, tal y como indica la figura:

### Energy Balance for ET




Figure 7– Balance de Energía en SEBAL (Fuente manual de SEBAL)

## 7. Resultados de la tarea WorkPackage 4 (T4\_01 y T4\_02).

Tal y como se explicó en el esquema general de funcionamiento del WP4 (Figura 1), la ejecución genera una serie de ficheros que pueden ser, por un lado, resultados intermedios necesarios en esta u otras tareas, y por otro, resultados finales para ser mostrados por ser importantes para los usuarios. A continuación, se muestran los archivos mencionados en la Figura 1 y el nombre que tienen en el visor WATER4CAST.



## 7.1. T4\_01 (CC.exe)

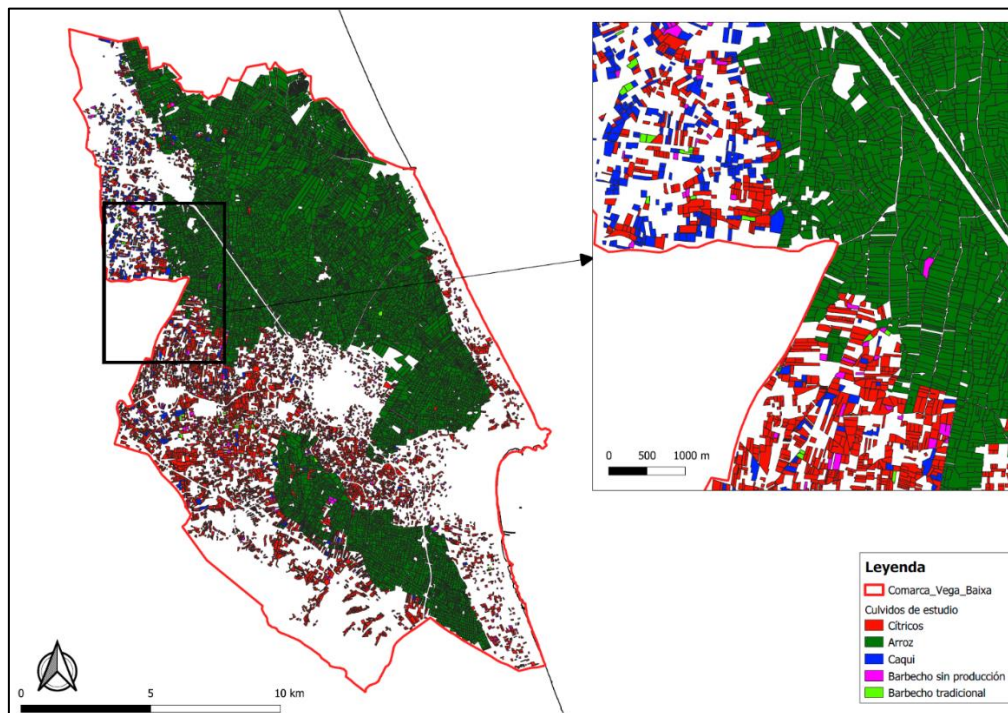


Figure 8— Mapa de Parcelas de interés con los cultivos de estudio agrupados de la comarca de la Ribera Baja

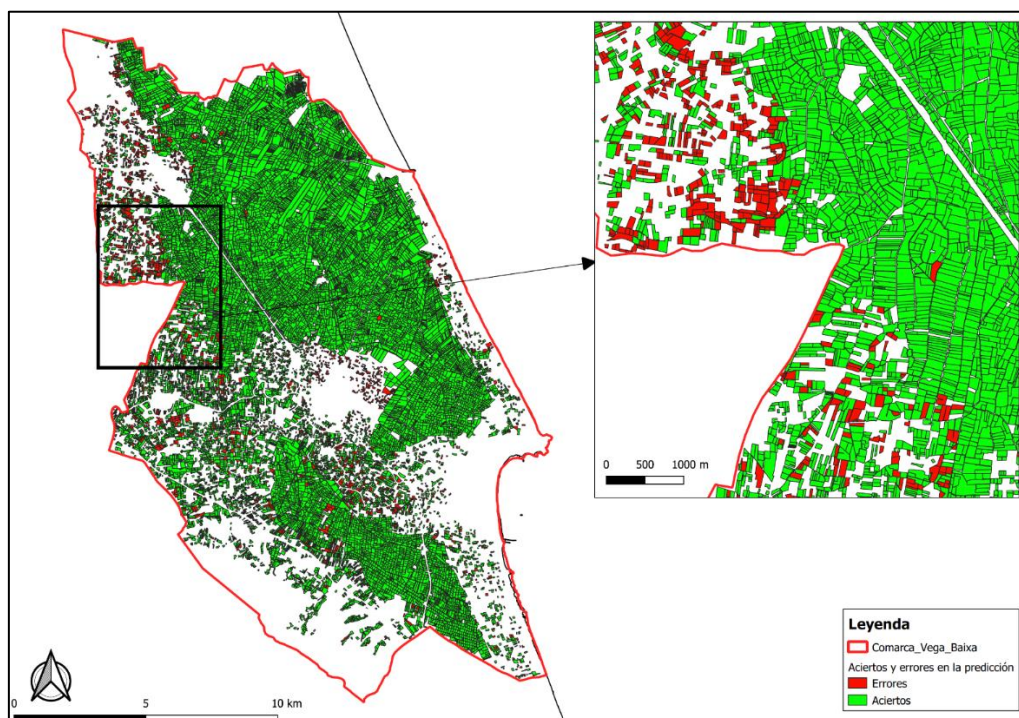


Figure 9—Parcelas clasificadas según la correcta o incorrecta clasificación de cultivos por parte del modelo predictivo Random Forest



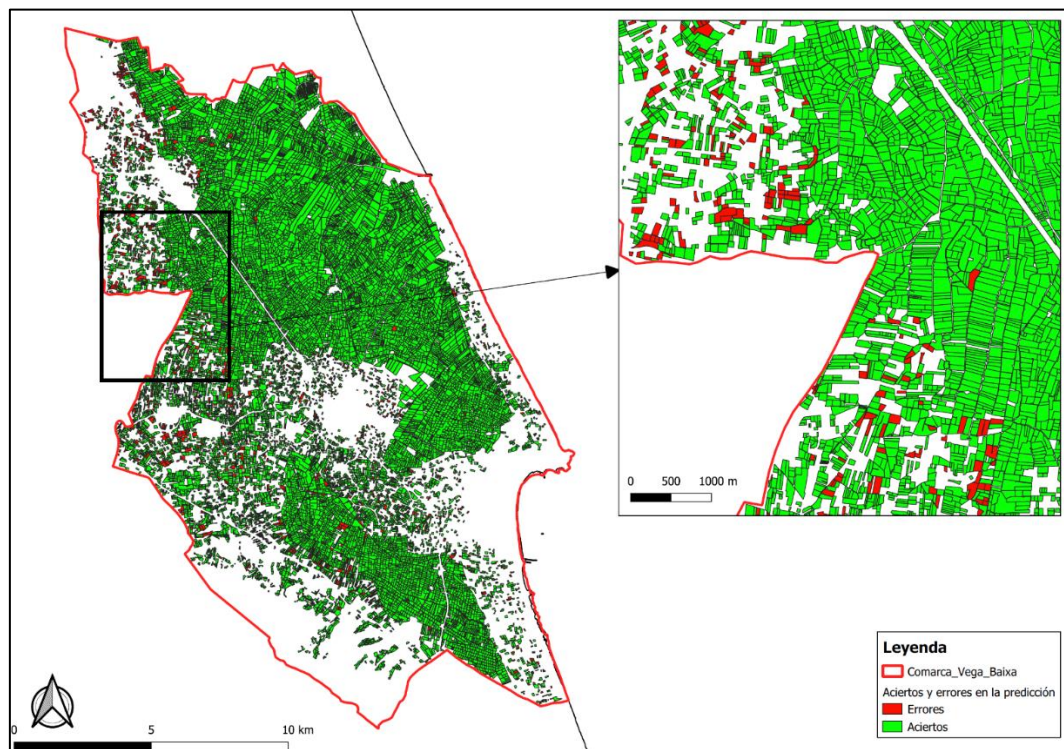


Figure 10–Parcelas clasificadas según la correcta o incorrecta clasificación de cultivos por parte del modelo predictivo red neuronal Bi-LSTM

## 7.2. T4\_02 (Shrotterm.exe)

Kc_CP.csv						
Autoguardado						
Archivo Inicio Insertar Disposición de página Fórmulas Datos Revisar						
Pegar Cortar Copiar Copiar formato Fuente Alineación						
R11						
	A	B	C	D	E	F
1	Fid	Fecha	Cod.UDA	OBJECTID	Kc	
2	0	29/11/2023	A5005	39	0.11495896	
3	1	29/11/2023	A5010	40	0.10094261	
4	2	29/11/2023	A5015	41	0.11677164	
5	3	29/11/2023	A5020	42	0.10186546	
6	4	29/11/2023	A5025	43	0.10203413	
7	5	29/11/2023	A5030	44	0.10614092	
8	6	29/11/2023	A5035	45	0.10943261	
9	7	29/11/2023	A5040	46	0.10557743	
10	8	29/11/2023	A5045	47	0.11010124	
11	9	29/11/2023	A5050	48	0.11748574	
12	10	29/11/2023	A5055	49	0.2365047	
13	11	29/11/2023	A5065	50	0.5123864	
14	12	29/11/2023	A5070	51	0.31374918	
15	13	29/11/2023	A5075	52	0.44921601	
16	14	29/11/2023	A5080	53	0.30734107	
17	15	29/11/2023	A5085	54	0.29684173	
18	16	29/11/2023	A5090	55	0.41518867	
19	17	29/11/2023	A5095	56	0.38818564	
20	18	29/11/2023	A5100	57	0.41381724	
21	19	29/11/2023	A5105	58	0.38657498	
22	20	29/11/2023	A5110	59	0.42669428	
23	21	29/11/2023	A5115	60	0.42297065	
24	22	29/11/2023	A5120	61	0.41487322	
25	23	29/11/2023	A5125	62	0.11728861	
26	24	29/11/2023	A5130	63	0.2585972	
27	25	29/11/2023	A5135	64	0.35134502	
28	26	29/11/2023	A5140	65	0.42308451	
29	27	29/11/2023	A5145	66	0.42212788	
30	28	29/11/2023	A5160	67	0.23807118	
31	29	29/11/2023	A5175	68	0.14607966	
32	30	29/11/2023	A5185	69	0.45540581	
33	31	29/11/2023	A5170	103	0.466364	
34	32	29/11/2023	A5165	104	0.21612411	
35	33	29/11/2023	A5155	105	0.15055963	
36	34	29/11/2023	A5150	109	0.32377858	
37	35	29/11/2023	A5060	110	0.40883687	
38	36	29/11/2023	A5180	112	0.4064987	
39						

Figure 11– Coeficientes de cultivo Kc derivados de NDVI.

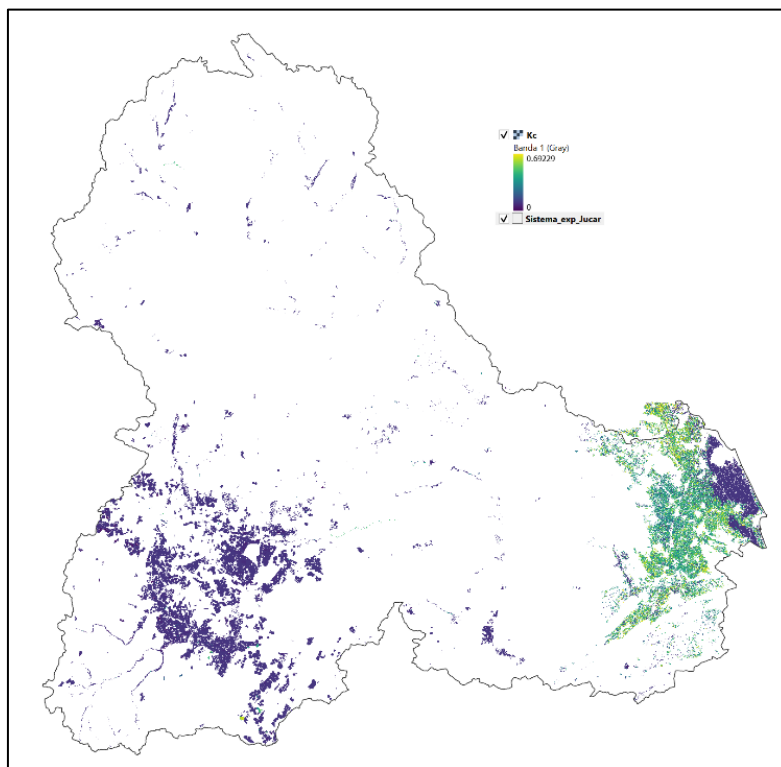


Figure 12—Coeficientes de cultivo Kc derivados de NDVI por parcela.

### 7.3. T4\_02 (CropWaterStress.exe)

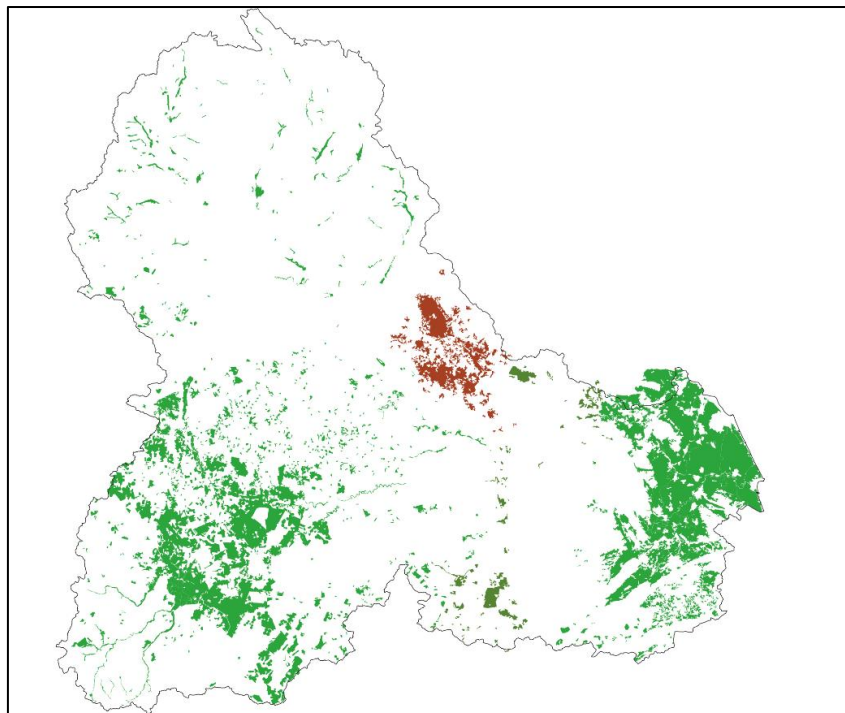


Figure 13—Estrés hídrico por UDA el 10 de julio de 2023.

	A	B	C	D	E	F	G	H	I	J	K	L
	SID	Year_issue	Month_issue	Day_issue	Year_forecas	Month_forec	Day_forecas	Leadtime	Latitude	Longitude	Date	ensemble0
1	A5020	2023	7	10	2023	7	10	0	1	1	10/07/2023	0.99932117
2	A5020	2023	7	10	2023	7	10	0	2	2	10/07/2023	1
3	A5020	2023	7	10	2023	7	10	0	3	3	10/07/2023	1
4	A5020	2023	7	10	2023	7	10	0	4	4	10/07/2023	1
5	A5020	2023	7	10	2023	7	10	0	5	5	10/07/2023	1
6	A5020	2023	7	10	2023	7	10	0	6	6	10/07/2023	0.84805751
7	A5020	2023	7	10	2023	7	10	0	7	7	10/07/2023	0.95357835
8	A5020	2023	7	10	2023	7	10	0	8	8	10/07/2023	1
9	A5020	2023	7	10	2023	7	10	0	9	9	10/07/2023	0.614875
10	A5020	2023	7	10	2023	7	10	0	10	10	10/07/2023	0.70327473
11	A5020	2023	7	10	2023	7	10	0	11	11	10/07/2023	1
12	A5020	2023	7	10	2023	7	10	0	12	12	10/07/2023	0.87793954
13	A5020	2023	7	10	2023	7	10	0	13	13	10/07/2023	0.82382947
14	A5020	2023	7	10	2023	7	10	0	14	14	10/07/2023	0.3798027
15	A5020	2023	7	10	2023	7	10	0	15	15	10/07/2023	1
16	A5020	2023	7	10	2023	7	10	0	16	16	10/07/2023	1
17	A5020	2023	7	10	2023	7	10	0	17	17	10/07/2023	0.82951902
18	A5020	2023	7	10	2023	7	10	0	18	18	10/07/2023	0.75657935
19	A5020	2023	7	10	2023	7	10	0	19	19	10/07/2023	1
20	A5020	2023	7	10	2023	7	10	0	20	20	10/07/2023	1
21	A5020	2023	7	10	2023	7	10	0	21	21	10/07/2023	1
22	A5020	2023	7	10	2023	7	10	0	22	22	10/07/2023	1
23	A5020	2023	7	10	2023	7	10	0	23	23	10/07/2023	1
24	A5020	2023	7	10	2023	7	10	0	24	24	10/07/2023	1
25	A5020	2023	7	10	2023	7	10	0	25	25	10/07/2023	1
26	A5020	2023	7	10	2023	7	10	0	26	26	10/07/2023	1
27	A5020	2023	7	10	2023	7	10	0	27	27	10/07/2023	1
28	A5020	2023	7	10	2023	7	10	0	28	28	10/07/2023	1
29	A5020	2023	7	10	2023	7	10	0	29	29	10/07/2023	1
30	A5020	2023	7	10	2023	7	10	0	30	30	10/07/2023	1
31	A5020	2023	7	10	2023	7	10	0	31	31	10/07/2023	1
32	A5020	2023	7	10	2023	7	10	0	32	32	10/07/2023	1
33	A5020	2023	7	10	2023	7	10	0	33	33	10/07/2023	1
34	A5020	2023	7	10	2023	7	10	0	34	34	10/07/2023	1

Figure 14—Estrés hídrico por parcela el 10 de julio de 2023.

## 8. CONCLUSIONES

Los resultados que generan las tareas T4\_01 y T4\_02 de WATER4CAST se generan a través del uso de algoritmos que se encuentra publicados en la literatura científica o bien que han sido desarrollados para cubrir procesos específicos en el contexto del proyecto, siendo por tanto un resultado de la investigación.

Las tareas programadas en el plan de trabajo de la memoria científico-técnica se han cubierto en su totalidad siguiendo el cronograma previsto.

## Referencias

- Calera A, Campos I, Osann A, D'Urso G, Menenti M (2017) Remote sensing for crop water management: from ET modelling to services for the end users. *Sensors MDPI* (basel, Switzerland) 17(5):1104.
- Campos, I., Neale, C.M.U., Calera, A., Balbontin, C. and González-Piqueras, J., 2010b. Assessing satellite-based basal crop coefficients for irrigated grapes (*Vitis vinifera* L.). *Agricultural Water Management*, 98: 45-54.
- Garcia-Prats, A., Carricondo-Anton, J. M., Jiménez-Bello, M. A., Manzano Juárez, J., López-Pérez, E., & Pulido-Velazquez, M. (2023). Dynamic procedure for daily PM56 ETo mapping conducive to site-specific irrigation recommendations in areas covered by agricultural weather networks. *Agricultural Water Management*, 287. <https://doi.org/10.1016/j.agwat.2023.108415>
- Kriegler FJ, Malila WA, Nalepka RF, Richardson W (1969) Preprocessing transformations and their effect on multispectral recognition. *Remote Sens Environ* VI:97–132.
- Whitfield, D.M., O'Connell, M.G., McAllister, A., McClymont, L., Abuzar, M. and Sheffield, K. (2011). SEBAL-METRIC ESTIMATES OF CROP WATER REQUIREMENT IN HORTICULTURAL CROPS GROWN IN SE AUSTRALIA . *Acta Hortic.* 922, 141-148.