

Jornadas de Automática

Robótica y análisis hiperespectral para la monitorización no invasiva: proyecto ATTENTIA

Rua-Tirado, Sara^a, Gómez-Bravo, Fernando^{a *}, Peregrín-Rubio, Antonio^b, Martín-Moreno, Javier^b, Domínguez-Moreno, Antonio^c, Moreno-Cuesta, Eduardo^c, Díaz-Márquez, Manuel Jesús^c, Camacho-Calero, Daniel^c

^a Departamento de Ingeniería Electrónica, de Sistemas Informáticos y Automática, Universidad de Huelva, Avda. de las Fuerzas Armadas, s/n. - 21007.

^b Departamento de Tecnologías de la Información, Universidad de Huelva.

^c Departamento de Ciencias Agroforestales, Universidad de Huelva.

To cite this article: Rua, S., Gómez, F., Peregrín, A., Martín, J., Domínguez, A., Moreno, E., Díaz, M.J., Camacho, D. 2026. Mobile robotics and hyperspectral analysis for non-invasive monitoring in the ATTENTIA project. *Jornadas de Automática*, 47. <https://doi.org/10.17979/ja-cea.2026.47.13769>

Resumen

Este artículo presenta algunos de los trabajos desarrollados por la Universidad de Huelva en el marco del proyecto de investigación ATTENTIA, una iniciativa de cooperación transfronteriza financiada por el programa Interreg POCTEP 2021–2027, orientada a impulsar una agricultura citrícola más sostenible mediante la aplicación de técnicas de Inteligencia Artificial y Robótica. El trabajo recoge diversos desarrollos tecnológicos orientados a la monitorización avanzada de cultivos. El sistema propuesto integra robótica móvil y la adquisición de datos mediante sensores LiDAR-3D y cámaras RGB-D, así como el uso de cámaras hiperespectrales. A lo largo del documento se describen técnicas de posicionamiento preciso y métodos de fusión de información sensorial, junto con el procesamiento para la captura y el análisis de imágenes hiperespectrales. Este planteamiento permitirá realizar una evaluación no invasiva del estado nutricional de los árboles cítricos, contribuyendo al desarrollo de estrategias de agricultura de precisión.

Palabras clave: Robótica Móvil, Imágenes Hiperespectrales, Fusión Sensorial, Monitorización de Cítricos.

Mobile robotics and hyperspectral analysis for non-invasive monitoring in the ATTENTIA project

Abstract

This article presents some of the work developed by the University of Huelva within the framework of the ATTENTIA research project, a cross-border cooperation initiative supported by the Interreg POCTEP 2021–2027 program, aimed at promoting more sustainable citrus farming through the application of Artificial Intelligence and Robotics techniques. The article addresses various technological developments focused on advanced crop monitoring. The proposed system integrates mobile robotics with data acquisition from a 3D-LiDAR sensor and an RGB-D camera, as well as the use of a hyperspectral camera. Throughout the document, precise positioning techniques and sensor fusion methods are described, along with the application of intelligent image processing techniques for hyperspectral data. These approaches enable a non-invasive assessment of the nutritional status of citrus trees, contributing to the development of precision agriculture strategies.

Keywords: Mobile Robotics, Hyperspectral Imaging, Sensor Fusion, Citrus Monitoring.

1. Introducción

En la actualidad, el uso de herramientas tecnológicas dentro de la agricultura tiene como finalidad hacer una gestión responsable de los recursos naturales, reduciendo el

impacto ambiental y contribuyendo al equilibrio entre rentabilidad y sostenibilidad (Sadjadi & Fernández, 2023).

El presente trabajo se enmarca en el contexto del proyecto de investigación ATTENTIA (Agricultura Sostenible de Cítricos con Inteligencia Artificial). Se trata de un proyecto de

cooperación transfronteriza financiado por el programa europeo Interreg POCTEP 2021-2027, orientado a impulsar el desarrollo tecnológico para promover una agricultura más sostenible, proponiendo la aplicación de técnicas de Inteligencia Artificial y Robótica (Proyecto ATTENTIA, 2023). Con este fin, el proyecto pretende analizar de forma inteligente la información procedente de sensores especializados y sistemas de monitorización avanzados obteniendo una visión generalizada y personalizada de la plantación para estimar y mitigar las necesidades de ésta.

El proyecto contempla distintas líneas de trabajo, orientadas a la actualización de sistemas de monitorización agrícola, proponiendo el desarrollo de aplicaciones de robótica móvil para la captura de datos y la utilización de metodologías inteligentes para el análisis de la información.

ATTENTIA está liderado por la Universidad de Huelva (UHU) y cuenta con la participación de la Universidad de Algarve (UA), la Universidad de Sevilla (US) y la Asociación de Citricultores de la Provincia de Huelva (ACPH).

En este artículo se presentan algunos de los desarrollos fundamentales obtenidos por el equipo de la UHU a lo largo de las distintas actividades. Particularmente se describen las experiencias en el desarrollo de sistemas avanzados de monitorización, dentro de los cuales cabe destacar: la mejora de la precisión del posicionamiento del robot tanto en entornos interiores como exteriores; el análisis y fusión de datos procedentes de sensores LiDAR láser 3D y cámara RGB-D, con el fin de obtener una representación integrada del entorno; la aplicación de técnicas de Inteligencia Artificial al tratamiento de imágenes captadas con una cámara hiperspectral.

La introducción de la robótica móvil en este proyecto permite automatizar el proceso de obtención de información del cultivo con las cámaras especializadas mientras que el robot navega entre las hileras de la plantación citrícola (Rahmadian y Widyartono, 2020). El mecanismo para la obtención de imágenes con estos dispositivos es un proceso estático, para lo cual se requiere la máxima precisión posible en cuanto al posicionamiento del robot, ya que, las muestras de las imágenes deben estar perfectamente geolocalizadas dentro de la plantación que se está analizando.

Por otra parte, el uso de cámaras hiperspectrales representa una ayuda inestimable para la evaluación no destructiva del estado nutricional de los árboles cítricos. Estas cámaras permiten capturar información espectral en un gran número de bandas del espectro electromagnético, incluyendo regiones visibles e infrarrojas que contienen información directamente relacionada con la fisiología vegetal. El análisis hiperspectral de hojas y frutos permite obtener información sobre la presencia de determinados compuestos bioquímicos; a partir de esta información es posible estimar deficiencias o excesos de nutrientes (Li et al., 2024; Ram et al., 2024).

El objetivo final de esta línea de trabajo es la integración de la toma de muestras autónoma con el análisis hiperspectral. En la actualidad, se está abordando el ajuste final de ambas metodologías, previéndose que dicha integración pueda alcanzarse al final del proyecto.

El contenido del artículo se estructura de la siguiente forma. En primer lugar, se introducen los métodos y materiales utilizados para el desarrollo de un sistema de monitorización móvil basado en un robot autónomo, así como las bases del sistema de captura y análisis de imágenes hiperspectrales. A continuación, se describen y discuten los resultados obtenidos. El artículo finaliza con las conclusiones.

2. Materiales y métodos

En esta sección se describen los materiales y métodos utilizados para implementar la fusión de datos procedentes de los sensores integrados inicialmente sobre el robot, así como las técnicas de navegación empleadas para desarrollar técnicas de monitorización avanzada. Igualmente se introducen las características de la captura de imágenes hiperspectrales y el fundamento de su procesado.

2.1 Robot móvil: fusión sensorial y técnicas de navegación

Como plataforma móvil para embarcar la sensórica se escogió el robot móvil SUMMIT-XL de Robotnik (Figura 1). Se trata de plataforma autónoma diseñada tanto para entornos interiores como exteriores. Dispone de un procesador Intel i7 de 11.ª generación, 32 GB de memoria RAM, sobre el que está implantado Ubuntu 20.04 y el 'middleware' *Robot Operating System* (versión Noetic). La plataforma adopta una configuración de cuatro ruedas con 'skid-steering'.



Figura 1: Robot SUMMIT-XL.

Para la adquisición de información espacial y visual del entorno, se han seleccionado dos sensores: la cámara RGB-D Orbbeo Astra Pro y el sensor LiDAR RoboSense RS-Helios-16P, caracterizado con un patrón de escaneo lineal de hasta 16 canales. Esta combinación permite capturar tanto mapas de profundidad de alta precisión a corta y media distancia como nubes de puntos 3D.

En primer lugar, la investigación centró su atención en el registro de datos por parte de los sensores de visualización instalados en el robot (LiDAR-3D y cámara RGB-D) y posterior procesado. Con ambos es posible obtener representaciones del entorno en 3 dimensiones a partir de la generación de nubes de puntos. Esta información es analizada y procesada con la finalidad de detectar obstáculos o identificar objetos que se encuentren dentro del campo de visión de los sensores y que pueden afectar las tareas de navegación (Sadjadi & Fernández, 2023). Una primera aproximación consistió en la integración de dichos datos en un mismo marco de referencia de forma que se obtuviera una representación integrada. Para ello se utilizó un proceso de 'clustering' y 'matching' que se describe en la subsección 3.1.

Adicionalmente, se pretende que el robot sirva de soporte autónomo para la toma de imágenes con la cámara hiperespectral, tarea que requiere que el registro de la imagen se realice con la cámara totalmente estática, desde una ubicación precisada con anterioridad. Dada la especificidad de esta tarea, uno de los objetivos del proyecto consiste en detener al robot con alta precisión, en posiciones predeterminadas. Para ello, es necesario el desarrollo de distintos métodos de navegación autónoma, a partir de la información captada por diferentes sensores soportados por el robot, que permitirán la construcción de mapas

De esta forma, se han aplicado diferentes técnicas de navegación entre las que destacan el *Simultaneous Localization And Mapping (SLAM)* y la navegación global utilizando el dispositivo GPS u-blox C94-M8P como receptor GNSS-RTK (Real-Time Kinematic), el cual recibe correcciones desde estaciones de la Red Andaluza de Posicionamiento (RAP) que mejoran la precisión de localización del robot (Niedzwiedzki et al., 2020).

La técnica SLAM permite al robot generar un mapa del entorno por el que se desplaza mientras se localiza dentro de él y puede aplicarse en cualquier escenario interior o exterior (Wang et al., 2022). En este trabajo se ha utilizado *Cartographer-ROS*, un conjunto de paquetes para ROS que implementa un sistema SLAM basado en la optimización de grafos (*Graph-Based SLAM*). Por otro lado, la navegación con GNSS-RTK es una técnica empleada para mejorar la exactitud de los datos recibidos por un receptor GNSS (Sistema Global de Navegación por Satélite) que puede alcanzar precisión centimétrica.

2.2 Imágenes hiperespectrales

Las imágenes hiperespectrales fueron capturadas con la cámara Specim IQ, con el fin de evaluar el estado nutricional de hojas y la calidad de los frutos, estableciendo un protocolo de muestreo y captura de imágenes que pueda relacionarse de forma consistente con los análisis realizados en laboratorio.

La cámara hiperespectral Specim IQ, es un equipo portátil de rango Visible e Infrarrojo Cercano (VNIR), que opera en el rango de 400–1000 nm, con una resolución espectral de unos 7 nm (204 bandas) y espacial de 512×512 píxeles. Estas prestaciones la hacen adecuada para detectar variaciones sutiles en las propiedades fisiológicas y compositivas de hojas y frutos (Behmann et al., 2018). El sistema emplea un escaneo lineal con tiempo de integración constante, lo que permite adquirir el cubo hiperespectral en una sola secuencia.

Antes de iniciar los ensayos específicos se establecieron criterios generales de operación, comunes a laboratorio, invernadero y campo, para asegurar la comparabilidad de los datos en todas las fases. Se trabajó siempre con plataformas fijas para garantizar estabilidad y repetitividad entre capturas, y con distancias estándar sensor objetivo: 0,5–1,25 m en laboratorio y maceta, 2–2,5 m en invernadero y 5–6 m en campo para parejas de árboles. Las imágenes hiperespectrales han demostrado ser una herramienta eficaz para la monitorización no invasiva en agricultura de precisión, permitiendo estimar parámetros bioquímicos y nutricionales de los cultivos a distintas escalas espaciales (Li et al., 2024; Ram et al., 2024).

Para monitorizar el estado nutricional de los árboles se siguió una estrategia por etapas. Primero se definió en laboratorio un escenario muy controlado con hojas individuales, después se evaluaron el ruido y la estabilidad de las firmas espectrales y, finalmente, se aplicó el protocolo en condiciones reales de muestreo en finca.

En una primera fase se realizaron pruebas preliminares para fijar las condiciones óptimas de captura. Se determinó que cada muestra debía incluir entre 4 y 16 hojas, cantidad suficiente para obtener al menos 1 g de materia seca tras secado y molienda, y se fijó una distancia cámara muestra de 50 cm para asegurar un encuadre completo y enfoque nítido.

Después, las muestras se secaron en estufa JUAN SA EB170 a 70 °C durante 48 h y se repitió la captura hiperespectral; el material seco se molió y tamizó con un homogeneizador HEIDOLPH DIAx 900 y tamiz de 1 mm para obtener al menos 1 g de polvo homogéneo por muestra, que se envasó en viales para determinar en el laboratorio las concentraciones de macro y micronutrientes.

Finalmente, los resultados analíticos se integraron con los datos de campo en una misma base de datos para su análisis y validación, comprobando que el flujo de trabajo completo fue sólido y escalable a campañas en fincas comerciales y apto para generar bases de datos espectral analíticas para modelos de predicción nutricional.

Dicho proceso de estimación nutricional del cítrico se llevó a cabo integrando la información hiperespectral de la captura de las hojas para alimentar el modelo de *Machine Learning (ML)* encargado de predecir los valores nutricionales de cada muestra. En primer lugar, se segmentaron los píxeles correspondientes a la región de interés de cada hoja sobre la imagen RGB mediante el modelo de visión artificial preentrenado *Segment Anything Model (SAM)* de Meta. A continuación, dichos píxeles se seleccionaron en la captura hiperespectral aplicando diversos criterios de limpieza: una reducción de la zona de la hoja para eliminar los bordes y así evitar sombras, y la eliminación del 10% de los píxeles más claros y oscuros, eliminando así reflejos y zonas oscuras. Los píxeles seleccionados se agregaron calculando la media de los valores para cada una de las 204 bandas espectrales, generando así la firma hiperespectral de la muestra (ver Figura 2).

La firma hiperespectral media de cada muestra se preprocesó mediante diferentes técnicas: el cálculo de la absorbancia, la *Standard Normal Variate (SNV)*, la *Multiplicative Scatter Correction (MSC)*, la aplicación del filtro de Savitzky-Golay y la eliminación de las bandas espectrales extremas, generalmente menos precisas (longitudes de onda por debajo de 417,52 nm y por encima de 991,22 nm). Finalmente, se entrenaron diversos modelos de ML para regresión con el objetivo de predecir el valor del nutriente correspondiente a partir de las firmas espectrales de las muestras foliares recogidas en laboratorio.

Como fase final del proceso de validación del sensor hiperespectral, se diseñó un ensayo específico para la caracterización nutricional a nivel de dosel en condiciones de campo. En cada naranjo de la parcela experimental de la ETSI en La Rábida se colocaron etiquetas de papel en distintas zonas de la copa, de forma que cada una definía una muestra foliar asociada a un sector concreto del dosel (Figura 3).




Figura 2: Segmentación de hojas y firma hiperespectral.



Figura 3: Naranja marcado con etiquetas.

3. Resultados y discusión

3.1 Integración de información procedente del LiDAR-3D y la cámara RGB-D

Los experimentos diseñados para las tareas de calibración y la integración de información procedente del LiDAR-3D y la cámara RGB-D se realizaron en un espacio interior en el cual se dispusieron 3 cajas de diferentes tamaños ubicadas estratégicamente dentro del campo de visión de los sensores (ver Figura 4).




Figura 4: Entorno de experimentación con sensores.


El procesamiento de datos consistió en el desarrollo de algoritmos de filtrado que permitiesen resaltar los obstáculos deseados sobre el resto de elementos. Para el tratamiento de los datos procedentes del LiDAR-3D se propuso el desarrollo de un filtro geométrico basado en la delimitación de una Región de Interés (ROI), con el objetivo de descartar información no relevante para la navegación del sistema. En el procesamiento de las imágenes capturadas con la cámara RGB-D se aplica un filtrado de ruido basado en densidad local configurado mediante pruebas experimentales,

eliminando, así, puntos aislados mediante criterios de vecindad y umbrales de distancia reducidos.

A continuación, se realiza una segmentación por conectividad espacial, agrupando puntos cuya separación euclídea es inferior a una distancia mínima. Una vez identificado el resultado óptimo, se define una ROI tridimensional y se seleccionan únicamente los puntos contenidos dentro de dicho volumen. En la Figura 5 a) se muestran enmarcados, y en color verde, los datos LiDAR asociados a los objetos 1, 2 y 3. Se ha utilizado una representación en el plano XY con el fin de mejorar la interpretación visual. Los datos representados en rojo en la Figura 5 b) constituyen el conjunto seleccionado para los datos procedentes de la cámara RGB-D.



a)



b)

Figura 5: Resultados detección de obstáculos. a) Plano de visualización XY sobre datos del LiDAR-3D; b) Visualización 3D sobre datos de la cámara RGB-D.

Por último, en la Figura 6 se ilustran los resultados de la fusión en el plano XY, de los datos tanto del LiDAR-3D, representados en azul, como los de la cámara, en color rojo. La información combinada de ambos sensores proporciona

una representación espacial coherente y más completa del escenario, permitiendo un análisis conjunto de los objetos detectados y de su distribución en el espacio.




Figura 6: Representación en plano XY de los datos fusionados.

3.2. Navegación basada en SLAM y en GNSS-RTK

Se evaluó la precisión en la localización en interiores y exteriores, incluyendo zonas arboladas y vegetación, extendiendo actualmente las pruebas a campos citrícolas. Para los experimentos basados en SLAM se elaboró una trayectoria definida por puntos de paso donde el robot se detiene. Tras realizar estas pruebas, se obtuvieron los siguientes resultados de error radial medido para cada prueba sobre cada punto de la trayectoria (ver Figura 7).




Figura 7: Error radial de posicionamiento. a) Resultados en experimentación interior; b) Resultados de experimentación exterior.

Los resultados obtenidos indican que el error de posicionamiento es menor en espacios interiores, con un valor máximo de 25 cm. Sin embargo, el procedimiento seguido para los experimentos realizados en exteriores consigue disminuir el error máximo superior a 60 cm, en las primeras pruebas, hasta valores por debajo de los 40 cm en

los ensayos finales. El posicionamiento en interiores proporciona mejores resultados que en espacios exteriores. Sin embargo, con el estudio de diferentes planes de actuación se ha conseguido mejorar el posicionamiento en estos últimos.

En la Figura 8 se ilustra una imagen de los mapas generados para la implantación de esta técnica de navegación en interior y en exterior. La implementación de la técnica de navegación con GNSS-RTK se realizaron solo en exteriores, siguiendo la misma línea que los realizados con la técnica SLAM, pero definen los puntos mediante coordenadas geodésicas. Los resultados de la experimentación muestran los valores de error de distancia radial sobre cada punto de la trayectoria en cada prueba realizada (Figura 9).




Figura 8: Representación mapas 2D. a) Espacio interior; b) Espacio exterior.




Figura 9: Error radial de posicionamiento con GNSS-RTK.

Los resultados obtenidos se consideran óptimos ya que, el error radial no supera los 20 cm en ningún punto.

3.3. Análisis de imágenes hiperespectrales.

Los ensayos de ruido y estabilidad espectral de las imágenes hiperespectrales mostraron inicialmente una variabilidad apreciable en la firma de una misma hoja, especialmente en el infrarrojo cercano (>800 nm), muy sensible al contenido hídrico y a las condiciones ambientales; se observó una variación que apuntaba a la propia evolución de la muestra, desaconsejando posponer las capturas sin un control estricto de conservación (Figura 10).




Figura 10: Firmas espectrales de hojas frescas y secas en el rango 400–1000 nm, donde se aprecian anomalías debidas al fallo de firmware de la cámara Specim IQ (Dark Reference); cada curva de color corresponde a una captura realizada a 0, 2, 4, 24, 26 y 28 horas tras la recogida.

Sin embargo, sucesivos experimentos revelaron anomalías en la gestión de la referencia oscura asociadas a un fallo de firmware, que finalmente se solventó. Tras esta corrección, las pruebas de validación evidenciaron una alta estabilidad espectral: en hojas frescas, las firmas sucesivas resultaron prácticamente superpuestas, las firmas se mantuvieron estables durante más de un día (Figura 11).




Figura 11: Firmas espectrales de diez hojas conservadas durante 28 horas antes de la captura, obtenidas tras corregir el fallo de firmware de la cámara Specim IQ mediante el nuevo flujo de procesado.

Además, las primeras experiencias con imágenes de dosel confirmaron la capacidad de relacionar la información de copa completa, obteniéndose primeros mapas nutricionales de boro y potasio a escala de árbol, confirmando la viabilidad del flujo completo de trabajo.

Respecto a la precisión de las predicciones, se compararon tres modelos de ML clásicos: *Partial Least Squares* (PLSR) *Regression*, *ElasticNet* (EN) y *eXtreme Gradient Boosting* (XGB), entrenados sobre el conjunto de datos formado por 746 muestras, caracterizadas cada una de ellas por los valores medios de los píxeles seleccionados en cada una de las 192 bandas hiperespectrales. En el entrenamiento se empleó una validación cruzada de 5 pliegues, y una búsqueda en rejilla para el ajuste de hiperparámetros de cada algoritmo. La precisión se evaluó mediante el R^2 y la raíz del error cuadrático medio ($RMSE$) de las predicciones de los principales nutrientes: Nitrógeno (N), Fósforo (P) y Potasio (K) (ver Tabla 1).

Tabla 1: Resultados obtenidos en la predicción de nutrientes

Modelo	N		P		K	
	R^2	RMS	R^2	RMS	R^2	RMS
	E		E		E	
PLSR	0.506	0.330	0.518	0.032	0.594	0.320
EN	0.353	0.379	0.348	0.037	0.478	0.363
XGB	0.374	0.374	0.421	0.035	0.440	0.375

Los valores de R^2 obtenidos son coherentes con la literatura y próximos a los descritos en Li et al. (2024), con R^2 de 0,48 y 0,58 para N y P, mediante PLSR, y de 0,66 y 0,72 con Random Forest. La variabilidad observada puede deberse a cuestiones físicas: diferencias de iluminación, posición en la copa, y a que el rango VNIR de la cámara recoge de forma indirecta parte de la información espectral asociada a determinados nutrientes, especialmente N y K. También puede influir el volumen de datos disponibles. Por ello, los resultados se interpretan como una validación preliminar del método, cuya precisión y capacidad de generalización podrán mejorar al ampliar la base de datos.

4. Conclusiones

Los resultados mostrados cumplen los requisitos del proyecto ATTENTIA. Se ha realizado la integración de información procedente de distintos sensores e implementado técnicas de localización precisas. El análisis de imágenes hiperespectrales ha proporcionado predicciones fiables. En el futuro se abordará la integración de la cámara hiperespectral en el robot y la generación de mapas nutricionales de cultivos.

Agradecimientos

Este trabajo ha sido financiado por el Proyecto ATTENTIA ('Agricultura sostenible de cítricos con Inteligencia Artificial-0085_ATTENTIA_5_E') financiado por el Fondo Europeo de Desarrollo Regional (FEDER), Programa Interreg España-Portugal (POCTEP) 2023-2027.

Referencias

- Behmann, J., Acebron, K., Emin, D., Bennertz, S., Matsubara, S., Thomas, S., Bohnenkamp, D., Kuska, M.T., Jussila, J., Salo, H., Mahlein, A.K., Rascher, U., 2018. Specim IQ: Evaluation of a new, miniaturized handheld hyperspectral camera and its application for plant phenotyping and disease detection. *Sensors* 18(2), 441. DOI: 10.3390/s18020441.
- Niedzwiedzki, J., Niewola, A., Lipinski, P., Swaczyna, P., Bobinski, A., Poryzala, P., Podsedkowski, L., 2020. Real-time parallel-serial LiDAR-based localization algorithm with centimeter accuracy for GPS-denied environments. *Sensors* 20(24), 7123. DOI: 10.3390/s20247123.
- Proyecto ATTENTIA, 2023. Agricultura sostenible de cítricos con inteligencia artificial. Programa Interreg POCTEP 2021–2027. Recuperado de: <https://attentiaproject.eu/> (Accedido: 29/06/2026)
- Rahmadian, R., Widyartono, M., 2020. Autonomous robotic in agriculture: A review. In: *Third International Conference on Vocational Education and Electrical Engineering (ICVEE)*, Surabaya, pp. 1–6. IEEE. DOI: 10.1109/ICVEE50212.2020.9243253.
- Ram, B.G., Oduor, P., Igathinathane, C., Howatt, K., Sun, X., 2024. A systematic review of hyperspectral imaging in precision agriculture: Analysis of its current state and future prospects. *Computers and Electronics in Agriculture* 222, 109037. DOI: 10.1016/j.compag.2024.109037.
- Sadjadi, E. N., Fernández, R., 2023. Challenges and opportunities of agriculture digitalization in Spain. *Agronomy* 13(1), 259. DOI: 10.3390/agronomy13010259.
- Wang, Z., Chen, H., Zhang, S., Lou, Y., 2022. Active view planning for visual SLAM in outdoor environments based on continuous information modeling. *IEEE/ASME Transactions on Mechatronics*, 1–14. DOI: 10.1109/TMECH.2023.3272910.
- Li, D., Hu, Q., Zhang, J., Dian, Y., Hu, C., Zhou, J., 2024. Leaf Nitrogen and Phosphorus Variation and Estimation of Citrus Tree under Two Labor-Saving Cultivation Modes Using Hyperspectral Data. *Remote Sensing* 16(17), 3261. DOI: 10.3390/rs16173261