

# Jornadas de Automática

## Estimación automática del estrés hídrico en olivar mediante dendrómetros

Palomo, Jaime<sup>a,\*</sup>, Romero, Rafael<sup>b</sup>, Cuevas, María V.<sup>b</sup>, Álamo, Teodoro<sup>a</sup>, Muñoz de la Peña, David<sup>a</sup>

<sup>a</sup>Departamento de Ingeniería de Sistemas y Automática, Universidad de Sevilla, Camino de los Descubrimientos, S/N, 41092, Sevilla, España

<sup>b</sup>Instituto de Recursos Naturales y Agrobiología (IRNASE-CSIC), Avenida Reina Mercedes 10, Sevilla, 41012, España

**To cite this article:** Palomo, Jaime, Romero, Rafael, Cuevas, María V., Álamo, Teodoro, Muñoz de la Peña, David. 2025. Automatic estimation of water stress in olive groves using dendrometers.

Jornadas de Automática, 46. <https://doi.org/10.17979/ja-cea.2025.46.12254>

### Resumen

En este trabajo se presenta un método de clasificación basado en aprendizaje automático para estimar el nivel de estrés hídrico en plantas a partir de lecturas de variación del diámetro del tronco, registradas mediante dendrómetros. El modelo se valida con datos experimentales de riego deficitario obtenidos en un olivar en Sevilla, Andalucía, durante cinco años. El objetivo es facilitar la integración de las herramientas propuestas en estrategias avanzadas de riego, reduciendo la dependencia de métodos invasivos o hardware costoso.

**Palabras clave:** Aprendizaje automático, Procesamiento de señales, Aprendizaje para el control, Modelado de series temporales, Identificación para el control, Reconocimiento de patrones e inteligencia artificial en la agricultura.

### Automatic estimation of water stress in olive groves using dendrometers

### Abstract

This work presents a machine learning-based classification method to estimate plant water stress levels from trunk diameter variation readings recorded using dendrometers. The model is validated with deficit irrigation experimental data collected in an olive tree orchard in Seville, Andalusia, during five years. The goal is to facilitate the integration of the proposed tools into advanced irrigation strategies, reducing reliance on invasive methods or costly hardware.

**Keywords:** Machine Learning, Signal processing, Learning for control, Time series modelling, Identification for control, Pattern recognition and AI in agriculture.

### 1. Introducción

El riego de cultivos representa cerca del 85 % del consumo global (Gleick, 2003). La escasez hídrica ha aumentado drásticamente en las últimas décadas debido a la limitada disponibilidad de agua y al crecimiento poblacional (Kummu et al., 2010). El cambio climático intensifica este problema, incrementando las necesidades hídricas de las plantas y reduciendo los recursos disponibles (Kang et al., 2009). Por ello, es fundamental desarrollar estrategias que incrementen el rendimiento agrícola disminuyendo el consumo de agua.

En este marco, el riego deficitario controlado (RDI) ha surgido como una alternativa práctica para suprir las demandas hídricas del cultivo (English and Raja, 1996; Fereres and Soriano, 2007). Esta técnica consiste en suministrar menos agua que la necesidad completa del cultivo, con el objetivo de maximizar el rendimiento por unidad de agua minimizando el impacto negativo a largo plazo sobre los cultivos (García-Tejero et al., 2010).

La medición en tiempo real del estado hídrico de los cultivos puede mejorar significativamente los esquemas de riego, proporcionando información clave para evitar daños (Romero

\* Autor para correspondencia: jpiranzo@us.es  
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

et al., 2012). Contar con datos precisos sobre las necesidades hídricas previene episodios no deseados de estrés (Fernández et al., 2008, 2013; Fernández, 2014; Padilla-Díaz et al., 2016). Evaluar con exactitud el estrés hídrico es vital para el desarrollo de sistemas avanzados de riego automatizado, dado que la falta de agua y el estrés hídrico severo pueden reducir el rendimiento del cultivo o incluso provocar la muerte de las plantas.

Diversos métodos han sido propuestos para medir el estrés hídrico, incluyendo análisis de pigmentación foliar (Govender et al., 2009; Thénot et al., 2002), cámaras de presión Scholander (Govender et al., 2009; Scholander et al., 1965) y medidores de actividad de agua (Martínez et al., 2013). Sin embargo, algunos equipos son costosos y/o demandan mucho tiempo para cada medición, limitando su uso en riego automatizado.

Fernández (Fernández, 2014) evaluó tres métodos de estimación del estrés poco usados comercialmente: a partir del flujo de savia (SF), de la variación del diámetro del tronco (TDV) medida con dendrómetros y a partir de la presión de turgencia foliar (LTP) medida mediante sondas ZIM (Zimmermann et al., 2008). TDV resultó más robusto que LTP en estrés alto, y más económico que SF.

Un dendrómetro es un dispositivo que mide con alta precisión las variaciones en el diámetro del tronco de una planta. Existe un gran número de tecnologías distintas aplicadas al diseño de dendrómetros (Clark et al., 2000), algunas de las cuales ofrecen una resolución de micrómetros (Clonch et al., 2021; Drew and Downes, 2009), lo que permite detectar con gran sensibilidad los efectos del estrés hídrico. Esta capacidad ha impulsado su uso en la investigación del estado hídrico de las plantas, especialmente mediante el análisis del ciclo diario del diámetro del tronco (Fernández, 2014; Waldburger et al., 2025). No obstante, la interpretación de estas señales requiere comprender las dinámicas fisiológicas involucradas, lo que ha dificultado su adopción en aplicaciones comerciales automatizadas.

En este trabajo proponemos emplear aprendizaje automático para clasificar las lecturas en tres estados de estrés (Fernández, 2014). En particular, presentamos un procedimiento para procesar los datos específicamente diseñado para reducir la dimensión de los indicadores para posteriormente hacer la clasificación con un método estándar. Validamos esta propuesta con datos de una finca de olivos Arbequina cerca de Sevilla, España, recopilados entre 2014 y 2019, comparando un amplio conjunto de clasificadores diferentes.

## 2. Formulación del problema

El objetivo de este trabajo es la automatización del análisis de los datos obtenidos por los dendrómetros para determinar diariamente estado de estrés hídrico del cultivo con el fin de permitir su uso en estrategias de planificación de riego y gestión del mismo.

Para este análisis se definen tres niveles de estrés hídrico. El nivel 1 corresponde a un nivel de estrés prácticamente nulo, de forma que la planta tiene cubiertas todas sus necesidades hídricas con el riego que recibe actualmente. El nivel 2 corresponde a un nivel de estrés leve o moderado, en el que la planta no tiene totalmente cubiertas sus necesidades pero en el que no existen riesgos para su desarrollo a largo plazo,

excepto en momentos concretos como la floración, pudiendo permanecer en este estado la mayor parte del tiempo sin perjuicio para su productividad. El nivel 3 corresponde a un nivel de estrés severo, en el que la productividad de la planta puede verse afectada a medio plazo o incluso pudiendo desencadenar la muerte de la misma si el estado de estrés se prolonga.

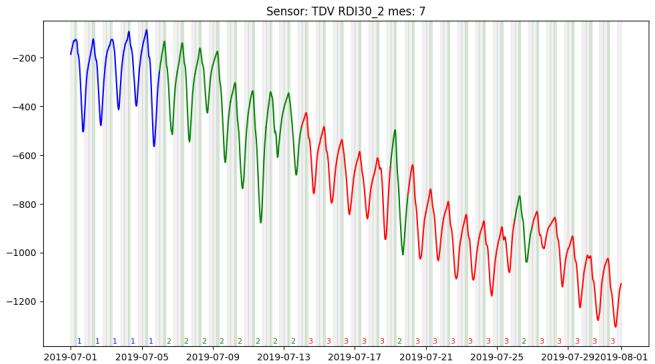


Figura 1: Ejemplo de lecturas de dendrómetros coloreadas según su nivel de estrés diario. Azul: nivel 1. Verde: nivel 2. Rojo: nivel 3.

En la actualidad, el análisis de los datos de dendrometría se realiza de forma manual y no causal una vez finalizada la campaña de riego, empleando las lecturas de varios días tanto anteriores como posteriores al día a clasificar. Esto dificulta su uso en aplicaciones comerciales.

Las lecturas de los dendrómetros se registran como valores incrementales en  $\mu\text{m}$ , donde 0 es un valor correspondiente al diámetro del tronco al inicio de la campaña. La figura 1 muestra las lecturas de un mes completo, con su respectiva clasificación. Las zonas sombreadas en gris representan las horas de noche de cada día, mientras que la franja verde indica las horas previas al amanecer, donde se espera que la lectura alcance su valor máximo diario. Las lecturas se realizan cada 15 minutos, con un total de 96 lecturas diarias.

La tabla 1 recoge el número de muestras diarias clasificadas manualmente según los niveles de estrés anteriormente descritos. Se puede observar que el número de datos disponibles es muy reducido y presenta un desequilibrio considerable entre las clases 1 y 3.

| Estrés | 2014 | 2015 | 2016 | 2019 | Total |
|--------|------|------|------|------|-------|
| 1      | 527  | 326  | 407  | 510  | 1770  |
| 2      | 433  | 320  | 284  | 299  | 1336  |
| 3      | 150  | 247  | 53   | 265  | 715   |
| Total  | 1110 | 893  | 744  | 1074 | 3821  |

Tabla 1: Datos de estrés hídrico disponibles por año y nivel de estrés.

Con el fin de comprobar la robustez de los clasificadores al paso del tiempo y el crecimiento de las plantas, se propone emplear los datos de 2014 como conjunto de entrenamiento y validar los resultados empleando el resto de datos, separados anualmente, así como en el conjunto completo de datos.

### 3. Método propuesto

Una solución al problema propuesto consiste en utilizar un algoritmo de clasificación usando como características los valores del dendrómetro de un número determinado de días pasados. Esta solución presenta el inconveniente de que aumentar el número de días utilizados para la clasificación aumenta los recursos (tiempo de procesado, espacio de memoria, etc.) requeridos para la misma. Esto limita el uso de algunas técnicas de clasificación y el máximo número de días que se puede utilizar, perdiendo información necesaria como se demuestra en la sección 4.

En este trabajo proponemos una forma de analizar el histórico de datos disponibles un determinado día para obtener un conjunto de características que proporcionen información relevante de la evolución a corto, medio y largo plazo útil para determinar el nivel de estrés hídrico del cultivo usándolas en un algoritmo de clasificación.

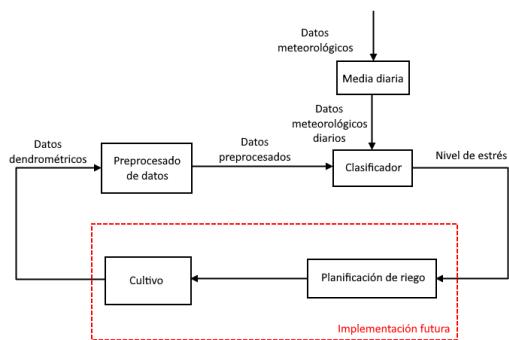


Figura 2: Solución propuesta.

#### 3.1. Preprocesado de datos

El algoritmo propuesto de preprocesado de datos obtiene dada la trayectoria de datos de dendrometría desde el inicio de la campaña las siguientes cuatro características para el día que se está analizando:

- $s$ : El signo de la tendencia del valor máximo diario, representativo de la evolución a muy corto plazo.
- $n$ : Número de días desde el último cambio de tendencia del máximo diario, con signo negativo si la tendencia es descendente, proporcionando la información de la tendencia a medio plazo.
- $m$ : Media móvil exponencial del signo de la tendencia del máximo diario. Se ha empleado un factor de ponderación de 0.5, y se ha considerado que una tendencia creciente tiene un valor igual a 1 y una decreciente tiene un valor igual a 0. Dado que este valor es acumulativo desde el inicio de la lectura del sensor, permite adquirir información de la tendencia a muy largo plazo.
- $d$ : Diferencia entre el valor máximo actual y el del último cambio de tendencia del máximo diario, lo que proporciona información acerca de la velocidad a la que la tendencia actual está afectando al crecimiento de la planta en el medio plazo.

Dado que las cuatro características propuestas se basan en la medida del valor máximo diario, se hace relevante definir correctamente dicho valor. Una recuperación o caída rápida de los niveles de agua en la planta puede ocasionar que el valor máximo medido se encuentre en torno a los límites del día; no obstante, la clasificación funciona mejor cuando se emplea el máximo correspondiente al ciclo normal de la planta, por el cual los niveles hídricos disminuyen durante las horas de sol por la transpiración y aumentan durante la noche, al disminuir la evaporación, como se observa en la Figura 1. La Figura 3 ilustra la diferencia entre ambos máximos. Se ha constatado que los máximos debidos al ciclo de la planta ocurren siempre en las horas previas al amanecer, ya que la mayor pérdida de agua se produce por influencia de la temperatura y la radiación solar, durante el día, mientras que por la noche la planta recupera su contenido de agua con mayor facilidad. Debido a esto, buscar el valor máximo entre las 5:00 y las 8:00 es suficiente para obtener los valores correctos, o, al menos, un valor suficientemente cercano en casos muy extremos.

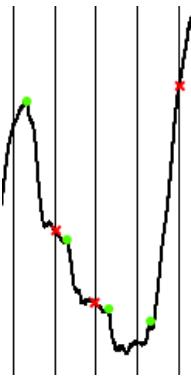


Figura 3: Ejemplo de casos extremos de sequía y recuperación. Las barras verticales marcan las 00:00 de cada día. Los círculos verdes marcan los máximos correspondientes al ciclo diario de la planta, entre las 5:00 y las 8:00 de cada día, mientras que las marcas rojas señalan los máximos artificiales debidos a la separación diaria en períodos de sequía severa y recuperación rápida, a las 00:00.

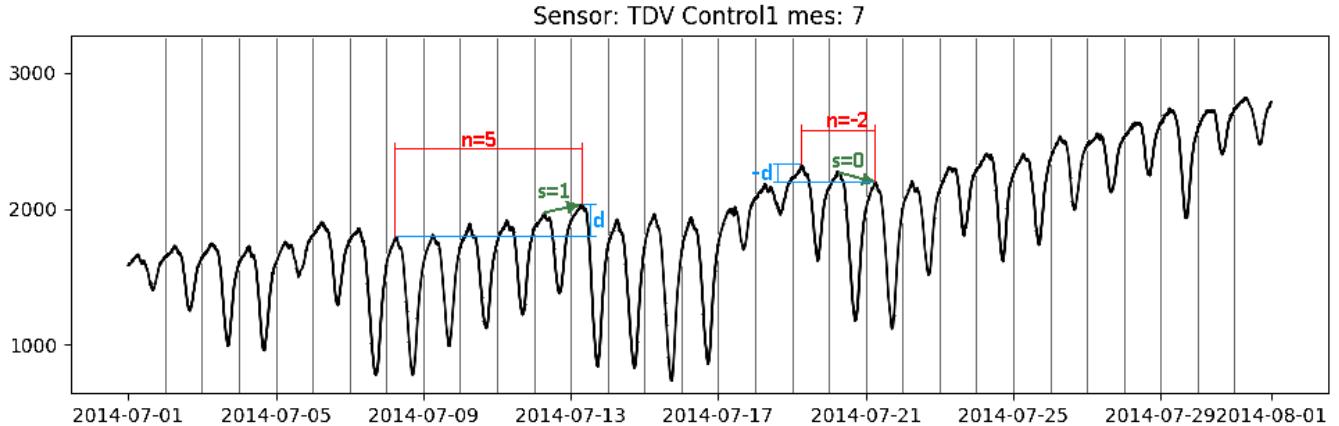
La Figura 4 muestra cómo se pueden obtener las características  $s$ ,  $n$  y  $d$  a partir del histórico de datos de lecturas de los dendrómetros para varios días.

Para el cálculo de  $m$ , puede obtenerse de forma recursiva a partir del valor de  $s$  y el valor anterior de  $m$ ; siendo  $t$  el día a obtener y  $t - 1$  el día anterior:

$$m_t = 0,5s_t + 0,5m_{t-1} \quad (1)$$

También se ha tenido en cuenta el posible efecto de la meteorología diaria sobre la medida del dendrómetro. Con el fin de evitar que la meteorología correspondiente a un día concreto afecte a la clasificación, se han considerado cuatro medidas relevantes que pueden influir en el proceso de transpiración de la planta, y por tanto alterar la medida del estrés hídrico:

- Temperatura ambiente media.
- Humedad relativa media.
- Radiación neta media.
- Déficit de presión de vapor.

Figura 4: Ejemplo de obtención de las características  $s$ ,  $n$  y  $d$ .

### 3.2. Técnicas de clasificación y métricas consideradas

Una vez preprocesados los datos, es posible utilizar cualquier técnica de clasificación para estimar el nivel de estrés. En este trabajo presentamos una comparación entre clasificadores basados en redes neuronales recurrentes (RNN), análisis discriminante lineal (LDA), k vecinos más cercanos (KNN), máquina de soporte vectorial lineal (L-SVM) y radial (RBF-SVM), random forest (RF), proceso gaussiano (GP), árbol de decisión (DT), boosting adaptativo (AdaBoost), naïve Bayes (NB) y análisis discriminante cuadrático (QDA). Esta lista de clasificadores ha sido seleccionada con el objetivo cubrir una variedad en los métodos de clasificación y ajustarse al estado del arte.<sup>1</sup>

Para comparar el rendimiento entre las distintas combinaciones de preprocesados y clasificadores, se ha utilizado la exactitud equilibrada, entendida como el promedio de las exactitudes de cada una de las clases, calculada según la Ecuación 2, donde  $Acc$  es la exactitud equilibrada,  $k$  es cada una de las clases,  $K$  es el número total de clases,  $T_k$  es el número de elementos correctamente clasificados como clase  $k$  y  $N_k$  es el número de elementos totales de la clase  $k$ .

$$Acc = \frac{\sum_{k=1}^K T_k/N_k}{K}. \quad (2)$$

## 4. Resultados experimentales

Para obtener una base comparativa del método propuesto basado en el preprocesado de los datos, primero se han analizado los resultados de acierto obtenidos para una serie de clasificadores basados en usar los datos de dendrometría sin procesar.

La Tabla 2 recoge los resultados obtenidos para ventanas de hasta 9 días, con o sin datos meteorológicos, empleando el año 2014 tanto para entrenar como para calcular la exactitud promedio obtenida para algunos de los clasificadores, habiéndose omitido aquellos más costosos computacionalmente

con el fin de poder usar una ventana amplia. Se observa que el tamaño de la ventana no tiene una gran influencia sobre los resultados en los clasificadores probados, siendo el mejor acierto el clasificador basado en redes neuronales sin tener en cuenta los datos meteorológicos. El acierto es similar usando dos días (0.63) o diez días (0.64).

A continuación analizamos los resultados teniendo en cuenta clasificadores basados en el método de preprocesado propuesto para comprobar su desempeño. La Tabla 3 recoge los resultados obtenidos al clasificar las muestras de 2014, empleando las mismas muestras para su entrenamiento, utilizando datos en bruto con ventana de dos días (es decir, el día actual y el anterior) y datos procesados según el método propuesto, que disponen del histórico de datos desde el inicio de la campaña de riego. Se observa cómo todos los clasificadores disponibles mejoran notablemente su exactitud al emplear el método propuesto, si bien esta empeora al tener en cuenta los datos meteorológicos.

Por último presentamos los resultados obtenidos al usar datos de diferentes campañas para entrenar y validar para comprobar la utilidad de usar dendrómetros para estimar el estrés hídrico en aplicaciones comerciales. La Tabla 4 muestra los resultados obtenidos al clasificar utilizando el método de preprocesado propuesto con los datos de distintos años empleando clasificadores entrenados en 2014, con o sin usar los datos meteorológicos. Se observa cómo en general el aporte de la información meteorológica no beneficia a la calidad de la clasificación. Por otro lado, se observa también que la calidad de dicha clasificación no se degrada con el paso del tiempo, pudiendo emplear datos de 2014 para clasificar datos obtenidos 5 años después. Para la última columna de ambas tablas se han omitido los datos procedentes del año 2014 en el cálculo del acierto, para evitar la posible influencia del sobreentrenamiento.

<sup>1</sup>El clasificador RNN se construyó utilizando la biblioteca TensorFlow (<https://www.tensorflow.org/>), con ajuste de hiperparámetros realizado mediante Keras Tuner ([https://keras.io/keras\\_tuner/](https://keras.io/keras_tuner/)), incluido en la misma biblioteca. Todos los demás clasificadores se implementaron usando la biblioteca scikit-learn(<https://scikit-learn.org>).

| Clasificador      | Sin datos meteorológicos |        |        |         | Con datos meteorológicos |        |        |         |
|-------------------|--------------------------|--------|--------|---------|--------------------------|--------|--------|---------|
|                   | 2 días                   | 4 días | 7 días | 10 días | 2 días                   | 4 días | 7 días | 10 días |
| RNN               | 0.63                     | 0.64   | 0.54   | 0.64    | 0.36                     | 0.45   | 0.46   | 0.45    |
| Naive Bayes       | 0.58                     | 0.59   | 0.58   | 0.58    | 0.57                     | 0.58   | 0.58   | 0.58    |
| Nearest Neighbors | 0.54                     | 0.59   | 0.58   | 0.58    | 0.55                     | 0.59   | 0.58   | 0.58    |
| LDA               | 0.54                     | 0.53   | 0.51   | 0.45    | 0.37                     | 0.41   | 0.36   | 0.42    |
| QDA               | 0.43                     | 0.34   | 0.36   | 0.35    | 0.36                     | 0.34   | 0.36   | 0.38    |
| Mejor             | 0.63                     | 0.64   | 0.58   | 0.64    | 0.57                     | 0.59   | 0.58   | 0.58    |

Tabla 2: Acierto obtenido por cada clasificador con datos TDV sin procesar y con o sin datos meteorológicos usando el año 2014 tanto para entrenar como para validar, tomando 2, 4, 7 o 10 días de datos (el actual y anteriores) para cada muestra.

| Clasificador      | Datos procesados         |                          | Datos sin procesar (2 días) |                          |
|-------------------|--------------------------|--------------------------|-----------------------------|--------------------------|
|                   | Sin datos meteorológicos | Con datos meteorológicos | Sin datos meteorológicos    | Con datos meteorológicos |
| RNN               | 0.76                     | 0.69                     | 0.63                        | 0.36                     |
| Random Forest     | 0.72                     | 0.72                     | 0.63                        | 0.60                     |
| LDA               | 0.72                     | 0.72                     | 0.54                        | 0.37                     |
| Decision Tree     | 0.72                     | 0.71                     | 0.59                        | 0.50                     |
| AdaBoost          | 0.72                     | 0.69                     | 0.59                        | 0.57                     |
| Naive Bayes       | 0.71                     | 0.71                     | 0.58                        | 0.57                     |
| QDA               | 0.71                     | 0.71                     | 0.43                        | 0.36                     |
| Linear SVM        | 0.70                     | 0.71                     | 0.54                        | 0.46                     |
| Nearest Neighbors | 0.67                     | 0.62                     | 0.54                        | 0.55                     |
| Gaussian Process  | 0.61                     | 0.59                     | 0.33                        | 0.33                     |
| RBF SVM           | 0.51                     | 0.33                     | 0.33                        | 0.33                     |
| Mejor             | 0.76                     | 0.72                     | 0.63                        | 0.60                     |

Tabla 3: Acierto obtenido por cada clasificador con datos TDV procesados según el método propuesto o sin procesar (con ventana de dos días) y con o sin datos meteorológicos usando el año 2014 tanto para entrenar como para validar.

| Clasificador | Sin datos meteorológicos |      |      |      |                              | Con datos meteorológicos |      |      |      |                              |
|--------------|--------------------------|------|------|------|------------------------------|--------------------------|------|------|------|------------------------------|
|              | 2014                     | 2015 | 2016 | 2019 | Conjunto completo (sin 2014) | 2014                     | 2015 | 2016 | 2019 | Conjunto completo (sin 2014) |
| AdaBoost     | 0.72                     | 0.74 | 0.58 | 0.77 | 0.70                         | 0.69                     | 0.74 | 0.59 | 0.73 | 0.69                         |
| NB           | 0.71                     | 0.75 | 0.62 | 0.61 | 0.67                         | 0.71                     | 0.67 | 0.61 | 0.63 | 0.66                         |
| LDA          | 0.72                     | 0.68 | 0.62 | 0.66 | 0.67                         | 0.72                     | 0.70 | 0.61 | 0.66 | 0.67                         |
| QDA          | 0.71                     | 0.74 | 0.62 | 0.60 | 0.67                         | 0.71                     | 0.72 | 0.61 | 0.55 | 0.65                         |
| RNN          | 0.76                     | 0.69 | 0.61 | 0.58 | 0.66                         | 0.69                     | 0.73 | 0.62 | 0.58 | 0.66                         |
| RF           | 0.72                     | 0.70 | 0.59 | 0.59 | 0.65                         | 0.72                     | 0.70 | 0.59 | 0.67 | 0.67                         |
| DT           | 0.72                     | 0.69 | 0.61 | 0.57 | 0.65                         | 0.71                     | 0.68 | 0.62 | 0.70 | 0.68                         |
| L-SVM        | 0.70                     | 0.69 | 0.59 | 0.60 | 0.64                         | 0.71                     | 0.70 | 0.59 | 0.68 | 0.67                         |
| GP           | 0.61                     | 0.71 | 0.60 | 0.61 | 0.63                         | 0.59                     | 0.72 | 0.61 | 0.59 | 0.63                         |
| KNN          | 0.67                     | 0.61 | 0.58 | 0.59 | 0.61                         | 0.62                     | 0.57 | 0.52 | 0.57 | 0.57                         |
| RBF-SVM      | 0.51                     | 0.41 | 0.48 | 0.46 | 0.46                         | 0.33                     | 0.33 | 0.33 | 0.33 | 0.33                         |
| Mejor        | 0.76                     | 0.75 | 0.62 | 0.77 | 0.70                         | 0.72                     | 0.74 | 0.62 | 0.73 | 0.69                         |

Tabla 4: Acierto obtenido por cada clasificador entrenado en 2014 al evaluar en los distintos conjuntos de datos procesados, comparando escenarios con y sin datos meteorológicos.

A partir de estos datos, se puede observar que el clasificador con mejores resultados ha sido AdaBoost, empleando el método de procesado propuesto y sin utilizar datos meteorológicos. Para este clasificador se obtiene la matriz de confusión de la ecuación 3 al clasificar todas las muestras disponibles, entrenando con los datos de 2014. Se observa que la mayoría de errores de clasificación se producen entre estados adyacentes; al existir un criterio difuso en los límites entre estados de estrés, este tipo de errores es menos grave que entre los estados 1 y 3 y puede permitir, a priori, su uso en una implementación orientada al riego automático. Todos los clasificadores probados obtienen resultados similares cuando su acierto es suficientemente alto.

$$C_{\text{AdaBoost}} = \begin{bmatrix} 0,881 & 0,114 & 0,005 \\ 0,122 & 0,746 & 0,133 \\ 0,079 & 0,377 & 0,544 \end{bmatrix}. \quad (3)$$

## 5. Conclusiones

El método de preprocessado de datos propuesto permite reducir la dimensionalidad del problema de clasificación del nivel de estrés, aumentando la cantidad de información relevante aportada por cada una de las características obtenidas de los datos originales, de forma que es posible obtener una clasificación en tres niveles de estrés suficientemente fiable como para permitir su uso en toma de decisiones de riego, sin conocimientos previos de lectura de datos dendrométricos, empleando clasificadores automáticos clásicos.

Además, se ha comprobado que la clasificación realizada no depende de medidas meteorológicas como la humedad ambiental o la temperatura, al menos en la finca en que el equipo fue instalado, sino que depende únicamente de la medida proporcionada por los dendrómetros, empeorando la clasificación al añadir información del estado meteorológico diario. Esto puede indicar que los dendrómetros proporcionan suficiente información como para estimar el estado de estrés de la planta, con independencia del entorno de la misma.

## Agradecimientos

Los autores agradecen el apoyo de los proyectos PID2021-124651OB-I00 y PID2022-141159OB-I00 financiados por MCIN/AEI/10.13039/501100011033 y por el FEDER Una manera de hacer Europa.

## Referencias

- Clark, N. A., Wynne, R. H., Schmoldt, D. L., 2000. A review of past research on dendrometers. *Forest Science* 46 (4), 570–576.  
DOI: 10.1093/forestscience/46.4.570
- Clonch, C., Huynh, M., Goto, B., Levin, A., Selker, J., Udell, C., 2021. High precision zero-friction magnetic dendrometer. *HardwareX* 10, e00248.  
DOI: 10.1016/j.ohx.2021.e00248
- Drew, D. M., Downes, G. M., 2009. The use of precision dendrometers in research on daily stem size and wood property variation: a review. *Dendrochronologia* 27 (2), 159–172.  
DOI: 10.1016/j.dendro.2009.06.008

- English, M., Raja, S. N., 1996. Perspectives on deficit irrigation. *Agricultural Water Management* 32 (1), 1–14.  
DOI: 10.1016/S0378-3774(96)01255-3
- Fereres, E., Soriano, M. A., 2007. Deficit irrigation for reducing agricultural water use. *Journal of experimental botany* 58 (2), 147–159.  
DOI: 10.1093/jxb/er1165
- Fernández, J., 2014. Plant-based sensing to monitor water stress: Applicability to commercial orchards. *Agricultural water management* 142, 99–109.  
DOI: 10.1016/j.agwat.2014.04.017
- Fernández, J., Green, S., Caspari, H., Diaz-Espejo, A., Cuevas, M., 2008. The use of sap flow measurements for scheduling irrigation in olive, apple and asian pear trees and in grapevines. *Plant and Soil* 305 (1), 91–104.  
DOI: 10.1007/s11104-007-9348-8
- Fernández, J., Perez-Martin, A., Torres-Ruiz, J. M., Cuevas, M. V., Rodriguez-Dominguez, C. M., Elsayed-Farag, S., Morales-Sillero, A., Garcia, J. M., Hernandez-Santana, V., Diaz-Espejo, A., 2013. A regulated deficit irrigation strategy for hedgerow olive orchards with high plant density. *Plant and soil* 372 (1), 279–295.  
DOI: 10.1007/s11104-013-1704-2
- Garcia-Tejero, I., Jiménez-Bocanegra, J., Martínez, G., Romero, R., Durán-Zuazo, V., Muriel-Fernández, J., 2010. Positive impact of regulated deficit irrigation on yield and fruit quality in a commercial citrus orchard [citrus sinensis (L.) osbeck, cv. salustiano]. *Agricultural Water Management* 97 (5), 614–622.  
DOI: 10.1016/j.agwat.2009.12.005
- Gleick, P. H., 2003. Water use. *Annual review of environment and resources* 28 (1), 275–314.  
DOI: 10.1146/annurev.energy.28.040202.122849
- Govender, M., Govender, P., Weiersbye, I., Witkowski, E., Ahmed, F., 2009. Review of commonly used remote sensing and ground-based technologies to measure plant water stress. *Water Sa* 35 (5).  
DOI: 10.4314/wsa.v35i5.49201
- Kang, Y., Khan, S., Ma, X., 2009. Climate change impacts on crop yield, crop water productivity and food security—a review. *Progress in natural Science* 19 (12), 1665–1674.
- Kummu, M., Ward, P. J., de Moel, H., Varis, O., 2010. Is physical water scarcity a new phenomenon? global assessment of water shortage over the last two millennia. *Environmental Research Letters* 5 (3), 034006.  
DOI: 10.1088/1748-9326/5/3/034006
- Martínez, E., Rey, B., Fandino, M., Cancela, J. J., 2013. Comparison of two techniques for measuring leaf water potential in vitis vinifera var. albariño. *Ciència e Técnica Vitivinícola* 28, 29–41.
- Padilla-Díaz, C., Rodriguez-Dominguez, C., Hernandez-Santana, V., Perez-Martin, A., Fernández, J., 2016. Scheduling regulated deficit irrigation in a hedgerow olive orchard from leaf turgor pressure related measurements. *Agricultural Water Management* 164, 28–37.  
DOI: 10.1016/j.agwat.2015.08.002
- Romero, R., Muriel, J., García, I., de la Peña, D. M., 2012. Research on automatic irrigation control: State of the art and recent results. *Agricultural water management* 114, 59–66.  
DOI: 10.1016/j.agwat.2012.06.026
- Scholander, P. F., Bradstreet, E. D., Hemmingsen, E., Hammel, H., 1965. Sap pressure in vascular plants: Negative hydrostatic pressure can be measured in plants. *Science* 148 (3668), 339–346.  
DOI: 10.1126/science.148.3668.339
- Thénot, F., Méthy, M., Winkel, T., 2002. The photochemical reflectance index (pri) as a water-stress index. *International Journal of Remote Sensing* 23 (23), 5135–5139.  
DOI: 10.1080/01431160210163100
- Waldburger, T., Walter, A., Cockburn, M., Nasser, H.-R., Monney, P., Hatt, M., Anken, T., 2025. Dendrometer as a water stress indicator for apple trees. *Agricultural Water Management* 309, 109326.  
DOI: 10.1016/j.agwat.2025.109326
- Zimmermann, D., Reuss, R., Westhoff, M., Gessner, P., Bauer, W., Bamberg, E., Bentrup, F.-W., Zimmermann, U., 2008. A novel, non-invasive, online-monitoring, versatile and easy plant-based probe for measuring leaf water status. *Journal of experimental botany* 59 (11), 3157–3167.  
DOI: 10.1093/jxb/ern171