

ESTIMACIÓN AUTOMATIZADA DEL PESO Y CALIBRE DE ACEITUNAS MEDIANTE ANÁLISIS DE IMAGEN

Juan M. Ponce

¹Departamento de Ingeniería Electrónica, Sistemas Informáticos y Automática, Universidad de Huelva, Carretera Huelva - Palos de la Frontera s/n, 21819, La Rábida, Palos de la Frontera (Huelva), jmponce.real@diesia.uhu.es

Arturo Aquino¹, arturo.aquino@diesia.uhu.es; Francisca Segura¹, francisca.segura@diesia.uhu.es; Borja Millán¹, borja.millan@diesia.uhu.es; J. M. Andújar¹, andujar@diesia.uhu.es

Resumen

El calibrado y selección de productos agrícolas es una actividad de gran relevancia dentro de la industria agroalimentaria. Este estudio, centrado en el sector del olivo, presenta una solución basada en análisis de imagen que permite la estimación automática y no invasiva del peso y calibre (ejes de simetría mayor y menor) de un conjunto de aceitunas, a partir de una serie de fotografías de las mismas. Utilizando dos variedades distintas de aceituna (Arbequina y Picual), se ha desarrollado un algoritmo de segmentación, a partir del cual se extrae la información necesaria para computar modelos de estimación para cada uno de los parámetros considerados. Una vez aplicados dichos modelos sobre los correspondientes conjuntos de validación, se ha podido comprobar, a través del cálculo de la raíz del error cuadrático medio (RMSE) cometido, la eficacia del método propuesto y su validez como base para el desarrollo de un sistema de calibrado de aceitunas de bajo coste basado en visión artificial.

Palabras clave: aceituna, peso, calibre, segmentación, visión artificial, estimación.

1 INTRODUCCIÓN

El cultivo del olivo se ha convertido en una actividad agrícola de gran peso y relevancia en la actualidad. Con gran presencia y tradición en la cuenca mediterránea, zona que ha concentrado históricamente a los principales países productores, su laboreo se ha extendido alrededor de todo el mundo en las últimas décadas, y ya es practicada en lugares tan dispares como el continente americano, Australia y Nueva Zelanda, e incluso en China o el sudeste asiático [4]. La principal razón de dicha expansión pasa por el espectacular auge en popularidad y el creciente consumo de los principales productos que derivan de la industria sustentada por dicho cultivo: las aceitunas

de mesa y el aceite de oliva. No en vano, y de acuerdo con datos del Consejo Oleícola Internacional (COI), el consumo de aceitunas de mesa se ha visto incrementado en más de un 170% en los últimos 25 años [4], y las expectativas de consumo de aceite de oliva, para el curso 2017/18, son de 3.000.000 toneladas a nivel mundial [12]. Con el objeto de satisfacer esta creciente demanda, toda la industria generada alrededor del olivo ha de afrontar numerosos retos, muchos de ellos de carácter tecnológico, ante la imperativa necesidad de modernización de todos sus procesos.

El tamaño y peso, además de otras características físicas, de los productos derivados de la actividad agrícola son datos de gran valor para su industria [6]. La clasificación y/o selección de los frutos en base a estos parámetros es tarea de especial importancia en según qué cultivos, siendo de vital relevancia en el caso del fruto del olivo [5, 9]. Así, en el caso de, por ejemplo, la aceituna de mesa, el proceso de calibrado, y la precisión del mismo, tienen un especial impacto en el producto final, dadas las expectativas de homogeneidad en cuanto a tamaño que se le presupone al consumidor final.

Frente a las tradicionales soluciones de carácter mecánico, los sistemas de visión artificial comienzan a ganar interés dentro de la industria de transformación agroalimentaria [1,3,7,8]. Ante este escenario, este tipo de tecnología puede ser de gran valía dentro del sector oleícola ya que no sólo abre la puerta a sistemas de clasificación y selección del fruto menos agresivos con éste, sino que además hacen posible la adquisición de una información antes inaccesible.

El presente estudio propone un sistema de estimación de peso y calibre (ejes mayor y menor) basado en análisis de imagen. En concreto, el método presentado es capaz de estimar el peso, así como los diámetros mayor y menor de cada una de las aceitunas contenidas en una imagen digital, empleando técnicas

basadas en morfología matemática y segmentación por umbralización. Dicha metodología es desarrollada a lo largo de la siguiente sección. Así, en primer lugar, se recoge en detalle cómo se ha realizado la captura de las imágenes, además de las mediciones de peso y calibre de cada uno de los frutos. Seguidamente, se exponen los distintos pasos acometidos por el algoritmo de segmentación propuesto para la transformación y binarización de dichas imágenes, y se establecen los criterios para evaluar la calidad de las segmentaciones obtenidas. Finalmente, es expuesto el proceso de extracción de datos característicos del peso y calibre desde las imágenes segmentadas, y la generación de los modelos de estimación a partir de éstos y de las mediciones previamente realizadas. En la Sección 3 son presentados y discutidos los resultados obtenidos, tanto para las segmentaciones realizadas como para los modelos de estimación computados. En el último apartado (Sección 4), a modo de conclusión, se destacan algunas implicaciones relacionados con los resultados obtenidos, y se sugieren algunos aspectos a tener en consideración en futuras investigaciones.

2 MATERIALES Y METODOLOGÍA

2.1 ADQUISICIÓN DE IMÁGENES Y DATOS DE REFERENCIA

Para el presente trabajo se cosecharon, en enero de 2018, muestras de aceituna de las variedades Arbequina y Picual. De ellas se seleccionaron 200 individuos por variedad para formar los conjuntos de estudio. En el caso de la variedad Arbequina, se establecieron los siguientes 5 conjuntos: A1, A2 y A3, con 40 individuos por conjunto, A4 con 50 individuos, y A5 con 30. Para la variedad picual, se formaron 4 conjuntos, P1, P2, P3 y P4, con 50 individuos cada uno.

Establecidos los conjuntos de estudio, se procedió al fotografiado de los mismos. Para ello, sus frutos integrantes fueron dispuestos de forma ordenada, y separados los unos de los otros, sobre un tapete blanco (véase un ejemplo de captura en la Fig. 1). Las imágenes fueron capturadas con una cámara digital sin espejo, y equipada con sensor NMOS, modelo LUMIX DMC-GH4 (Panasonic, Kadoma, Osaka, Japón). Ésta fue configurada en modo manual, con una apertura de $f/8$, un tiempo de exposición de $1/500s$, una sensibilidad ISO de 400 y una distancia focal de 14mm. Para iluminar la escena, se utilizaron dos lámparas halógenas de 500W, con una temperatura de color de 3300k. La cámara fue montada por encima del tapete sobre el que se situaron las aceitunas a fotografiar, mirando perpendicularmente a éste. Los focos se situaron a la misma altura, orientados hacia el

punto de enfoque de la cámara. Las capturas fueron almacenadas en formato JPG, con una resolución de 4608×2592 píxeles, una densidad de 180 píxeles por pulgada y una profundidad de color de 24bits. En la Figura 1 se muestra, a modo de ejemplo, una de las capturas tomadas en laboratorio.



Figura 1: Ejemplo de imagen capturada para uno de los conjuntos de aceitunas bajo estudio.

Una vez finalizada la captura de las imágenes de los conjuntos, se realizó el pesado individualizado (en gramos, g) de cada fruto usando la balanza de precisión KERN PCB 3500-2 (KERN & Sohn GmbH, Balingen, Alemania). También se realizaron las mediciones de los diámetros mayores y menores (en milímetros, mm) de cada individuo, utilizando un calibrador digital, con 0.01mm de resolución y 0.02mm de precisión. Finalmente, cada medición se asoció unívocamente, mediante etiquetado, a su correspondiente aceituna fotografiada.

2.2 ALGORITMO DE ANÁLISIS DE IMAGEN

La metodología propuesta se basa en la extracción automática de características de las imágenes que son descriptivas del peso y calibre de las aceitunas. Para ello, el algoritmo desarrollado emplea técnicas basadas en morfología matemática y segmentación por umbralización.

2.2.1 Preprocesamiento

En primer lugar, las imágenes son escaladas a un 40% de su tamaño original mediante interpolación bicúbica, ello para reducir la carga computacional de los algoritmos. Seguidamente, se aplica un filtrado gaussiano para la atenuación de ruido de sal y pimienta, con kernel de 5×5 y desviación típica de 0.8. Finalmente, las imágenes se transforman, desde su espacio de color nativo RGB, a una representación en base al espacio de color HSV (del inglés *Hue*, *Saturation*, *Value*). Esta elección estuvo motivada por las características propias de las imágenes capturadas en laboratorio, así como por la propia naturaleza del experimento. Y es que, en efecto, abordar una segmentación basada en características de color carecía de sentido aquí, al no existir garantías de homogeneidad entre las distintas aceitunas en cuanto

a matiz (hecho especialmente destacable en la variedad Arbequina). Sin embargo, el utilizar un tapete de color blanco como fondo de escena propició que sus píxeles presentaran *valores de color* o *luminosidad* considerablemente mayores a los de los píxeles pertenecientes a las aceitunas. Por todo ello, se decidió la conversión de las imágenes al espacio HSV, que proporciona la información de luminosidad, en el canal *V*, desacoplada de otras características. Cabe mencionar que hay más espacios de color potencialmente válidos para este trabajo por ofrecer la misma característica, como por ejemplo los CIELAB (canal *L*) [2] o HSL (canal *L*) [11], entre otros.

2.2.2 Segmentación de las aceitunas

Una vez ejecutada la transformación al espacio HSV, el canal correspondiente a la información del valor de color (*value* en inglés) es almacenada en una matriz independiente, y tratada a partir de este punto como una imagen en escala de grises que, tras diversas transformaciones, será finalmente la imagen binarizada.

Para la matriz contenedora de dicha componente, se realiza una inversión de los valores de sus elementos en base al máximo valor *de gris* contemplado, esto es 255. Así, sea *V* la imagen definida en el intervalo [0, ..., 255] (8 bits) correspondiente al canal *Value* del espacio de color HSV, la imagen *V_{INV}* es la que resulta de la siguiente operación:

$$V_{INV} = 255 - V \quad (1)$$

Con esto, el objetivo perseguido es que los valores de gris mayores (más próximos al blanco) sean los propios de los píxeles que se corresponden con las aceitunas, y que, por tanto, el fondo de la imagen pase a ser la parte más oscura de ésta.

A continuación, para obtener una estimación de fondo, se realiza una apertura morfológica sobre la matriz resultante de la inversión de valores anterior, *V_{INV}*:

$$I_\gamma = \gamma_\beta(I_{INV}) = \delta_\beta(\varepsilon_\beta(I_{INV})) \quad (2)$$

donde β es un elemento estructurante circular de radio 50 píxeles (lo suficientemente grande como para contener completamente una aceituna de la imagen), y δ y ε las operaciones morfológicas básicas de dilatación y erosión, respectivamente [10].

En búsqueda de una imagen de alto contraste entre las aceitunas y el fondo, la estimación de fondo calculada es sustraída a la matriz de la que origina:

$$I_C = I_{inv} - I_\gamma \quad (3)$$

donde *I_C* es la imagen de *alto contraste*.

Como última transformación previa a la segmentación definitiva, se aplica una operación de relleno por

difusión para incrementar el valor de aquellas regiones más oscuras que aparecen sobre las aceitunas, y que se corresponden con los puntos de máximo brillo, consecuencia del fenómeno de reflectividad máxima de la luz sobre la superficie convexa de los frutos. Complementariamente, y debido al procesamiento previo aplicado, este operador promueve también la homogeneización de los valores de gris del fondo de la imagen. Matemáticamente:

$$I_F = R_{I_C}^\varepsilon(I_m), \quad (4)$$

donde *R* es la operación de reconstrucción morfológica, consistente en la erosión (ε) iterativa de la imagen *I_m* con respecto a *I_C*, con un elemento estructurante unitario, hasta la idempotencia [10]:

$$R_{I_C}^\varepsilon(I_m) = \varepsilon_{I_C}^i(I_m), \text{ siendo} \quad (5)$$

$$I_m(x, y) = \begin{cases} I_C(x, y) & \text{si } (x, y) \in \text{borde de } I_C \\ \max(I_C) & \text{en otros casos} \end{cases}, y$$

$$\varepsilon_{I_C}^i(I_m) = \varepsilon_{I_C}^{i+1}(I_m), \quad \varepsilon_{I_C}^1(I_m) = \varepsilon_{\beta=1}(I_m) \vee I_C$$

Finalmente, la imagen resultante *I_F*, aún en escala de grises, es sometida al proceso de binarización por umbralización. Para ello, se establece como umbral su mínimo valor de gris, el cual corresponde a los píxeles pertenecientes al fondo (como ya se ha comentado, el propósito de algunas de las transformaciones realizadas es el de conseguir la uniformidad en cuanto a valor para dichos píxeles). Así, los valores por encima de dicho mínimo se asocian con píxeles de aceituna y se segmentan del fondo (ver Figura 2):

$$I_{BIN}(x, y) = \begin{cases} 255 & \text{si } I_F(x, y) > \min(I_F) \\ 0 & \text{en otros casos} \end{cases} \quad (6)$$




Figura 2: Resultado de la segmentación de la imagen mostrada en la Figura 1.

2.2.3 Postprocesamiento

Como último paso, se aplica una apertura morfológica con un elemento estructurante pequeño para eliminar aquellas componentes conexas con un área (número de píxeles) anormalmente pequeña como para corresponder a una aceituna segmentada:

$$I_{DEF} = \gamma_\beta(I_{BIN}), \quad (7)$$

donde β es un elemento estructurante circular de 10 píxeles de radio.

A continuación (Figura 3), se ilustra el proceso de segmentación a través de los resultados obtenidos en sus distintas etapas, para una sub-imagen de una de las capturas bajo estudio:




Figura 3: proceso de segmentación para una sub-imagen de una de las capturas bajo estudio: (a) imagen original; (b) canal de valor; (c) canal de valor invertido; (d) estimación de fondo; (e) substracción del fondo estimado; (f) homogeneización de valores; (g) segmentación; (h) imagen final tras postprocesado.

2.2.4 Evaluación de la calidad de la segmentación

Se realizó una segmentación a mano para cada una de las capturas, utilizando un editor de gráficos, con el objetivo de obtener un resultado lo más cercano posible a una segmentación ideal (*Gold Standard*). El conjunto de imágenes de referencia resultante fue utilizado para, mediante comparación con las generadas por el algoritmo, determinar la calidad de la segmentación proporcionada por éste, a través del cómputo de las métricas *RC* (*Recall*) y *PC* (*Precision*), propuestas a continuación:

$$RC = \frac{TP}{TP+FN} \quad PC = \frac{TP}{TP+FP}, \quad (8)$$

dónde *TP* (*True Positives*), se refiere al número de píxeles categorizados por el algoritmo como pertenecientes a una aceituna (son píxeles blancos en la imagen binarizada) que también lo son según la segmentación ideal (*Gold Standard*). *FN* (*False Negatives*), se corresponde con el número de píxeles erróneamente clasificados como no pertenecientes a alguna aceituna. De la misma forma, *FP* (*False Positives*), se refiere al número de píxeles considerados erróneamente como pertenecientes a alguno de los frutos, en base a la clasificación propuesta por la segmentación *Gold Standard*.

Junto a *RC* y *PR*, se propone una tercera métrica, $F_{measure}$, basada en los mismos principios, y que evalúa la calidad global de la segmentación:

$$F = 2 \frac{PC \times RC}{PC+RC} \quad (9)$$

2.3 EXTRACCIÓN DE INFORMACIÓN Y DESARROLLO DEL MODELO DE ESTIMACIÓN

Una vez generadas las distintas segmentaciones, es necesario extraer de éstas la información necesaria para realizar un estudio de correlación con las mediciones de peso y calibre obtenidas previamente en laboratorio. Dentro de cada imagen binaria, para cada región o componente conexas correspondiente a un fruto, se calcula el número de píxeles que la integran; éste es el valor a enfrentar con el peso, medido en gramos, de la aceituna correspondiente. Por otra parte, se determina la elipse que mejor encaja o inscribe la correspondiente componente; esto es, la elipse con el mismo segundo momento central normalizado que dicha región. Los diámetros de dicha elipse, medidos en píxeles, son los datos a enfrentar con las mediciones, en mm, realizadas para los ejes mayor y menor de las aceitunas.

Una vez es adquirido este conjunto de datos, para cada una de las dos variedades consideradas en el experimento, se procede como sigue: del conjunto de 200 frutos que comprende la muestra de estudio, se toman 50, representando la variabilidad del conjunto de la muestra, para conformar un conjunto de entrenamiento. Mediante un análisis de regresión, basado en la relación de dependencia entre los pesos de las aceitunas de dicho conjunto y el número de píxeles que corresponden a las mismas (según lo aportado por la segmentación), se obtiene la recta de regresión que determina, mediante la ecuación que la describe, el modelo predictivo obtenido. Este modelo es aplicado sobre los 150 frutos restantes, actuando dicho subgrupo como conjunto de validación externo, a partir del cual se evalúa la calidad del modelo. El proceso es replicado para los otros parámetros bajo estudio, esto es, para los ejes mayor y menor de los frutos.

Insistiendo en que este procedimiento es realizado de forma independiente para cada una de las variedades, en última instancia, se contempla la generación de un único modelo válido para ambas de forma conjunta. Para ello, se hace uso de los dos conjuntos de entrenamiento establecidos anteriormente, abordando el análisis de regresión a partir de la unión de ambos, y aplicando el resultado sobre la suma de los conjuntos de validación externa correspondientes. Esto, tanto para el peso como para la longitud de los ejes que determinan el calibre de los frutos.

2.3.1 Evaluación de la calidad de los modelos de estimación

Una vez calculados los modelos de predicción, y aplicados éstos sobre las poblaciones correspondientes, se llevó a cabo una evaluación final de las estimaciones realizadas. Para ello se recurrió al

cálculo de la raíz del error cuadrático medio, según lo establecido a continuación:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (10)$$

Donde \hat{y}_i y y_i son, respectivamente, el valor predicho y el valor real del parámetro a estimar, para el fruto i -ésimo de la muestra tratada, de un total de n elementos.

También se realizó el cálculo del error cuadrático relativo a la media como porcentaje, en base a la siguiente definición:

$$SE = \frac{RMSE}{\frac{\sum_{i=1}^n y_i}{n}} \times 100 \quad (11)$$

Finalmente, se determinó el error relativo (como porcentaje), una vez más para cada modelo y la población de aceitunas correspondiente. Dicho error se calculó según se indica a continuación:

$$|E| = \frac{|\sum_{i=1}^n (\hat{y}_i - y_i)|}{\sum_{i=1}^n y_i} \times 100 \quad (12)$$

3 RESULTADOS Y DISCUSIÓN

3.1 RESULTADOS DE LA EVALUACIÓN DE CALIDAD DE LA SEGMENTACIÓN

Como se ha comentado anteriormente, la viabilidad del algoritmo para la segmentación ha sido testada en base a la comparación de las imágenes generadas por éste con segmentaciones *presumiblemente* ideales (*Gold Standard*), generadas a mano. Esto, a través de las métricas propuestas en el apartado anterior. En la Tabla 1 se muestran los resultados obtenidos, mostrando los valores para cada una de las segmentaciones realizadas. Según los datos recogidos en ella, se puede concluir la solidez del algoritmo de segmentación propuesto. Cabe destacar que no se observan importantes diferencias entre las distintas variedades, manteniéndose los resultados obtenidos siempre dentro de unos márgenes similares. Esta uniformidad respalda la decisión de no basar el proceso de segmentación en características de color (dadas las significativas diferencias en cuanto a tono entre las dos variedades bajo estudio), y sugiere su correcto funcionamiento tratando nuevas variedades, o frutos en distintos estados de maduración. Otra de las bondades aportadas por el método es su eficacia a la hora de detectar únicamente aquellas componentes conexas que se corresponden con aceitunas, descartando en la segmentación final cualquier componente anómala que no pueda corresponderse con algún fruto. Esto hace posible determinar de forma exacta el número de frutos que aparecen en cada imagen.

Tabla 1: Resultados de la evaluación de la calidad y precisión de las segmentaciones realizadas por el algoritmo propuesto.

| muestra | RC | PC | $F_{measure}$ |
|----------|------------|------------|---------------|
| A1 | 1 | 0,8633652 | 0,9266731 |
| A2 | 1 | 0,87684168 | 0,93438002 |
| A3 | 1 | 0,88152872 | 0,93703456 |
| A4 | 1 | 0,89458439 | 0,9443595 |
| A5 | 1 | 0,8669487 | 0,92873329 |
| promedio | 1 | 0,87665374 | 0,93423609 |
| P1 | 0,99997252 | 0,87503607 | 0,93334188 |
| P2 | 1 | 0,89381748 | 0,94393202 |
| P3 | 0,99999426 | 0,88897784 | 0,94122379 |
| P4 | 1 | 0,90662967 | 0,9510286 |
| promedio | 0,99999336 | 0,89111527 | 0,94238157 |

3.2 RESULTADOS DE LA EVALUACIÓN DE CALIDAD DE LOS MODELOS DE PREDICCIÓN

La correlación existente entre la información extraída a partir de las segmentaciones (las áreas como número de píxeles de las componentes conexas que pertenecen a los frutos, y la longitud, también en píxeles, de los diámetros de las elipses que las inscriben) y las mediciones de peso y calibre de las aceitunas correspondientes, puede observarse en los gráficos mostrados en las figuras 4, 5 y 6. Nótese los altos valores de correlación obtenidos.

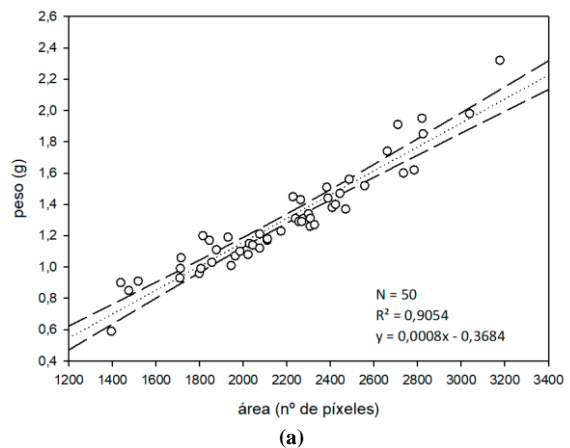
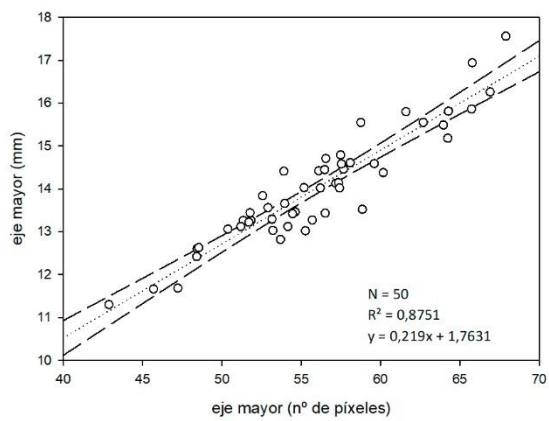



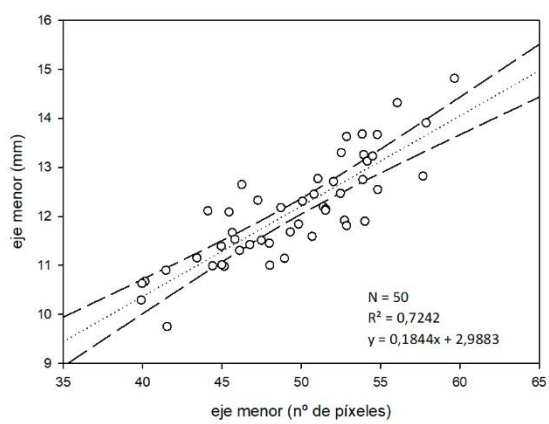
Figura 4: Obtención de los modelos de predicción de la variedad Arbequina a partir del conjunto de entrenamiento, para los parámetros bajo estudio: (a) peso.




(b)



(a)

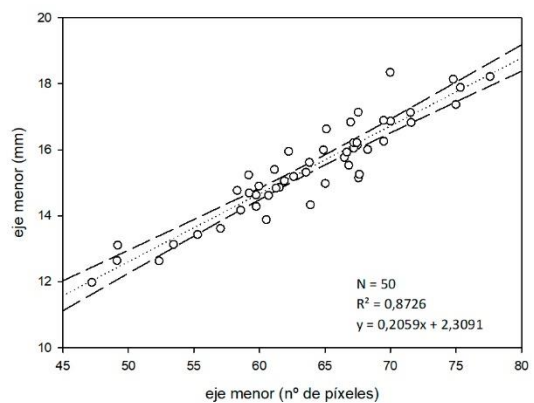


(c)




(b)

Figura 4: Obtención de los modelos de predicción de la variedad Arbequina a partir del conjunto de entrenamiento, para los parámetros bajo estudio: (b) eje mayor; (c) eje menor.

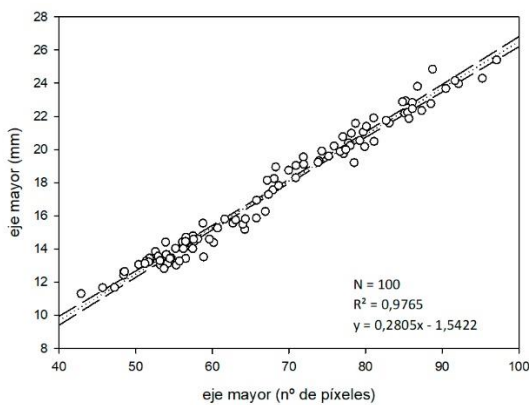


(c)


Figura 5: Obtención de los modelos de predicción de la variedad Picual a partir del conjunto de entrenamiento, para los parámetros bajo estudio: (a) peso; (b) eje mayor; (c) eje menor.



(a)



(b)



(c)

Figura 6: Obtención de los modelos de predicción independientes de la variedad a partir de la unión de los dos conjuntos de entrenamiento, para los parámetros bajo estudio: (a) peso; (b) eje mayor; (c) eje menor.

Por otra parte, con el objeto de ilustrar la calidad predictiva de los modelos, se muestran en la Tabla 2 los resultados de su aplicación sobre los conjuntos de validación externa, para cada una de las características bajo estudio.

Tabla 2: Resultados de las distintas mediciones computadas para evaluar la calidad de los modelos de estimación, tras ser estos aplicados sobre los conjuntos de validación externa correspondientes (según variedad), para cada una de las características bajo estudio: peso (a), eje mayor (b) y eje menor.

| <i>PESO</i> | | | |
|----------------------------------|-----------------|---------------|----------------|
| <i>Variedad</i> | <i>RMSE (g)</i> | <i>SE (%)</i> | <i> E (%)</i> |
| Arbequina | 0,131495 | 10,36649 | 7,406528 |
| Picual | 0,256875 | 8,105015 | 5,602251 |
| Ambas variedades (modelo global) | 0,154839 | 6,97819 | 1,105803 |

(a)

| <i>EJE MAYOR</i> | | | |
|----------------------------------|------------------|---------------|----------------|
| <i>Variedad</i> | <i>RMSE (mm)</i> | <i>SE (%)</i> | <i> E (%)</i> |
| Arbequina | 0,538303 | 3,81445 | 0,756152 |
| Picual | 0,505237 | 2,407021 | 0,325996 |
| Ambas variedades (modelo global) | 0,580499 | 3,307466 | 0,060863 |

(b)

| <i>EJE MENOR</i> | | | |
|----------------------------------|------------------|---------------|----------------|
| <i>Variedad</i> | <i>RMSE (mm)</i> | <i>SE (%)</i> | <i> E (%)</i> |
| Arbequina | 0,557464 | 4,635956 | 0,310614 |
| Picual | 0,608311 | 3,917913 | 0,04032 |
| Ambas variedades (modelo global) | 0,62158 | 4,51218 | 0,117851 |

(c)

Estos resultados ponen de relieve la viabilidad del método, esto es, la estimación del peso y calibre de distintas aceitunas capturadas en una imagen a partir de la información extraída a partir de una segmentación de ésta, y por extensión, el uso del análisis de imagen para dar solución al problema planteado.

Atendiendo a que la calidad de la segmentación para ambas variedades es similar, las leves diferencias en los valores de error cometido en las estimaciones de peso, así como los mejores resultados de correlación para el caso de las aceitunas picuales, se pueden explicar por las propias diferencias morfológicas existentes entre los frutos de estas variedades. El método aproxima el problema mediante la proyección de la aceituna en un plano, y considera que cada píxel tiene una aportación equitativa en su peso. Esta aproximación, aunque válida a tenor de los resultados obtenidos, puede empobrecer éstos ligeramente para según que variedades, en base a determinadas características morfológicas, tales como su esfericidad. En el caso de los parámetros que determinan el calibre de los frutos, el no considerar estas características también puede tener cierto impacto en la precisión con que se realizan las mediciones de los mismos. Como se ha comentado anteriormente, estas mediciones de los ejes mayor y menor de cada fruto se realizaron utilizando un

calibrador digital. Esta forma de abordar dicha tarea introduce inevitablemente el error humano como factor a considerar en el proceso, que es mayor aún dada la naturaleza y características de los frutos a medir, dada su falta de firmeza. Pero el hecho interesante a destacar es el de que, si bien es cierto que identificar el eje o diámetro de simetría mayor de cada uno de los frutos, y realizar su medición, es un trabajo relativamente sencillo (al menos con las dos variedades tratadas), determinar el eje menor no es una tarea obvia, y su medición está sujeta a un mayor grado de incertidumbre. Este hecho podría explicar las diferencias en los resultados, así como el mejor comportamiento de los modelos computados para el eje mayor respecto a los que estiman el diámetro menor.

Por otro lado, es interesante destacar la ausencia de indicios de un beneficio claro en el uso de modelos específicos para cada variedad en detrimento de un modelo general. Ello potencia la usabilidad y generalización de la metodología desarrollada.

Finalmente, cabe también reseñar que no hay evidencias claras que indiquen la necesidad de explorar modelos no lineales más complejos y de más difícil manejo.

4 CONCLUSIONES

En el presente estudio, se ha desarrollado un método para la estimación del peso y calibre de aceitunas mediante análisis de imagen. Los resultados obtenidos muestran la solidez y precisión de éste, y respaldan el uso de este tipo de técnicas en la implementación de sistemas de calibrado y selección, basados en visión artificial, dentro la industria olivícola.

Cabe destacar la estabilidad en el comportamiento del método al tratar con dos tipos distintos de aceitunas y con distintos estados de maduración, hecho que pone de relieve sus posibilidades como estimador independiente de la variedad. Por otra parte, en todas las imágenes testeadas, el número de componentes conexas segmentadas por el algoritmo coincidió exactamente con el número de frutos. Esta eficacia apoya la confianza en el uso de la solución presentada también para realizar un control preciso del número de aceitunas procesadas en un hipotético sistema real basado en ella.

El presente trabajo admite cierto margen para ser extendido en investigaciones futuras. Así, resultaría interesante cuantificar el impacto de la ponderación de la contribución de los píxeles de aceituna en la estimación de su peso. También es necesario corroborar los resultados obtenidos sobre un conjunto de datos más extenso, y considerando un mayor

número de variedades de aceituna, al objeto verificar su generalidad.

Agradecimientos

Este trabajo se ha realizado en el contexto del proyecto TecnOlivo, aprobado en la primera convocatoria del Programa Interreg V-A España - Portugal (POCTEP) 2014-2020, y cofinanciado con fondos FEDER.

English summary

AUTOMATED OLIVE-FRUIT WEIGHT AND SIZE ESTIMATION BY MEANS OF IMAGE ANALYSIS

Abstract

The sizing and sorting of agricultural commodities is a high relevance activity in food industry. This study, focused on the olive farming sector, presents a solution based on image analysis which allows the automatic and non-invasive estimation of the weight and size (major and minor axis) of a set of olive fruits. Considering two different varieties of olive fruits (Arbequina and Picual), a segmentation algorithm, able to extract from images the needed information to compute the weight and size prediction models, was developed. The effectiveness of the proposed method was assessed by calculating the root-mean-square error (RMSE) produced by the models when applied to the corresponding external validation sets. The measured results show evidences of viability as a base to the development of a low-cost olive fruit grading system based on machine vision.

Keywords: olive fruit, weight, size, segmentation, machine vision, estimation.

Referencias

- [1] Benalia, S., Bernardi, B., Cubero, S., Leuzzi, A., Larizza, M., Blasco, J., 2015. Preliminary trials on hyperspectral imaging implementation to detect mycotoxins in dried figs. *Chem. Eng. Trans.* 44, 157–162.
- [2] Connolly, C., Fliess, T. A, 1997. Study of efficiency and accuracy in the transformation from RGB to CIELAB color space. *IEEE Trans. Image Process.* 6, 1046–1047.

- [3] Gómez-Sanchis, J., Blasco, J., Soria-Olivas, E., Lorente, D., Escandell-Montero, P., Martínez-Martínez, J.M., Aleixos, N., 2013. Hyperspectral LCTF-based system for classification of decay in mandarins caused by *Penicillium digitatum* and *Penicillium italicum* using the most relevant bands and non-linear classifiers. *Postharvest Biol. Technol.* 82, 76–86.
- [4] International Olive Oil Council (IOC), 2018. IOC updates series of world statistics on production, imports, exports and consumption. Available: <http://www.internationaloliveoil.org/estaticos/view/131-world-olive-oil-figures>.
- [5] Kailis, S.; Harris, D. *Producing Table Olives*; Publisher: Landlinks Press, Collingwood, Vic., 328, Australia, 2007; pp. 173-174, pp. 244-246
- [6] Moreda, G. P.; Ortiz-cañavate, J.; García-ramos, F. J.; Ruiz-altisent, M. Non-destructive technologies for fruit and vegetable size determination – a review. *J. Food Eng.* 2009, 92, 119–136
- [7] Pallottino, F., Costa, C., Antonucci, F., Menesatti, P., 2013a. Sweet cherry freshness evaluation through colourimetric and morphometric stem analysis: two refrigeration systems compared. *Acta Aliment.* 42, 428–436.
- [8] Pallottino, F., Menesatti, P., Lanza, M.C., Strano, M.C., Antonucci, F., Moresi, M., 2013b. Assessment of quality-assured Tarocco orange fruit sorting rules by combined physicochemical and sensory testing. *J. Sci. Food Agric.* 93 (1176), 1183.
- [9] Sánchez Gómez, A. H.; García García, P.; Rejano Navarro, L. *Elaboration of table olives. Grasas y Aceites* 2006, 57, 86–94.
- [10] Soille, P. (2013). *Morphological image analysis: principles and applications*. Springer Science & Business Media, Germany.
- [11] Sonka, M., Hlavac, V., Boyle, R, 2014. *Image processing, analysis, and machine vision*. Cengage Learning, USA.
- [12] United States Department of Agriculture, Foreign Agricultural Service. *Oilseeds: World Markets and Trade*. Available online: <https://apps.fas.usda.gov/psdonline/circulars/oilseeds.pdf> (accessed on 19 June 2018).



© 2018 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution CC-BY-NC 3.0 license (<https://creativecommons.org/licenses/by-nc/3.0>).