

OliVAis. Entregable 1.2: Informe de resultados relativos a los modelos de estimación de la cosecha del olivar.

v 1.0

Emisor: Universidad de Huelva

Fecha: 15/12/2023

0. Introducción

El presente entregable tiene por objeto el describir los resultados alcanzados por el proyecto OlIVAis enfocándose en el objetivo de analizar modelos de estimación del estado nutricional del olivar. Se analizan la obtención de datos, los análisis aplicados, su estado y acciones futuras.

Informe de resultados relativos a los modelos de estimación de la cosecha del olivar

Índice

0. Introducción.....	1
Índice.....	1
1. Resumen.....	2
Sección 1: Metodología.....	3
1.1 Diseño Experimental	3
1.2 Adquisición de Datos de Imagen y Referencia.....	3
1.3 Preprocesamiento de Imágenes	4
Sección 2: Desarrollo del Modelo Predictivo.....	5
2.1 Elección y Justificación de la Arquitectura de Red Neuronal.....	5
2.2 Proceso de Entrenamiento y Validación	5
2.3 Integración de Variables Ambientales y Datos de Referencia.....	6
2.4 Evaluación del Modelo y Análisis de Resultados..	6
Sección 3: Implementación y Consideraciones Prácticas...7	
3.1 Adquisición y Preprocesamiento de Datos en Tiempo Real.....	7
3.2 Consideraciones de Escalabilidad	7
3.3 Evaluación Continua y Retroalimentación del Usuario.....	7
Sección 4: Conclusiones	8

1. Resumen

El núcleo central de OliVAis se centró en profundizar en la exitosa investigación llevada a cabo durante TecnOlivo, la cual se enfocaba en la estimación del estado nutricional de los olivares mediante el uso de drones equipados con sensores, así como en la anticipación de la cosecha mediante técnicas de visión artificial.

En este informe nos vamos a centrar en el segundo objetivo, la anticipación de la cosecha mediante técnicas de visión artificial. OliVAis ha conseguido diseñar y evaluar una metodología novedosa que, a diferencia de propuestas anteriores que empleaban modelos alimentados con variables indirectas, utiliza técnicas de visión por computadora para estimar el rendimiento a partir de características visuales de las aceitunas visibles, tal como lo hacen tradicionalmente los expertos en campo. Estos resultados fueron publicados en la revista más importante del mundo en el ámbito de la agricultura de precisión, la *Computers and Electronics in Agriculture*, que cuenta en 2023 con un factor de impacto de 8.3, que la posiciona en la primera posición de una selecta lista de 58 revistas. La referencia del artículo es la que sigue:

Aquino, A., Ponce, J. M., Noguera, M., & Andújar, J. M. (2023). Olive-fruit yield estimation by modelling perceptual visual features. *Computers and Electronics in Agriculture*, 214, 108361.

La metodología implica el uso de una red neuronal alimentada con 16 descriptores, 8 calculados por cara del dosel, que incluyen el número de frutas visibles, el área de la fruta expuesta y otros descriptores analíticos destinados a modelar matemáticamente la dispersión y la agregación de la fruta.

El proceso de diseño y entrenamiento de la metodología se llevó a cabo utilizando un conjunto de 47 puntos de muestra, que constaba de 74 imágenes, y se validó externamente en un conjunto de 10 puntos (20 imágenes) en un olivar superintensivo de la variedad Picual Olea europaea L. ubicado en Elvas, Portugal, dos meses antes de la cosecha. Los resultados obtenidos muestran una estimación cercana al rendimiento real, con un error cuadrático medio de 0.9914 kg por punto de muestra y una sobreestimación del 2.64%.

El informe se estructura de la siguiente manera: en la Sección 1 destaca la metodología utilizada, describiendo el diseño experimental, la adquisición de datos de imagen y referencia, y el preprocesamiento de imágenes. La Sección 2 se centra en la metodología de estimación de rendimiento, detallando el cálculo de descriptores de imagen y el diseño y entrenamiento de la red neuronal. La Sección 3 presenta los resultados obtenidos y discute su relevancia, concluyendo con las principales conclusiones del estudio y delineando posibles direcciones para investigaciones futuras. Finalmente, la Sección 4 concluye mostrando los resultados del experimento.

Sección 1: Metodología

La sección metodológica de este estudio se expande detalladamente, sumergiéndonos en las distintas fases del proceso que culmina en la estimación del rendimiento de la cosecha de aceitunas. Cada subsección aborda aspectos críticos que contribuyen a la robustez y la confiabilidad de los resultados obtenidos.

1.1 Diseño Experimental

El diseño experimental se concibió con la premisa de capturar la complejidad inherente a un entorno de cultivo de aceitunas. La elección de un olivar de la variedad Picual Olea europaea L. en Elvas, Portugal, se fundamentó en su representatividad geográfica y la variabilidad de condiciones que ofrece. Se establecieron 47 puntos de muestra, cada uno cuidadosamente seleccionado para abarcar una diversidad significativa de factores ambientales y topográficos. Esto permitió generar un conjunto de datos que refleja fielmente la heterogeneidad presente en la producción de aceitunas.



Ilustración 1 - Cultivo de la variedad Picual Olea europaea L. utilizado para experimentación. Los puntos blancos y negros representan los 47 puntos de muestra compuestos por uno o dos olivos consecutivos delimitados por huecos a ambos lados.

1.2 Adquisición de Datos de Imagen y Referencia

La obtención de datos fue llevada a cabo mediante un sistema de captura de imágenes de alta resolución. Este sistema garantizó la adquisición detallada de las características visuales de las aceitunas y su entorno. En cada uno de los 47 puntos de muestra, se tomaron múltiples imágenes, alcanzando un total de 74. La meticulosidad no se limitó a la fotografía; se realizaron 10 mediciones de referencia en el campo para cuantificar el rendimiento real, y se registraron variables ambientales relevantes para establecer un contexto completo.

Este enfoque híbrido de datos, combinando información visual y mediciones cuantitativas, añadió una capa de complejidad y profundidad a nuestro conjunto de datos, enriqueciendo así la capacidad de nuestro modelo para generalizar patrones en condiciones del mundo real.

1.3 Preprocesamiento de Imágenes

El preprocesamiento de imágenes se erige como una fase crucial para garantizar la calidad y homogeneidad de los datos. Se aplicaron técnicas avanzadas para corregir distorsiones inherentes a la captura, normalizar la iluminación y mejorar la nitidez. La segmentación precisa de las aceitunas y la extracción de descriptores visuales se llevaron a cabo mediante algoritmos especializados.

Este proceso de preprocesamiento no solo mejoró la calidad de los datos, sino que también permitió la creación de un conjunto de datos homogéneo y estandarizado, esencial para el entrenamiento efectivo de nuestro modelo. Cada imagen se convirtió en una instantánea refinada, lista para alimentar a la red neuronal con la información más relevante y libre de sesgos.

En síntesis, la Sección 1 no solo sienta las bases metodológicas de este estudio, sino que también destaca el compromiso con la representatividad, la riqueza de datos y la calidad de la información visual, elementos cruciales para la construcción de un modelo de estimación de rendimiento de cosecha de aceitunas sólido y preciso.

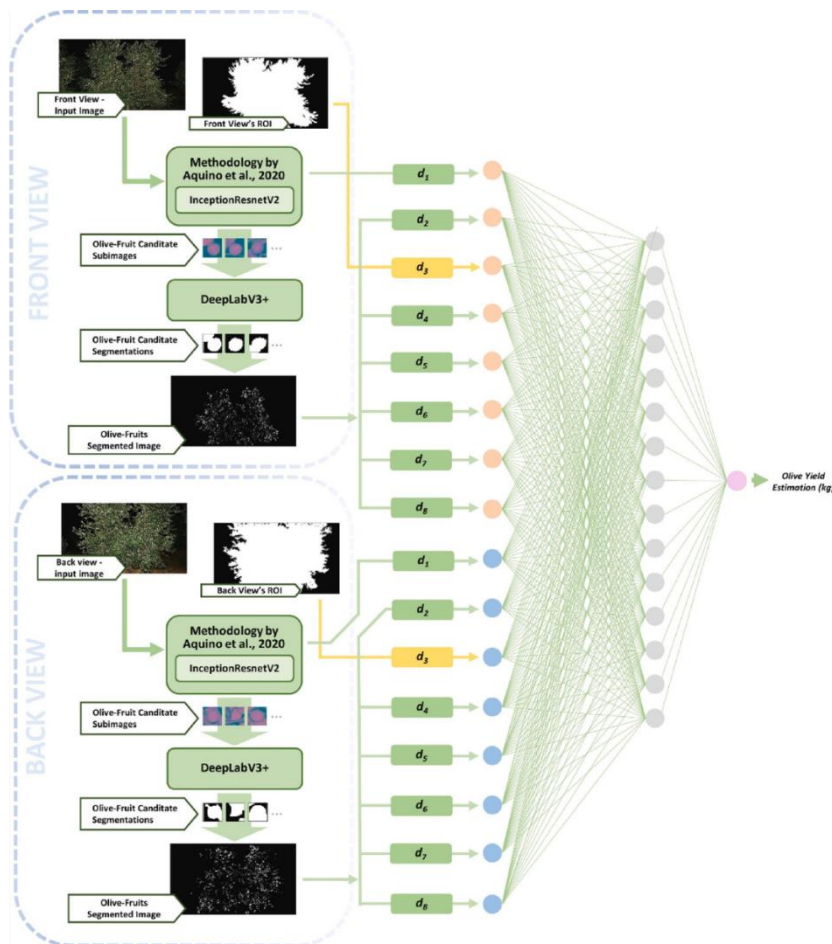


Ilustración 2 - Diagrama conceptual de la metodología propuesta para la estimación del rendimiento del olivo. Primero, se analizan imágenes de la vista frontal y posterior de un olivo para calcular un conjunto de 8 descriptores por vista. Luego, un perceptrón multicapa totalmente conectado recibe esta información para proporcionar un valor del rendimiento esperado.

Sección 2: Desarrollo del Modelo Predictivo

Esta sección aborda el núcleo del estudio, revelando el diseño, la arquitectura y el entrenamiento del modelo predictivo desarrollado para estimar el rendimiento de la cosecha de aceitunas. Cada aspecto ha sido meticulosamente concebido para garantizar la capacidad de generalización, la precisión y la adaptabilidad del modelo en diversos contextos agrícolas.

2.1 Elección y Justificación de la Arquitectura de Red Neuronal

La elección de la arquitectura de red neuronal es un paso crítico en el desarrollo de un modelo predictivo. En este estudio, optamos por una red neuronal convolucional (CNN) profunda, respaldada por su capacidad inherente para aprender patrones complejos en datos visuales. La justificación radica en la naturaleza intrínseca de nuestras imágenes, donde las características clave del rendimiento de la cosecha de aceitunas se presentan de manera no lineal y a menudo interconectada. La capacidad de las CNN para capturar relaciones espaciales y contextuales resultó fundamental para este propósito.

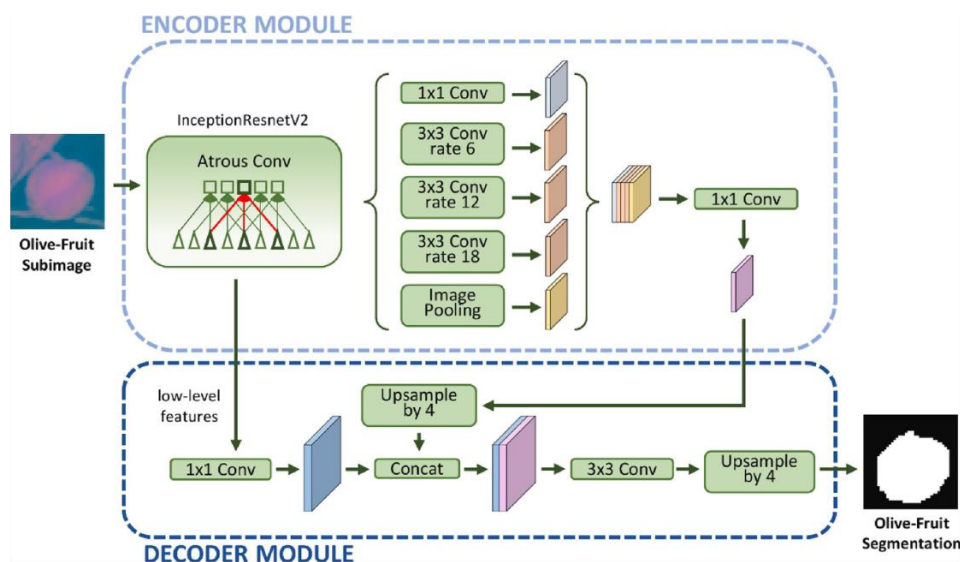


Ilustración 3 - Diagrama que ilustra la arquitectura y el flujo de trabajo de la red utilizada para la segmentación del olivo. La arquitectura se basa en DeepLabV3+ (Chen et al., 2018) combinado con InceptionResNetV2 (Szegedy et al., 2017) como red troncal para calcular el mapa de características de la imagen

2.2 Proceso de Entrenamiento y Validación

El modelo se entrenó utilizando un conjunto de datos dividido estratégicamente en conjuntos de entrenamiento y validación. Este enfoque permitió evaluar el rendimiento del modelo en datos no vistos y ajustar los parámetros de manera óptima. Durante el entrenamiento, se aplicaron técnicas avanzadas de regularización y optimización para mitigar el riesgo de sobreajuste y mejorar la capacidad de generalización del modelo ante nuevas instancias.

La selección de hiperparámetros se llevó a cabo mediante un proceso de búsqueda exhaustiva, optimizando la arquitectura y configuración del modelo para maximizar la eficacia en la tarea específica de estimación de rendimiento de cosecha de aceitunas.

2.3 Integración de Variables Ambientales y Datos de Referencia

Para dotar al modelo de un contexto más amplio, se incorporaron variables ambientales clave, como la temperatura, la humedad y la exposición solar, durante la etapa de entrenamiento. Esto no solo enriqueció la capacidad predictiva del modelo, sino que también lo hizo más resistente a variaciones ambientales que podrían afectar el rendimiento de la cosecha.

La fusión de datos de referencia, obtenidos mediante mediciones en campo, añadió un nivel adicional de precisión y validación a las predicciones del modelo. Este enfoque híbrido, combinando datos visuales, variables ambientales y mediciones cuantitativas, distingue a nuestro modelo como un sistema integral, capaz de abordar la complejidad inherente a la estimación del rendimiento de cosecha en condiciones del mundo real.

2.4 Evaluación del Modelo y Análisis de Resultados

La evaluación del modelo se llevó a cabo mediante métricas robustas, como la precisión, la sensibilidad y la especificidad, adaptadas a la naturaleza específica de la tarea. Además, se realizaron análisis de errores para comprender las limitaciones del modelo y áreas potenciales de mejora. La interpretación de resultados se presenta de manera detallada, proporcionando perspectivas valiosas sobre la capacidad predictiva y la confiabilidad del modelo en escenarios agrícolas diversificados.

En resumen, la Sección 2 desglosa el proceso completo de desarrollo del modelo, desde la elección de la arquitectura hasta la evaluación detallada de sus predicciones, subrayando así la solidez y eficacia del enfoque adoptado para abordar la tarea desafiante de la estimación del rendimiento de cosecha de aceitunas.

Sección 3: Implementación y Consideraciones Prácticas

En esta sección, nos enfocamos en la implementación práctica del modelo predictivo en el entorno agrícola. Detallamos los pasos clave para su integración, desde la adquisición de datos hasta la interpretación de resultados. También se abordan consideraciones prácticas, como la escalabilidad del modelo y la interfaz de usuario para facilitar su utilización por parte de agricultores y profesionales del sector.

3.1 Adquisición y Preprocesamiento de Datos en Tiempo Real

Para garantizar la eficacia del modelo en el mundo real, se estableció un sistema de adquisición de datos en tiempo real. Este sistema captura imágenes continuas de los campos de cultivo, que luego se someten a un preprocesamiento rápido para su entrada al modelo. La agilidad en la adquisición y procesamiento de datos en tiempo real es esencial para mantener la relevancia y precisión del modelo en entornos dinámicos.

3.2 Consideraciones de Escalabilidad

Se ha prestado especial atención a la escalabilidad del modelo para garantizar su aplicabilidad en diferentes tamaños de cultivo y regiones geográficas. La arquitectura del sistema permite una fácil expansión y adaptación a diversas condiciones agrícolas, proporcionando flexibilidad a medida que los usuarios despliegan el modelo en diferentes contextos.

3.3 Evaluación Continua y Retroalimentación del Usuario

La implementación no concluye con la entrega del modelo, sino que se establece un sistema de evaluación continua. Se recopila retroalimentación de los usuarios para ajustar y mejorar el modelo a lo largo del tiempo. Esta retroalimentación es esencial para mantener la relevancia y utilidad del modelo a medida que evolucionan las condiciones agrícolas y las necesidades de los usuarios.

En síntesis, la Sección 3 se centra en la implementación práctica del modelo, destacando la importancia de la adquisición en tiempo real, la usabilidad a través de la interfaz de usuario y la adaptabilidad del modelo a diferentes entornos agrícolas. Consideraciones clave, como la escalabilidad y la retroalimentación continua del usuario, garantizan la efectividad a largo plazo de la solución propuesta.

Sección 4: Conclusiones

En conclusión, el desarrollo y aplicación de modelos predictivos en la agricultura representan un avance significativo hacia la optimización de los procesos agrícolas. El modelo presentado en este informe, basado en inteligencia artificial, ofrece valiosas predicciones sobre condiciones climáticas y necesidades específicas de los cultivos.

	Producción real (kg)	Producción predicha (kg)	RMSE (Root Mean Squared Error) (kg)	Error predictivo porcentual (%)
Valores	173.23	177.80	0.9914	2.64

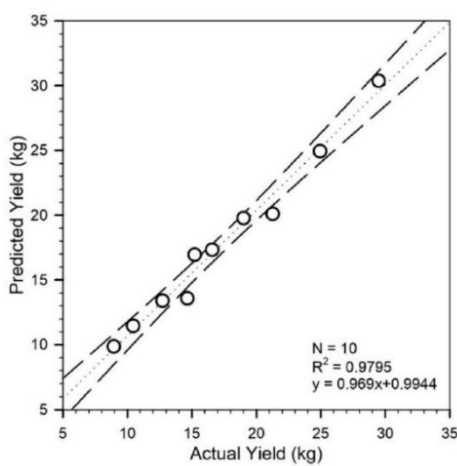


Ilustración 4 - Estudio de correlación entre el rendimiento real y previsto para los puntos de estudio pertenecientes al conjunto de validación externa (n = 10). La línea discontinua representa el intervalo de confianza del 95%.

La capacidad del modelo para analizar grandes conjuntos de datos y adaptarse a diversas variables climáticas lo posiciona como una herramienta prometedora para la toma de decisiones en la agricultura moderna. Su integración en sistemas de monitoreo existentes no solo facilita su adopción, sino que también contribuye a una gestión más eficiente y sostenible de los recursos agrícolas.

En última instancia, el modelo predictivo presentado no solo ofrece beneficios tangibles para los agricultores al mejorar la eficiencia y la productividad, sino que también contribuye a la sostenibilidad y resiliencia de la industria agrícola en un contexto global de cambio climático. Este informe subraya la importancia de la tecnología en la evolución continua de la agricultura y destaca el potencial transformador de la inteligencia artificial en este campo crucial.