

Jornadas de Automática

Monitorización continua y autónoma de árboles frutales mediante imagen

Jaime Giménez-Gallego^{a,*}, Alejandro Gómez-López^a, Cristian Rodríguez-García^a, Honorio Navarro-Hellín^b, Roque Torres-Sánchez^a, Fulgencio Soto-Valles^a

^a Dpto. de Automática, Ingeniería Eléctrica y Tecnología Electrónica, ETSII, Universidad Politécnica de Cartagena (UPCT), 30202, Cartagena, España.

^b Widhac Smart Solutions, 30593, La Palma, Cartagena, España

To cite this article: Giménez-Gallego, J., Gómez-López, A., Rodríguez-García, C., Navarro-Hellín, H., Torres-Sánchez, R., Soto-Valles, F. 2026. Continuous and autonomous image-based fruit tree monitoring. Jornadas de Automática, 47. <https://doi.org/10.17979/ja-cea.2026.47.13809>

Resumen

En Agricultura de Precisión, es esencial una monitorización exhaustiva del estado del cultivo para optimizar la toma de decisiones sobre el uso de recursos hídricos y la logística de la cosecha. Sin embargo, la instrumentación y digitalización a gran escala en el sector agrícola depende de soluciones automáticas y de bajo coste. En este trabajo, se aborda la monitorización continua de frutos de mandarina en árbol, por medio de sensores de imagen visible instalados de forma fija. Se emplean técnicas de visión por computador, potenciadas por Inteligencia Artificial, para la segmentación de los frutos y el posterior análisis de sus parámetros visuales. A partir de los resultados de 24 sensores desplegados en campo durante una temporada completa, se demuestra la capacidad de reflejar tendencias en la evolución del crecimiento y maduración de los frutos. Además, se incluye una comparativa con medidas manuales de referencia, en la que se alcanzaron R^2 medios de 0.816 y 0.953 para tamaño y color respectivamente.

Palabras clave: Reconocimiento de patrones e IA en agricultura, Sensores de software en agricultura, Redes de sensores inalámbricos en agricultura, Sistemas de calificación y evaluación de la calidad, Apoyo a la toma de decisiones.

Continuous and autonomous image-based fruit tree monitoring

Abstract

In Precision Agriculture, exhaustive monitoring of crop status is essential to optimize decision-making regarding water use and harvest logistics. However, large-scale instrumentation and digitization in the agricultural sector depend on automated and low-cost solutions. This study addresses the continuous monitoring of tangerine fruit on trees using fixed visible-light image sensors. Computer vision techniques, powered by Artificial Intelligence, are employed for fruit segmentation and the subsequent analysis of their visual parameters. Based on the results from 24 sensors deployed in the field over a full growing season, the system's ability to reflect trends in fruit growth and ripening is demonstrated. Additionally, a comparison with manual reference measurements is included, yielding mean R^2 values of 0.816 and 0.953 for size and color, respectively.

Keywords: Pattern recognition and AI in agriculture, Software sensors in agriculture, Wireless sensor networks in agriculture, Grading systems and Quality assessment, Decision-making support.

1. Introducción

La crítica escasez de recursos hídricos en regiones áridas y semiáridas, como el sureste de España, motiva la investigación en la optimización de la producción agrícola.

En agricultura de precisión, el empleo de técnicas de riego deficitario controlado persigue minimizar el agua de riego sin provocar perjuicio sobre la cosecha (Blanco et al., 2019). Para ello, es imprescindible identificar correctamente la fase fenológica del cultivo, ya que existen periodos críticos, en los

que es indispensable satisfacer completamente las necesidades hídricas de la planta, y otros no críticos, en los que hay margen para el ahorro de agua (Blanco et al., 2019). Por tanto, la monitorización del cultivo es crucial para una aplicación precisa de estrategias de riego más eficientes.

En el caso de árboles frutales, es muy importante conocer el estado de los frutos. Su nivel de maduración y etapa de crecimiento permiten clasificar la fase fenológica del cultivo (Rizzo et al., 2023). Además, el seguimiento de estos parámetros, junto con el número de frutos, puede ofrecer información adicional relativa a la producción, como estimaciones de volumen y fecha de cosecha. Esto puede suponer una mejora logística, y repercutir favorablemente en la calidad y en la reducción del desperdicio de alimentos.

Existen múltiples estudios que abordan la medida de indicadores de maduración y calidad en muestras de frutos mediante diferentes equipos en laboratorio (Rizzo et al., 2023). Sin embargo, se trata de un proceso destructivo y que no es automatizable. Una alternativa es el uso de equipos portátiles para medida no destructiva in situ (Rizzo et al., 2023). El principal inconveniente es que es un proceso manual, difícilmente escalable a nivel de número de fincas y frecuencia de muestreo. La viabilidad para una implementación extendida en campo pasa por la automatización.

Las técnicas más avanzadas de visión por computador, basadas en Inteligencia Artificial (IA), han demostrado su capacidad para detectar y segmentar frutos en árboles, en condiciones de extrema complejidad, debida al fondo, las oclusiones y la iluminación (Giménez-Gallego et al., 2024b) (Giménez-Gallego et al., 2024a) (Gené-Mola et al., 2023). En ciertos casos, se optó por emplear vehículos terrestres (Chen et al., 2024) (Liu et al., 2026) o aéreos (Apolo-Apolo et al., 2020), que permiten cubrir un área extensa. No obstante, el coste y la necesidad de operarios especializados supone una restricción a su uso frecuente a lo largo de la temporada. Por ello, en otros trabajos, se decidió instalar la cámara en una plataforma fija (Giménez-Gallego et al., 2024a) (Wang et al., 2020) (Piani et al., 2025). A pesar de limitar el número de frutos monitorizados, esta estrategia posibilita la autonomía, continuidad y bajo coste de la medida. En (Wang et al., 2020) sólo se analizó el tamaño del fruto en la imagen, y en (Piani et al., 2025) únicamente se evaluó el sistema 1 día de medida. El presente trabajo se construye sobre la experiencia descrita en (Giménez-Gallego et al., 2024a), en el que se desarrolló un sensor basado en imagen visible para el seguimiento de tamaño y color de frutos, y se evaluó en campo, en cultivo de granado, durante varios años.

En esta nueva investigación se persiguen los siguientes objetivos: (1) Desarrollar un sensor de bajo coste basado en imagen para la monitorización continua y autónoma de parámetros visuales de frutos, en árbol de mandarino, con alimentación independiente de la red eléctrica, mediante batería y panel solar. (2) Entrenar un modelo de segmentación de instancias de última generación, más capaz y eficiente. (3) Evaluar su funcionamiento en finca comercial real a lo largo de una temporada a través de la instalación de 24 sensores en postes verticales. (4) Validar con medidas de referencia, tomadas con equipos manuales en muestras de frutos.

2. Materiales y Métodos

2.1. Instalación experimental

Los ensayos experimentales se llevaron a cabo en una finca comercial ubicada en Ulea, Murcia, España (38°11'07.2"N, 1°17'17.8"W). El cultivo objeto de estudio fue el árbol de mandarino (*Citrus reticulata*), variedad "Tango". Los árboles estaban plantados a una distancia de 2 m entre sí y de 5 m entre hileras. Las medidas analizadas en este trabajo se realizaron a lo largo de 2025 y principios de 2026, cubriendo una temporada agrícola completa. En la parcela experimental se desplegaron 24 sensores, repartidos en 12 hileras, para capturar imágenes de los frutos. Además, se instalaron 2 routers Wi-Fi LTE para la comunicación remota de las medidas a un servidor. Cada uno se alimentó a través de una batería LiFePO4 de 12V y 8Ah, conectada a un regulador de carga y cargada mediante un panel solar de 50W.

2.2. Instrumentación

Los sensores de imagen utilizados se equiparon prácticamente con el mismo hardware que los desarrollados en (Giménez-Gallego et al., 2024a): la unidad de procesamiento Raspberry Pi Zero W de Raspberry Pi Foundation (Cambridge, U.K.), con módulo Wi-Fi integrado; la cámara para Raspberry Pi Zero con sensor OV5647 (5 MP, f2.9); una tarjeta microSD de 32 GB para almacenamiento; una carcasa comercial IP67 de ABS; pasamuros para sellar el cable de alimentación; una ventana protectora para lente de cámara móvil de cristal templado y una sección de tubo de metacrilato transparente, como barrera ante la lluvia, pegadas a la tapa. Además, se integró un RTC DS3231 para Raspberry Pi, para conservar la hora en el dispositivo aunque no lograra conectarse a internet.

Respecto al montaje en campo, cada sensor se acopló a un poste metálico vertical, que se hincó en el terreno entre dos árboles de la misma hilera, quedando orientado hacia la hilera contigua (Figura 1). La altura a la que se fijaron las cámaras fue aproximadamente de 1.2 m, la cual se calculó en función de la altura de los árboles y la distancia entre hileras, con la pretensión de abarcar en el campo de visión los árboles de forma centrada.



Figura 1: Instalación de sensores y dataloggers en campo.

En cuanto a la alimentación, cada pareja de sensores se conectó a un datalogger D-Wide de WIDHOC Smart Solutions S.L. (Cartagena, España), dotado con 2 baterías de 3.7 V y 5000 mAh, cargadas por medio de un panel solar de

5W. El datalogger activaba y desactivaba un relé para alimentación de las Raspberry Pi en la franja correspondiente a la hora de captura. Un convertidor elevador a la salida del relé para cada sensor se encargaba de suministrar los 5V requeridos.

La frecuencia de adquisición de imágenes fue de una diaria, y la hora se definió próxima al amanecer, de forma dinámica en función de la hora de salida del Sol. En (Giménez-Gallego et al., 2024a) se concluyó que los mejores resultados se obtenían a primera hora de la mañana. Sin embargo, establecer una hora fija conlleva grandes diferencias en la iluminación en función de la fecha, lo que tiene especial incidencia en el caso de este cultivo, teniendo en cuenta que la temporada abarca prácticamente el año entero. Por ello, en este experimento, para tratar de minimizar este factor, cada día se calculaba la hora de amanecer, se sumaba un retraso de 45 minutos para dar margen a que el nivel de iluminación fuera suficiente, y se actualizaban consecuentemente las horas de activación del relé, por parte del datalogger, y de captura, por parte de la Raspberry Pi.

El sistema operativo instalado en la Raspberry Pi fue Raspbian GNU/Linux 10 (buster) y el lenguaje de programación empleado Python 3.7.3. La ejecución del programa de medida se automatizó usando crontab, utilidad Linux que permite la programación de tareas. Las imágenes se capturaron a la máxima resolución del sensor (2592×1944 píxeles), con ganancias roja y azul fijadas manualmente a 1.43 y 1.41, respectivamente, usando la librería Picamera. Una vez tomada la foto, esta se guardaba en local en la microSD y también se subía a la nube de OneDrive por medio de la librería Relone, que permite la sincronización de carpetas de archivos. Tras finalizar, el sensor se apagaba.

2.3. Segmentación de frutos

Para monitorizar automáticamente las características visuales de los frutos a partir de la imagen, es necesario un modelo de visión por computador que segmente las máscaras de los frutos. Con este fin, se optó por el modelo de Deep Learning para segmentación de instancias YOLO26-seg (Jocher and Qiu, 2026). Concretamente, se usó el modelo de tamaño “small”, por presentar un buen equilibrio entre precisión y velocidad. Los pesos del modelo disponibles para descarga son el resultado de un preentrenamiento en el popular dataset Microsoft COCO. Estos suponen una excelente base para las capacidades de segmentación generales del modelo, por lo que únicamente es necesario un proceso de “finetune” en un reducido conjunto de imágenes de ejemplo específicas para especializarlo en la tarea requerida.

Para ello, se reunió un dataset compuesto por 300 imágenes de mandarinos. Estas se tomaron en la finca experimental con la cámara de un teléfono móvil, en árboles aleatorios (distintos de los monitorizados por los sensores fijos instalados), desde diferentes distancias, orientaciones y en condiciones de iluminación variadas, para que la capacidad de generalización del modelo pudiera desarrollarse y evaluarse mejor. Además, cubrían el rango completo de maduración del fruto, siendo capturadas en múltiples fechas desde Diciembre de 2024 hasta Diciembre de 2025. La resolución original de las imágenes era de 4624×3472 píxeles

y se redimensionaron a 1280×960 píxeles para reducir el coste computacional de entrenamiento e inferencia. Se llevó a cabo una estratificación del dataset en 3 fases de maduración del fruto: inmaduro (Mayo-Octubre), transición (Octubre-Diciembre) y maduro (Diciembre-Enero). Para cada etapa, se seleccionaron 100 imágenes, pertenecientes en igual número a cada una de las diferentes fechas de captura correspondientes a dicho periodo. Así, se aseguró que todas las fases de maduración del fruto estaban equitativamente representadas. Para cada fecha de cada fase, el dataset se dividió en los subconjuntos de entrenamiento (70%), validación (15%) y test (15%), respetando la estratificación. El dataset se anotó manualmente en la plataforma Roboflow (“Roboflow Annotate,” n.d.), con asistencia de la herramienta basada en SAM 3 (Carion et al., 2025), que permite generar máscaras con un click. Como resultado, se obtuvo la máscara de cada fruto, sumando un total de 43386 mandarinas anotadas.

Respecto a los parámetros de entrenamiento del modelo, se configuraron los siguientes: `patience=20`, `imgsz=1280`, `batch=4`, `workers=4`, `optimizer='auto'` y `amp=True`. Además, se utilizó la técnica de “data augmentation”, para evitar el sobreajuste del modelo mediante la aplicación de pequeñas transformaciones geométricas y colorimétricas aleatorias sobre las imágenes, con los siguientes argumentos: `hsv_h=0.015`, `hsv_s=0.4`, `hsv_v=0.4`, `degrees=5`, `translate=0.1`, `scale=0.2`, `flip=0.5`. El entrenamiento duró 100 epochs. Al finalizar cada una, el modelo resultante se evaluó en el subconjunto de validación. Los pesos que obtuvieron mejores métricas en validación se escogieron para la evaluación final del modelo entrenado en el subconjunto independiente de test (sección 3.1.).

El equipo donde se ejecutó el entrenamiento y la inferencia del modelo de Deep Learning, así como el procesamiento posterior de las imágenes y máscaras, tomadas por los sensores en campo, contaba con las siguientes especificaciones: CPU Intel® Core™ i7-10875H 8 núcleos @ 2.30 GHz, RAM 32.0 GB @ 3200 MHz, GPU NVIDIA GeForce® RTX 2070 8 GB VRAM GDDR6. El lenguaje de programación empleado fue Python 3.11.15, y las principales librerías de IA instaladas: PyTorch 2.5.1, CUDA 12.1 y Ultralytics 8.4.49.

2.4. Medidas de frutos en imagen

A partir de las máscaras obtenidas del modelo de segmentación, es posible extraer información de interés agronómico del cultivo relativa a los frutos:

En primer lugar, el número de frutos en el árbol, dentro del campo de visión de la cámara, se correspondió con el número de instancias predichas por el modelo.

En segundo lugar, se calculó el tamaño de los frutos, relativo a la imagen. Para ello, con cada fruto, se ajustó un círculo al contorno de la máscara, mediante la función “minEnclosingCircle” de OpenCV, y el diámetro resultante en píxeles se dividió entre la dimensión máxima de la imagen.

Y, en tercer lugar, se determinó el color de los frutos en la imagen. Con el fin de minimizar el efecto de la heterogeneidad del color captado por la cámara en las diferentes fechas, provocado por las condiciones de iluminación ambiente variables en campo, se aplicó la normalización de Reinhard (Reinhard et al., 2001), tomando como parámetros de

referencia los siguientes: media (L, a, b) = [132.17 115.35 131.96]; desviación (L, a, b) = [56.72 8.20 9.39]. Además, para alcanzar mayor precisión en la estimación del color de los frutos, se utilizó la operación morfológica de erosión con un kernel de 7x7 píxeles sobre las máscaras. La intención era filtrar los píxeles del borde de las máscaras de los frutos que potencialmente podían corresponder con hojas o cielo erróneamente. Por tanto, el procedimiento para calcular el parámetro de color del fruto estimado a partir de la imagen consistió en: erosionar la máscara del modelo de segmentación, aplicarla sobre la imagen normalizada, y calcular en esos píxeles la mediana del canal H del espacio de color HSV.

Estos parámetros de los frutos se calcularon en las series temporales de imágenes diarias capturadas por los sensores instalados en la finca experimental, como se muestra en la sección 3.2. En el caso de que se detectasen menos de 10 frutos en una imagen o menos del 30% de la media de los 5 días anteriores, se consideró que era un error, que los datos de tamaño y color no eran representativos, y no se incluyeron en las series de resultados.

2.5. Validación con medidas manuales

Para validar la metodología de monitorización de tamaño y color de los frutos basada en imagen, propuesta en este trabajo, se llevó a cabo un análisis comparativo entre las medidas automáticas en imagen y medidas manuales en campo.

Las medidas manuales se realizaron aproximadamente cada 15 días, entre Agosto de 2025 y Enero de 2026, resultando un total de 9 fechas. Para cada cámara, se escogió una muestra de 3 frutos visibles en imagen, que se marcaron con cintas para asegurar la continuidad temporal de las medidas. El tamaño del fruto se midió con un calibre digital, con 0.1 mm de resolución y ± 0.2 mm de precisión. Para cada medida, se anotaron las dimensiones del diámetro máximo, diámetro mínimo y altura de la mandarina, y se calculó la media. En cuanto al color del fruto, se utilizó el colorímetro PCE-CSM 2 de PCE Instruments (Meschede, Germany). Para cada medida, se tomaron tres repeticiones en diferentes puntos de la superficie de la mandarina visible por la cámara, y se calculó la media del canal H del espacio de color HSV.

Respecto a las medidas en imagen, en las mismas fechas que habían tenido lugar las medidas manuales, se calcularon los parámetros de tamaño y color en todos los frutos detectados y se obtuvo la media.

3. Resultados y Discusión

3.1. Segmentación de frutos

El modelo de segmentación de instancias entrenado en el dataset de mandarinas se evaluó en el subconjunto de test, compuesto por 8244 frutos anotados (45 imágenes). Los resultados alcanzados se incluyen en la Tabla 1.

Tabla 1: Métricas del modelo de segmentación de frutos

mIoU	Precision	Recall	F1-score	mAP	Pred. time (ms/img)
0.686	0.809	0.602	0.690	0.606	26.11

Las métricas de precisión en la segmentación fueron inferiores a las logradas por otros autores del estado del arte en el campo de la segmentación de fruto (Miranda et al., 2023) (Giménez-Gallego et al., 2024b). Sin embargo, es importante remarcar la complejidad de este caso de estudio, en el que el tamaño de los frutos en imagen es muy reducido y son frecuentes las oclusiones. También hay que considerar el error humano en la anotación de las imágenes. Además, en el contexto de la aplicación que se propone, no se persigue un nivel de precisión extremo, puesto que la muestra de frutos en árbol es habitualmente de un tamaño tal, que puede absorber en cierto grado errores derivados de la segmentación o de la inclusión de falsos positivos, y no sería crítico para la representatividad de la misma la existencia de falsos negativos. Por tanto, los resultados obtenidos se consideraron suficientes para la aplicación prevista.

Respecto al tiempo de predicción, se calculó el valor mediano, más robusto que la media ante el warm-up de la GPU, en el conjunto de test (Tabla 1). Se considera que 26.11 ms es un resultado apropiado para el hardware, la arquitectura del modelo y la resolución de imagen empleados, y es notablemente inferior al de Mask R-CNN (Giménez-Gallego et al., 2024b).

3.2. Medidas de frutos en imagen

A continuación, se presentan ejemplos de resultados sobre las secuencias de imágenes registradas por los sensores en campo (Figura 2).

A la vista de los resultados, se demuestra una excelente capacidad del modelo de segmentación para detectar con éxito los frutos en imágenes con gran densidad. Visualmente, no se aprecian errores destacados en la detección en cuanto a falsos positivos ni negativos, especialmente a partir de una fecha más avanzada de la temporada, en la que el crecimiento del fruto ha progresado.

En cuanto a la evolución del conteo, se observa un incremento en el número de frutos a lo largo de la temporada. La explicación reside en que, conforme estos aumentan de tamaño y cambian de color, su visibilidad se intensifica de cara al modelo de segmentación, por lo que el número de frutos detectados crece. Se trata de la curva más ruidosa y la justificación de las bruscas oscilaciones en el conteo de los frutos se puede deber a varios factores intrínsecos a la naturaleza de la instrumentación en campo: la suciedad en la lente de la cámara, que se acumula de forma natural por el polvo y la lluvia, y, principalmente, por la proyección de fertilizantes e insecticidas sobre las hojas; los días con iluminación especialmente desfavorable; y la oclusión por ramas que se interponen delante del objetivo debido a su natural crecimiento o caída por el aumento de peso en los frutos. Para tratar de paliar el efecto de estos factores sobre las imágenes (que también afecta a tamaño y color), se realizó un mantenimiento periódico, entre cada 15 días y un mes, que consistió en la limpieza de las ventanas protectoras de las cámaras y la recolocación de ramas problemáticas.

Respecto a la evolución de tamaño, se aprecia claramente una división entre una primera fase de crecimiento lineal del fruto y una segunda sin crecimiento (tamaño constante). Además, en las series temporales recabadas por todas las cámaras, el cambio de tendencia que lleva de una fase a otra

acontece en fechas similares (aproximadamente a final de octubre).




Figura 2: [Cámara 1] (a.1-4) Imágenes originales; (b.1-4) Máscaras predichas representadas a color original y con contorno azul sobre imágenes a escala de grises; (a.1 y b.1) 2025/07/17; (a.2 y b.2) 2025/09/15; (a.3 y b.3) 2025/11/15; (a.4 y b.4) 2026/01/15; (c) Evolución temporal del número de frutos; (d) Evolución temporal de la media del tamaño relativo de los frutos; (e) Evolución temporal de la media del color de los frutos.

En las curvas de evolución de color, también se distinguen fases notablemente diferenciadas. En este caso, existe una primera fase sin evolución de color del fruto, una segunda fase de transición hacia la madurez (habitualmente en noviembre), y una tercera de nuevo sin cambio en la que los frutos ya han madurado. Las fechas de transición entre fases son similares para todas las cámaras. Además, el paso de la primera a la segunda fase, que desata el llamativo viraje de color, ocurre en fechas sincronizadas con las del cambio de tendencia comentado en las series de tamaño. Es decir, prácticamente a la vez, el fruto deja de crecer y empieza a cambiar de color. Este fenómeno tan característico se ha logrado capturar notablemente con todos los sensores instalados. Además, en todas las cámaras, los rangos del parámetro de color para fruto inmaduro y maduro son consistentes entre sí.

3.3. Validación con medidas manuales

Las medidas manuales llevadas a cabo en la instalación experimental se compararon con las obtenidas de las imágenes para cada sensor (Figuras 3 y 4).




Figura 3: [Cámara 4] Series temporales de medidas de tamaño manuales y en imagen.




Figura 4: [Cámara 4] Series temporales de medidas de color manuales y en imagen.

En las gráficas, se manifiesta un correcto solapamiento entre ambas curvas. Además, las series manuales presentan las mismas fases de crecimiento y maduración que las comentadas en la sección anterior sobre las series de imágenes.

También se calculó la correlación entre las medidas manuales y basadas en imagen de tamaño y color de los frutos para cada cámara. El coeficiente R^2 medio para los 24 sensores resultó 0.816 y 0.953 para tamaño y color respectivamente (Tabla 2).

Tabla 2: Métricas de correlación entre medidas manuales y en imagen.

R ²	Medio	Mediano	Desv.	Min.	Max.
Tamaño	0.816	0.831	0.110	0.557	0.956
Color	0.953	0.965	0.038	0.821	0.989

Adicionalmente, se calculó la correlación del color para todas las cámaras de forma conjunta. Se obtuvo un coeficiente R^2 de 0.93. En este caso, no se pudo replicar para el tamaño, debido a que es un parámetro relativo.

Los coeficientes R^2 tan elevados alcanzados en este experimento demuestran una muy fuerte correlación entre ambas medidas. Por tanto, se valida firmemente la metodología propuesta para monitorizar de forma continua y automática los parámetros visuales de los frutos, de cara a extraer información en tiempo real de interés para el agricultor sobre el estado de su cultivo.

4. Conclusiones

En este trabajo, se ha presentado una solución para la monitorización continua y autónoma de árboles frutales mediante imagen. La metodología propuesta se ha validado extensamente a través de resultados experimentales de 24 sensores en condiciones reales a lo largo de una temporada completa. Se demostró que la medida automática diaria del tamaño relativo y color de los frutos a partir de la imagen se podría utilizar para informar acerca de la evolución de su crecimiento y maduración. La comparativa con equipos manuales de medida directa en muestras de frutos evidenció una fuerte correlación: R^2 medio en los 24 sensores de 0.816 para tamaño con calibre y 0.953 para color con colorímetro.

Aunque los indicadores visuales no pueden reemplazar los parámetros obtenidos mediante ensayos destructivos en laboratorio, se podría emplear como herramienta complementaria. El sistema descrito ofrece numerosas ventajas frente a dispositivos operados manualmente in situ o sobre muestras recogidas en laboratorio: la medida es continua, una mayor frecuencia no supone un incremento en los costes operativos; la medida en todos los frutos de diferentes fincas se puede realizar simultáneamente; es una solución escalable, debido al bajo coste del sensor y su fácil instalación, además del reducido coste computacional del modelo de segmentación escogido, lo que hace viable procesar las imágenes de múltiples sensores desde un mismo servidor; y la medida se efectúa de forma remota, no destructiva y es accesible inmediatamente.

La monitorización de los frutos se podría aplicar para identificar tendencias de crecimiento y evolución del color, lo que permitiría estimar la etapa de maduración del cultivo. Esto es crucial para ajustar de forma precisa el riego, diagnosticar posibles problemas y predecir la fecha de cosecha. Además, por medio del conteo de frutos, se podría predecir el volumen de cosecha o cuantificar la merma ocasionada por una plaga. Todo ello, muy relevante para la planificación logística de la cosecha y conllevaría una mejora en la calidad del fruto. La metodología propuesta en esta investigación sería aplicable a otros cultivos frutales y hortícolas. Como trabajo futuro, a partir de las series temporales de parámetros visuales de los frutos, se pretenden extraer indicadores agronómicos derivados e integrarlo en un sistema de apoyo a la decisión para el agricultor junto con otros sensores de suelo, planta y atmósfera.

Agradecimientos

Este trabajo es parte del proyecto CPP2023-010502 financiado por MICIU/AEI /10.13039/501100011033 y por

FEDER, UE. También es resultado del programa AGROALNEXT y ha sido apoyado por MCIN con financiación de la Unión Europea NextGenerationEU (PRTR-C17.I1) y por la Fundación Séneca con financiación de la CARM.

Referencias

- Apolo-Apolo, O.E., Martínez-Guanter, J., Egea, G., Raja, P., Pérez-Ruiz, M., 2020. Deep learning techniques for estimation of the yield and size of citrus fruits using a UAV. *Eur. J. Agron.* 115, 126030. <https://doi.org/10.1016/j.eja.2020.126030>
- Blanco, V., Torres-Sánchez, R., Blaya-Ros, P.J., Pérez-Pastor, A., Domingo, R., 2019. Vegetative and reproductive response of 'Prime Giant' sweet cherry trees to regulated deficit irrigation. *Sci. Hortic. (Amsterdam)*. 249, 478–489. <https://doi.org/10.1016/J.SCI.2019.02.016>
- Carion, N., Gustafson, L., Hu, Y.-T., Debnath, S., Hu, R., Suris, D., Ryali, C., Vasudev Alwala, K., Khedr, H., Huang, A., Lei, J., Ma, T., Guo, B., Kalla, A., Marks, M., Greer, J., Wang, M., Sun, P., Rädle, R., Afouras, T., Mavroudi, E., Xu, K., Wu, T.-H., Zhou, Y., Momeni, L., Hazra, R., Ding, S., Vaze, S., Porcher, F., Li, F., Li, S., Kamath, A., Cheng, H.K., Dollár, P., Ravi, N., Saenko, K., Zhang, P., Feichtenhofer, C., 2025. SAM 3: Segment Anything with Concepts. *arxiv*.
- Chen, M., Chen, Z., Luo, L., Tang, Y., Cheng, J., Wei, H., Wang, J., 2024. Dynamic visual servo control methods for continuous operation of a fruit harvesting robot working throughout an orchard. *Comput. Electron. Agric.* 219, 108774. <https://doi.org/10.1016/J.COMPAG.2024.108774>
- Gené-Mola, J., Ferrer-Ferrer, M., Gregorio, E., Blok, P.M., Hemming, J., Morros, J.R., Rosell-Polo, J.R., Vilaplana, V., Ruiz-Hidalgo, J., 2023. Looking behind occlusions: A study on amodal segmentation for robust on-tree apple fruit size estimation. *Comput. Electron. Agric.* 209. <https://doi.org/10.1016/j.compag.2023.107854>
- Giménez-Gallego, J., Martínez-del-Rincon, J., Blaya-Ros, P.J., Navarro-Hellín, H., Navarro, P.J., Torres-Sánchez, R., 2024a. Fruit Monitoring and Harvest Date Prediction Using On-Tree Automatic Image Tracking. *IEEE Trans. AgriFood Electron.* 3, 56–68. <https://doi.org/10.1109/TAFE.2024.3408912>
- Giménez-Gallego, J., Martínez-del-Rincon, J., González-Teruel, J.D., Navarro-Hellín, H., Navarro, P.J., Torres-Sánchez, R., 2024b. On-tree fruit image segmentation comparing Mask R-CNN and Vision Transformer models. Application in a novel algorithm for pixel-based fruit size estimation. *Comput. Electron. Agric.* 222, 109077. <https://doi.org/10.1016/J.COMPAG.2024.109077>
- Jocher, G., Qiu, J., 2026. Ultralytics YOLOv6 [WWW Document]. URL <https://github.com/ultralytics/ultralytics>
- Liu, S., Ampatzidis, Y., Guan, H., Liu, W., Zhou, C., Choi, D., Lee, W.S., 2026. Agrosense v2: An AI-enabled system for precision orchard sensing and tree-level monitoring. *Comput. Electron. Agric.* 248, 111797. <https://doi.org/10.1016/J.COMPAG.2026.111797>
- Miranda, J.C., Gené-Mola, J., Zude-Sasse, M., Tsoulas, N., Escolà, A., Arnó, J., Rosell-Polo, J.R., Sanz-Cortiella, R., Martínez-Casasnovas, J.A., Gregorio, E., 2023. Fruit sizing using AI: A review of methods and challenges. *Postharvest Biol. Technol.* 206, 112587. <https://doi.org/10.1016/J.POSTHARVIBIO.2023.112587>
- Piani, M., Scalisi, A., Bortolotti, G., Mengoli, D., Manfrini, L., 2025. Evaluating Orchard Fruit Quality from Monocular and Stereo RGB-D Imagery: A Comparative Study, in: 2025 IEEE International Workshop on Metrology for Agriculture and Forestry (MetroAgriFor). IEEE, pp. 51–56. <https://doi.org/10.1109/METROAGRIFOR66923.2025.11512584>
- Reinhard, E., Ashikhmin, M., Gooch, B., Shirley, P., 2001. Color transfer between images. *IEEE Comput. Graph. Appl.* 21, 34–41. <https://doi.org/10.1109/38.946629>
- Rizzo, M., Marcuzzo, M., Zangari, A., Gasparetto, A., Albarelli, A., 2023. Fruit ripeness classification: A survey. *Artif. Intell. Agric.* 7, 44–57. <https://doi.org/10.1016/j.aiia.2023.02.004>
- Roboflow Annotate [WWW Document], n.d. URL <https://roboflow.com/annotate> (accessed 6.3.26).
- Wang, D., Li, C., Song, H., Xiong, H., Liu, C., He, D., 2020. Deep Learning Approach for Apple Edge Detection to Remotely Monitor Apple Growth in Orchards. *IEEE Access* 8, 26911–26925. <https://doi.org/10.1109/ACCESS.2020.2971524>