

Robótica cooperativa para control inteligente de plagas en viñedos

Ribeiro, A.^{a,*}, Bengochea-Guevara, J.M.^a, Andújar D.^a, Ranz C.^a, Montes H.^b

^a Centro de Automática y Robótica (CAR), Consejo Superior de Investigaciones Científicas y Universidad Politécnica de Madrid, Crta. Campo Real km. 0,200, 2800 Arganda del Rey, Madrid, España.

^b Departamento de Ingeniería Eléctrica, Electrónica, de Control Automático y Física Aplicada, Escuela Técnica Superior de Ingeniería y Diseño Industrial, Universidad Politécnica de Madrid, 28012 Madrid, España.

Resumen

Este trabajo presenta un sistema multi-robot heterogéneo para la detección y el tratamiento localizado de enfermedades agrícolas. Está compuesto por dos robots de inspección, basados en vehículos eléctricos comerciales, y dos robots de tratamiento con pulverizadores eléctricos. Cada robot cuenta con cámaras estéreo y receptores GNSS RTK, todos ellos coordinados por un sistema de gestión de misiones en la nube. La estrategia separa las tareas de inspección y tratamiento, permitiendo navegación autónoma, detección en tiempo real mediante redes neuronales convolucionales (YOLOv8) y aplicación localizada del tratamiento. El sistema fue validado en un viñedo comercial afectado por *Botrytis cinerea*, logrando cobertura continua, solapamiento medio del 20 % y una precisión del 95 %, con un 30 % de falsos positivos. Los tratamientos se aplicaron solo en zonas infectadas. Esta solución ofrece una alternativa precisa, escalable y eficiente para la agricultura de precisión, mejorando la sostenibilidad mediante el uso racional de recursos y la automatización colaborativa.

Palabras clave: Robótica móvil autónoma, Vehículos terrestres inteligentes, Agricultura de precisión, Sistemas multi-robot, Percepción artificial, Navegación autónoma, Fusión de sensores, Sistemas ciberfísicos agrícolas, Planificación de misiones

Cooperative Robotics for Intelligent Pest Control in Vineyards

Abstract

This paper presents a heterogeneous multi-robot system designed for the autonomous detection and targeted treatment of agricultural diseases in vineyard environments. The system integrates two inspection robots—based on commercial electric vehicles—and two treatment robots equipped with electric sprayers. All platforms are equipped with stereo cameras and RTK-GNSS receivers and are coordinated through a cloud-based mission management system. The proposed strategy decouples inspection and actuation tasks, enabling efficient navigation, real-time detection through convolutional neural networks (CNNs), and precise, localized treatment. Field validation was conducted in a commercial vineyard affected by *Botrytis cinerea*, achieving continuous row coverage, an average image overlap of 20%, and a detection accuracy of 95%, albeit with a 30% false positive rate. The treatment robots executed spraying only in the identified infected zones, reducing chemical usage. This approach combines high-resolution ground sensing, modular automation and intelligent task distribution to enable scalable, sustainable agricultural monitoring and included.

Keywords: Autonomous mobile robotics, Intelligent ground vehicles, Precision agriculture, Multi-robot systems, Machine perception, Autonomous navigation, Sensor fusion, Agricultural cyber-physical systems, Mission planning

1. Introducción

La robótica agrícola ha evolucionado significativamente en las últimas décadas, impulsada por la necesidad de mejorar la sostenibilidad y eficiencia de la producción de alimentos (Bechar and Vigneault, 2017; Duckett et al., 2018). Los sistemas autónomos pueden realizar tareas repetitivas y

exigentes con mayor precisión y menor consumo de recursos, lo que resulta especialmente útil en contextos como la agricultura de precisión (Zhang and Kovacs, 2012).

En este contexto, los sistemas heterogéneos multi-robot se perfilan como una solución especialmente eficaz. Este tipo de arquitecturas permite asignar tareas específicas a robots con distintas capacidades, lo que favorece la cooperación

*Angela Ribeiro: angela.ribeiro@csic.es

distribuida y la especialización funcional (Khamis et al., 2015; Bekris et al., 2012). Aplicado al sector agrícola, este enfoque facilita la separación de tareas como la inspección y el tratamiento, optimizando los recursos energéticos, sensoriales y mecánicos necesarios para cada actividad.

Diversos estudios han explorado soluciones para la inspección autónoma mediante vehículos terrestres (Underwood et al., 2016; Montes & Ribeiro 2023) y plataformas aéreas (Torres-Sánchez et al., 2021; Jiménez-Brenes et al., 2019), sin embargo, en muchos casos la integración con plataformas de tratamiento sigue siendo limitada o depende de intervención humana. A su vez, los avances en visión por computador y aprendizaje profundo han permitido la detección precisa de enfermedades, plagas o estrés hídrico a partir de imágenes RGB y multispectrales (Gao et al., 2023; Rey et al., 2019; Kerkech et al., 2020), lo que ha ampliado las posibilidades de automatización de alto nivel.

Este trabajo propone una arquitectura multi-robot en la que se desacoplan completamente las tareas de percepción y actuación. Dos robots de inspección capturan imágenes georreferenciadas del cultivo, que son procesadas mediante redes neuronales convolucionales (YOLOv8), detectando racimos de uva afectados por *Botrytis cinerea*. A partir de estos datos, se generan instrucciones que son ejecutadas por dos robots de tratamiento equipados con pulverizadores eléctricos. Todos los robots se coordinan mediante un sistema de gestión de misiones basado en la nube, que organiza las tareas de forma autónoma y en tiempo real.

La validación del sistema se llevó a cabo en viñedos comerciales en España, y los resultados obtenidos confirman la viabilidad técnica de la solución, así como su potencial para su escalado operativo y adopción en otras aplicaciones agrícolas extensivas.

2. Materiales y métodos

El sistema multi-robot propuesto está compuesto por cuatro unidades: dos robots de inspección y dos robots de tratamiento. Todos ellos se comunican con una estación base situada en la nube, que actúa como centro de control y coordinación. Esta sección describe las características técnicas de cada uno de los robots, los sensores integrados, los sistemas de navegación y percepción utilizados, así como la arquitectura de comunicaciones empleada.

2.1. Robots de inspección

Los robots de inspección se basan en el vehículo comercial eléctrico Renault Twizy, modelo Urban 80, que ha sido modificado para operar de forma autónoma en entornos agrícolas. Este vehículo fue seleccionado por su bajo coste, tamaño compacto y fiabilidad mecánica. Cada unidad incorpora un ordenador Jetson AGX Orin 32GB, dos cámaras estéreo ZED2i (una frontal y otra lateral) y un receptor GNSS RTK modelo Mosaic-H (Septentrio). La arquitectura de control se basa en módulos independientes conectados mediante bus CAN, que controlan los actuadores del volante, acelerador y freno. El sistema de navegación está implementado sobre ROS, distribución NOETIC y sistema operativo UBUNTU 20.04, utilizando el planificador global SBPL y el local TEB, configurados para seguir trayectorias a una velocidad constante de 3 km/h.

2.2. Robots de tratamiento

Para las tareas de tratamiento, se emplearon dos plataformas diferentes. La primera es un robot comercial XAG R150, equipado con un pulverizador eléctrico multibrazo con control de altura. La segunda plataforma está basada en el robot RB-VOGUI (Robotnik), sobre el que se ha montado un sistema de pulverización controlado mediante ROS, con servomotores que orientan la lanza en función de la altura del objetivo. Ambos robots incluyen cámaras estéreo ZED2i y receptores GNSS RTK similares a los de los robots de inspección, lo que permite la ejecución precisa de órdenes de tratamiento en zonas específicas del cultivo.

2.3. Sistema de gestión de misiones

La coordinación entre robots y el control de las operaciones se realiza mediante un sistema de gestión de misiones implementado en la nube. Este sistema, desarrollado en Python, se comunica con los robots a través del protocolo MQTT, utilizando el broker EMQX. Los robots envían imágenes georreferenciadas a la nube, donde se almacenan en una base de datos SQLite y son analizadas mediante una red neuronal convolucional YOLOv8 (Hussain, 2024) entrenada para la detección de racimos infectados por *Botrytis cinerea*. Para el entrenamiento, se utilizó un conjunto de más de 1.000 imágenes RGB capturadas directamente en viñedos comerciales, en las que se anotaron manualmente los racimos afectados mediante cajas delimitadoras. Las imágenes presentaban variación en la iluminación y algunas presentaban situaciones complejas de oclusión parcial.

Cuando se detectan infecciones, se generan automáticamente puntos de tratamiento que son enviados a los robots de tratamiento mediante mensajes MQTT. Además, se emplean marcadores visuales en el campo para verificar la ejecución correcta de las órdenes de tratamiento.

3. Estrategia de validación del sistema

La validación del sistema multi-robot propuesto se llevó a cabo en condiciones reales de operación en un viñedo comercial de uva blanca gestionado por Bodegas Terras Gauda (España). Este entorno permitió evaluar tanto la precisión de detección como la eficacia en la ejecución de tratamientos localizados, considerando condiciones reales de iluminación, vegetación, estructura del terreno y distribución de las plantas.

3.1 Procedimiento experimental

Durante las pruebas, los robots de inspección fueron programados para recorrer de manera autónoma varias calles del viñedo. Mientras se desplazaban a una velocidad de 3 km/h, capturaban imágenes RGB con las cámaras estéreo ZED2i laterales. Estas imágenes, junto con su información de geolocalización proporcionada por el GNSS RTK, eran enviadas en tiempo real al sistema de gestión en la nube mediante conexión 4G. El sistema clasificaba automáticamente cada imagen utilizando la CNN, identificando aquellas en las que se detectaba la presencia de racimos afectados por *Botrytis cinerea*.

Cada detección generaba un punto de tratamiento georreferenciado, que era almacenado en una base de datos y

posteriormente enviado al robot de tratamiento correspondiente. Para validar la ejecución del tratamiento, se colocaron marcadores físicos (bandas de colores) en las ubicaciones de interés. El sistema multi-robot fue monitorizado desde una estación base remota, desde la cual se supervisaron todas las comunicaciones y acciones de los robots, ver Figura 1.




Figura 1: Estrategia de inspección y tratamiento autónomos. Tratamiento de precisión

3.2 Evaluación de la detección

La evaluación de la detección de racimos infectados se realizó comparando las predicciones del sistema con las observaciones realizadas manualmente por un experto humano, quien recorrió las mismas hileras después de la inspección robótica. Se utilizó como métrica la tasa de aciertos (detecciones correctas respecto a las verdaderas) y la tasa de falsos positivos (detecciones erróneas en zonas sin afectación real). Esta evaluación permitió calibrar el umbral de confianza de la red YOLOv8 para maximizar la sensibilidad sin comprometer excesivamente la precisión.

4. Resultados y discusión

4.1. Inspección autónoma y cobertura del viñedo

Durante las pruebas de campo, los robots de inspección recorrieron de manera autónoma las hileras asignadas sin intervención humana, manteniendo una velocidad constante de 3 km/h. Gracias a la colocación lateral de las cámaras estéreo y a la configuración del solapamiento entre imágenes, se logró una cobertura continua de los racimos a lo largo de las calles del viñedo. Se observó un solapamiento medio del 20 % entre imágenes consecutivas, lo cual es adecuado para garantizar la redundancia necesaria para una detección fiable, incluso en zonas con oclusiones parciales por follaje.

4.2. Rendimiento del sistema de detección

La red neuronal YOLOv8 alcanzó una tasa de detección correcta del 95 %, en comparación con las observaciones del experto humano. No obstante, se registró una tasa de falsos positivos cercana al 30 %. Las principales causas de estos errores fueron: (i) oclusión parcial o total de los racimos en algunas imágenes, (ii) condiciones de iluminación irregulares,

y (iii) diferencias visuales entre las imágenes de entrenamiento y las condiciones reales del viñedo durante las pruebas. A pesar de ello, la alta tasa de acierto valida el uso de CNNs para inspección agrícola automatizada en viñedos.

4.3. Precisión en el tratamiento localizado

Los robots de tratamiento ejecutaron correctamente las órdenes generadas por el sistema de gestión de misiones. Los tratamientos fueron aplicados únicamente en las ubicaciones detectadas como afectadas por *Botrytis cinerea*. La verificación se realizó mediante la inspección de los marcadores físicos colocados en campo, confirmando que el robot se había detenido y actuado en los puntos esperados. Este enfoque demostró que la estrategia basada en separación funcional entre inspección y tratamiento puede ser eficaz, siempre que la precisión de la detección sea elevada. Las Figuras 2 y 3 recogen detalles de la experimentación realizada en campo.

4.4. Ventajas del enfoque multi-robot

El uso de robots especializados para tareas diferenciadas permitió optimizar el uso de energía y tiempo operativo. Mientras los robots de inspección se enfocaban en la captura continua de datos visuales con sensores optimizados, los robots de tratamiento empleaban sistemas de pulverización más complejos y pesados solo donde era estrictamente necesario. Esta arquitectura desacoplada permite escalar el sistema fácilmente para cubrir grandes superficies agrícolas, desplegando múltiples unidades en paralelo y reduciendo el uso innecesario de insumos fitosanitarios.



Figura 2: Arriba: Los dos robots de inspección en acción durante la tarea de detección. Abajo: Los dos robots de tratamiento en funcionamiento.



Figura 3: Izquierda: Telemetría de los robots de inspección. Derecha: Secuencia de imágenes; el racimo de uvas dañado ha sido marcado y aparece desde distintas perspectivas en ambas imágenes, de inspección y tratamiento autónomos. Tratamiento de precisión

5. Conclusiones

Este trabajo ha demostrado la viabilidad y eficacia de un sistema multi-robot heterogéneo para la inspección autónoma y el tratamiento localizado de enfermedades en cultivos, concretamente en viñedos. La arquitectura propuesta, que desacopla las tareas de percepción y actuación, permite una mayor eficiencia operativa, reduce el uso de productos fitosanitarios y facilita la escalabilidad del sistema.

La combinación de vehículos comerciales eléctricos automatizados para inspección, junto con robots especializados en tratamiento, coordinados por un sistema de gestión de misiones en la nube, proporciona una solución robusta, flexible y fácilmente replicable para entornos agrícolas estructurados. El uso de visión por computador y aprendizaje profundo para la detección de plagas, junto con navegación autónoma basada en ROS, demostró ser adecuado para tareas de precisión a baja velocidad en entornos reales.

Los resultados obtenidos en condiciones de campo validan el enfoque tanto desde el punto de vista técnico como práctico, destacando su potencial para ser aplicado en agricultura extensiva y como base para futuros desarrollos orientados hacia una agricultura más sostenible, autónoma e inteligente.

En cuanto al trabajo futuro, a partir de los resultados obtenidos, se identifican diversas oportunidades para evolucionar y ampliar el sistema multi-robot propuesto. Una de las principales prioridades es mejorar la capacidad de detección incorporando otro tipo de sensores, como por ejemplo los multispectrales, buscando disminuir la tasa de falsos positivos y mejorar la robustez del sistema frente a condiciones variables de iluminación y oclusión. También se contempla la aplicación de técnicas de aprendizaje continuo para adaptar los modelos de detección a nuevas variedades de cultivo y entornos agrícolas. Además, se planea evaluar la escalabilidad del sistema en otros tipos de cultivos y para distintas patologías, con el objetivo de validar su aplicabilidad generalizada. En cuanto a la planificación y ejecución de misiones, se considera esencial desarrollar estrategias de replanificación dinámica y gestión autónoma de recursos en tiempo real. Finalmente, las líneas de investigación futuras incluirán la exploración de mecanismos de cooperación entre robots que permitan una asignación óptima de tareas y rutas,

facilitando despliegues eficientes en superficies agrícolas extensas.

Agradecimientos

Este trabajo se ha realizado en el marco del proyecto FlexiGroBots, financiado por la Unión Europea, Programa H2020, con el acuerdo de subvención n.º 101017111. Los autores desean agradecer el valioso apoyo técnico de Damián Rodríguez.

Referencias

- Berger, G. S., Teixeira, M., Cantieri, A., Lima, J., Pereira, A. I., Valente, A. et al. (2023). Cooperative heterogeneous robots for autonomous insects trap monitoring system in a precision agriculture scenario. *Agriculture*, 13(2), 239.
- Cheng, C., Fu, J., Su, H., & Ren, L. (2023). Recent advancements in agriculture robots: Benefits and challenges. *Machines*, 11(1), 48.
- Hussain, M. (2024). Yolov1 to v8: Unveiling each variant—a comprehensive review of yolo. *IEEE Access*, 12, 42816–42833.
- Jiménez-Brenes, F. M., López-Granados, F., Torres-Sánchez, J., Peña, J. M., Ramírez, P., Castillejo-González, I. L., & de Castro, A. I. (2019). Automatic UAV-based detection of *Cynodon dactylon* for site-specific vineyard management. *PLoS one*, 14(6), e0218132.
- Ju, C., Kim, J., Seol, J., & Son, H. I. (2022). A review on multirobot systems in agriculture. *Computers and Electronics in Agriculture*, 202, 107336.
- Montes, H., & Ribeiro, A. (2023). Automation in Agriculture. In *Encyclopedia of Digital Agricultural Technologies* (pp. 92-105). Cham: Springer International Publishing.
- Quigley, M., Conley, K., Gerkey, B., Faust, J., Foote, T., Leibs, J. et al. (2009). ROS: an open-source Robot Operating System. Open-Source Software Workshop, Proc. Int. Conf. on Robotics and Automation (ICRA), Kobe, Japan. 12-17 May. 2009.
- Rizk, Y., Awad, M., & Tunstel, E. W. (2019). Cooperative heterogeneous multi-robot systems: A survey. *ACM Computing Surveys (CSUR)*, 52(2), 1-31.
- Sparrow, R., & Howard, M. (2021). Robots in agriculture: prospects, impacts, ethics, and policy. *Precision Agriculture*, 22, 818-833.
- Torres-Sánchez, J., Mesas-Carrascosa, F. J., Jiménez-Brenes, F. M., de Castro, A. I., & López-Granados, F. (2021). Early detection of broad-leaved and grass weeds in wide row crops using artificial neural networks and UAV imagery. *Agronomy*, 11(4), 749.
- Underwood, J. P., Hung, C., Whelan, B., & Sukkarieh, S. (2016). Mapping almond orchard canopy volume, flowers, fruit and yield using lidar and vision sensors. *Computers and electronics in agriculture*, 130, 83-96.