

Universidad Nacional del Noroeste de la Provincia de Buenos Aires

Título: Detección y conteo de limones mediante técnicas de visión artificial y tracking para la estimación de cosecha en tiempo real

Carrera: Ingeniería en Informática

Alumno: Gabriel Pérez

Supervisor Docente: Lucas Benjamin Cicerchia

Tutor de Empresa / Institución / Organización: Hugo Dionisio Ramón

Fecha de Presentación: 04-12-2020

Índice

Introducción	4
Objetivos	5
Plan de Trabajo y Carga Horaria	5
Descripción de la Práctica Profesional Efectuada	6
Introducción	6
Adquisición y procesamiento de imágenes	8
Sobre la escena	8
Pruebas preliminares	11
Esquema de color HSI	12
Separación de objetos	14
Detección de bordes de la imagen segmentada	14
Mapeo de círculos en la imagen a partir de Transformada de Hough	16
Segmentación Watershed	18
Solución Propuesta	19
Preprocesamiento de Imágenes	20
Técnicas de Segmentación	21
Técnicas de Tracking	24
Pruebas y resultados	25
Conclusiones	27

Anexos	28
Marco teórico	28
Espacios de color	28
Espacio de color RGB	29
Espacio de color CIE Lab	30
Segmentación	31
Índices cromáticos de vegetación	31
Morfología matemática	33
Erosión	33
Dilatación	34
Apertura	36
Cierre	37
Bibliografía	38
Agradecimientos	42

Presentación del Informe

Lineamientos Generales

1. Introducción

El presente informe describe el trabajo realizado durante la Práctica Profesional Supervisada (PPS) que surge del proyecto de investigación denominado "Prototipo de sensado con inteligencia artificial para la recolección de datos de cosecha aplicado a maquinaria agrícola" llevado a cabo en el Instituto de Investigación y Transferencia en Tecnología (ITT). Este instituto depende de la Secretaría de Investigación, Desarrollo y Transferencia (SIDyT) y con dependencia académica con las carreras de la Escuela de Tecnología (ET) de la Universidad Nacional del Noroeste de la Provincia de Buenos Aires (UNNOBA). Allí se desarrollan varios proyectos destinados a fomentar la transferencia de conocimiento y tecnología de la investigación aplicada en TIC hacia los sectores productivos, para potenciar el nivel de la I+D y la innovación tecnológica en las empresas y en las instituciones.

El objetivo del proyecto surge como resultado de una consulta técnica privada de la empresa Maqtec, dedicada al diseño, desarrollo y venta de máquinas agrícola de cosecha para plantaciones de limones. Maqtec buscaba adaptarse a las nuevas tecnologías brindando un servicio adicional que sea capaz de estimar la cantidad de frutos cosechados sabiendo que esto permite al agricultor conocer su producción, generar estrategias comerciales y estimar ganancias totales.

El trabajo tiene la finalidad de aplicar las TIC al área de la agricultura, en particular desarrollar algoritmos capaces de automatizar el reconocimiento y conteo de limones en etapa de cosecha mediante técnicas de visión artificial y procesamiento digital de imágenes. Donde además este proceso se realiza en tiempo real sobre una cosechadora a través de unidades de visión constituidas por una computadora de bajo procesamiento y de cámaras de baja resolución.

Este desarrollo culminó con la publicación de los resultados en la "XLVI Conferencia Latinoamericana de informática" específicamente en el Simposio Latinoamericano de Computación Gráfica, Realidad Virtual y Procesamiento de Imágenes. El trabajo fue denominado "Detection and counting of lemons using artificial vision and tracking techniques for real time harvest estimation" y próximamente será indexado en IEEE Xplore Digital Library.

Se asignaron los horarios de acuerdo a un periodo de 10 semanas (5 días a la semana) con 4 horas diarias arbitrarias dependiendo de los horarios que la condición académica del estudiante lo permitió. Además, durante todas las semanas de trabajo se realizaron entrevistas con el docente supervisor ya sea durante las clases semanales de la materia Procesamiento de Imágenes o en el lugar de trabajo designado (ITT).

4. Descripción de la Práctica Profesional Efectuada

4.1. Introducción

La aplicación de la tecnología informática para la automatización de procesos y el trabajo en proyectos multidisciplinarios es de gran relevancia en la actualidad. Contar con la capacidad de obtener datos y mediciones a través de dispositivos digitales se considera de vital importancia para el crecimiento y desarrollo de diferentes áreas, incluida la Agricultura. La Agricultura de Precisión (AP) es la respuesta al manejo de los recursos disponibles para obtener mayores rendimientos y mayor calidad en las cosechas [1].

En los últimos años se han incorporado herramientas de monitoreo de rendimiento que incluyen diferentes tipos de sensores para lograr una toma de decisiones más efectiva, en pos de un mayor aprovechamiento del recurso suelo [2], entre ellos las cámaras.

Los sistemas de captación de imágenes para su procesamiento digital se consideran herramientas importantes para obtener datos relevantes y ayudar a la toma de decisiones (Decision Support System) [3]. Eso incluye la fase de adquisición de imágenes, la que consiste en un proceso de vital importancia para los resultados que luego se obtendrán.

Existen trabajos que muestran diferentes estrategias de adquisición de imágenes, la más común es utilizando cámaras RGB [4] [5] [6]. También se encuentran algunos trabajos que las adquieren a partir de un sistema Cold Mirror de doble cámara con el objetivo de capturar diferentes bandas de ondas (RGB y NIR) sin necesidad de realizar registración por software [7] [8] [9]. Otra alternativa también plantea Gené-Mola et al. [10] donde realizan el sensado a través de un escáner móvil con láser (MTLS) con sensores 3D y GPS evitando de este modo ser afectados por las condiciones de luz naturales en escenas outdoor.

Luego de la adquisición de un dataset de imágenes, se comienza con el procesamiento de esas imágenes. En la bibliografía se puede observar que existen diferentes trabajos con el fin de obtener datos relevantes en el área de la fruticultura. Se puede observar que específicamente en el procesamiento digital de imágenes existen diferentes técnicas con el objetivo único de poder realizar detección y segmentación de frutos [4]. Algunos trabajos están basados en segmentación por umbral en imágenes de índice de color [5] obteniendo resultados mejores y rápidos comparados con otros métodos de segmentación que también

estudiaron [7] [8] [9]. Hay trabajos donde se aplican métodos basados en la forma de frutos inmaduros, utilizando transformada de Hough circular (CHT), en imágenes RGB, NIR y Depth, eliminando los falsos positivos con Redes Neuronales Convolucionales (CNN) clasificadoras [11]. Se pueden encontrar también papers donde se redujo el ruido producido por CHT en imágenes RGH (Red,Green,Hue) con fast normalized cross correlation (FNCC) [6]. Otros donde además de la forma, se sumaron características de textura con descriptores SIFT, SURF, ORB clasificadas por support vector machine (SVM) [12] [13]. Otras técnicas encontradas para la detección de frutos usan características de color y suavidad para crear “áreas de semillas” con una alta probabilidad de ser frutos y utilizando segmentación de contornos [14]. En muchos casos con la segmentación no alcanza ya que esta devuelve un conjunto de frutos que necesitan ser separados. Así es que existen estudios al respecto, algunos utilizando el perímetro de cada label para identificar el centro de cada fruto y la segmentación realizada en imágenes de coeficiente de cromaticidad roja [15]. Otros utilizan técnicas basadas en las características esféricas de los frutos con imágenes en condiciones de luz controladas [16], su objetivo principal fue contar la cantidad de uvas en un racimo. Otros trabajos utilizan tecnologías de clasificación supervisada de frutos utilizando Faster Region-based CNN (Faster R-CNN) [17]. Y se pueden encontrar trabajos donde se aplican al conteo de frutos con datasets simulados y resultados con un promedio de precisión del 91% en datasets reales [18].

Uno de los desafíos que encuentra el cultivo de frutos, específicamente cítricos, es estimar el número de frutos recolectados. Saber la cantidad de frutos cosechados permite al agricultor conocer su producción, generar estrategias comerciales y estimar ganancias totales. El conteo de frutos a través de personas que lo realizan de manera visual es una tarea tediosa y subjetiva que involucra mucho tiempo y muchas veces gran cantidad de errores. Tanto si ésta se realiza durante una cosecha manual o si se utiliza una máquina cosechadora. Se pueden encontrar trabajos al respecto donde se estudiaron técnicas de conteo automático en tiempo real [19] a través del uso de Deep learning [20] [21] y realizando un tracking de objetos utilizando el filtro de Kalman y kernelized correlation (KCF) [22] [23] [24].

A partir de la problemática que conlleva realizar el conteo es que surge el presente trabajo el cual tiene como objetivo automatizar dicho proceso de conteo mediante la utilización de técnicas de procesamiento digital. Donde además este se realiza sobre una cosechadora a través de la utilización de una computadora de bajo procesamiento y de cámaras de baja resolución. Las pruebas han sido realizadas sobre la cosechadora de limones Optimus Citrus de la empresa Maqtec [25] en búsqueda de desarrollar un software que fuera capaz de realizar un conteo de los limones en tiempo real. Aprovechando la capacidad de visión en diferentes escenas para la recolección de datos antes y/o durante el proceso de cosecha y mediante la utilización de dispositivos portables con una cámara RGB. Para la obtención de ejemplares de frutos en tiempo real como datos imprescindibles para un proceso de conteo se han utilizado técnicas de procesamiento de imágenes basadas en índice de color,

segmentación por rango de valores en el esquema de color CieLAB, morfología matemática (binaria y en color) y un algoritmo de tracking de los frutos conocido como algoritmo de Kuhn-Munkres [26].

4.2. Adquisición y procesamiento de imágenes

4.2.1. Sobre la escena

Las máquinas construidas por Maqtec pueden cosechar frutos a partir de un proceso de zarandeo y sacudida de las plantas frutales. Donde, a partir de esto, los frutos caen dentro de la cosechadora, pasan por diversas etapas de limpieza y finalmente son transportadas por medio de mini tolvas hacia la cinta transportadora externa.

Como paso inicial, es necesario mencionar la etapa de adquisición de imágenes ya que la misma juega un papel fundamental en el tratamiento posterior de esos datos. Para la obtención de dichas imágenes se utilizaron dispositivos portables que fueron montados en la cosechadora. Dispositivos construidos con una Raspberry Pi 4 Model B y con una cámara RGB (Genius Widecam F100) fueron colocados en diferentes sitios de la cosechadora para capturar videos tomados en condiciones de luz natural en el momento que se realizaba la cosecha de los frutos.



(a)



(b)

Figura 1. Cosechadora de limones Optimus Citrus de la empresa Maqtec. (a) Cosechadora pasando por una planta. (b) Interior de la cosechadora.

De acuerdo a un relevamiento realizado en el año 2019 durante la cosecha de limones en una plantación en la provincia de Tucumán, se determinó que los escenarios necesarios para cubrir tanto los limones cosechados por el equipo, como los que no, serán relevados de la siguiente forma:

CINTA TRANSPORTADORA: En este escenario se van a contar todos aquellos limones que la cosechadora haya conseguido obtener a partir del zarandeo de la planta y están en condiciones de pasar a la tolva. Se coloca el sistema de visión al inicio de la cinta transportadora con una cámara que enfoca al área de ingreso de los limones.



Figura 2. Escena de la cinta transportadora de frutos.

PLANTA: Este escenario será tenido en cuenta para conocer la cantidad de limones que la cosechadora no junta (relevar la copa de la planta una vez que la misma ya pasó por la cosechadora) y para medir la efectividad de volteo (diferencia de limones en la planta antes y después del paso del equipo).



Figura 3. Escena de la planta.

SUELO: Este escenario también será tenido en cuenta para conocer la cantidad de limones que la cosechadora logra sacar de la planta pero no junta. Para esto se contarán tanto los limones antes del ingreso de la planta a la cosechadora como los que quedan después.



Figura 4. Escena del suelo.

A continuación se detallan las actividades realizadas que abarcan el proceso de conteo de los frutos cosechados, desde las pruebas preliminares hasta la solución propuesta. Es decir, se trabaja la escena de la cinta transportadora ya que se trata de una escena donde se pueden capturar de una forma más clara los frutos cosechados. Si bien es la escena que mejor permitía observar los limones, esta está a la intemperie lo que hace que las condiciones de luz varíen a lo largo de la jornada y con la posición de la cosechadora.

4.2.2. Pruebas preliminares

Las primeras pruebas realizadas como parte del proyecto involucra un conjunto de imágenes representativas de distintas zonas de la cosechadora, las plantas y el suelo. Durante la fase de prueba se realizaron diversos cambios relacionados a la segmentación (Ver Anexo I) con la finalidad de reconocer los frutos. Uno de los inconvenientes que existe en este tipo de problemáticas es la presencia de grupos de frutos que debido a la segmentación quedan contemplados como un solo fruto. Separar frutos y obtener instancias de cada uno es un trabajo que se planteó desde un inicio, donde para ello se utilizaron técnicas empleadas en la literatura específica, entre las cuales se encuentra el uso de

Transformada de Hough Circular (CHT) [6] [11] [12], Watershed[29] y bordes. Desafortunadamente estas técnicas no obtuvieron buenos resultados y no pudieron ser aplicadas en tiempo real.

A continuación se detalla el resultado de algunas técnicas aplicadas y pruebas realizadas durante todo el trayecto. Los fundamentos teóricos que se encuentran detrás de los conceptos desarrollados a continuación podrá encontrarlos en el Anexo I.

4.2.2.1. Esquema de color HSI

Como parte del reconocimiento de los frutos, una de las primeras pruebas realizadas fue la utilización del esquema de color HSI (Ver Anexo I) teniendo en cuenta una de las características principales del fruto como es el color. Sobre este esquema de color se analizaron diferentes rangos de tono y saturación en los que el fruto se encuentra y se aplicó segmentación basadas en umbrales (Ver Anexo I) de prueba en la capa H (Capa de tono) y S (Capa de saturación).

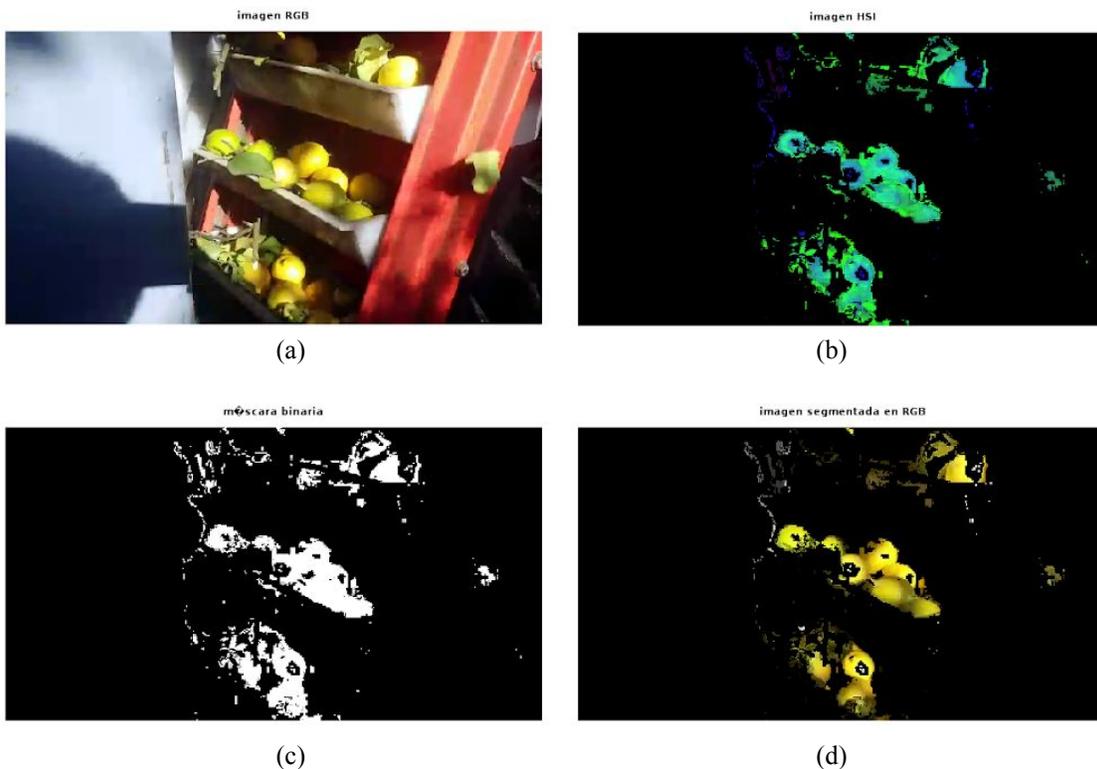


Figura 5. Resultado de aplicar segmentación HSI a imagen de mini tolvas de la cosechadora. (a) Imagen original. (b) Imagen HSI. (c) Máscara binaria obtenidas de la segmentación. (d) Imagen segmentada en RGB.

Las pruebas en esta zona y con este esquema de color no parecen ser tan acertadas debido a la sobre segmentación obtenida. Se utilizó este mismo algoritmo en la zona del suelo. Antes de aplicar HSI se realizó un pre-procesamiento a la imagen donde se aumentó el contraste para delimitar mejor los objetos en la imagen.



Figura 6. Aplicando contraste a la imagen. (a) Imagen original. (b) Imagen aplicando contraste.

Al aumentar el contraste se obtuvo una mejor imagen de entrada para el algoritmo de segmentación HSI donde los objetos se encuentran más delimitados y como se puede observar en los resultados, su segmentación final también.



Figura 7. Resultado de aplicar segmentación HSI imagen original. (a) Imagen original. (b) Imagen segmentada en RGB.

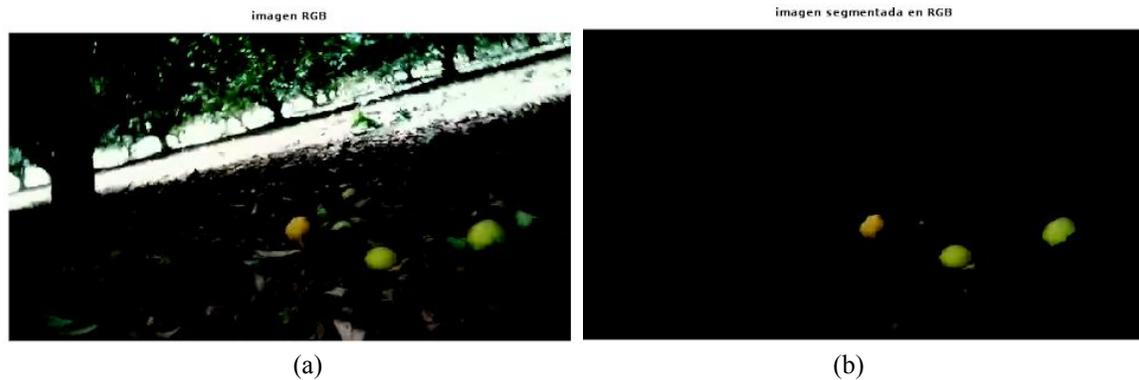


Figura 8. Resultado de aplicar segmentación HSI imagen contraste.(a) Imagen original con contraste. (b) Imagen segmentada en RGB.

Luego continuando con el mismo criterio de utilizar una umbralización para quedarnos con los frutos, se realizaron pruebas con el esquema de color CieLAB (ver Anexo I). Se observó así, que dicho esquema permitía segmentar mejor los frutos, mejorando así los resultados obtenidos como se mostrará en la solución propuesta.

4.2.2.2. Separación de objetos

Una de las dificultades que tiene realizar segmentación de objetos es la incapacidad de obtener segmentos separables cuando los objetos se encuentran juntos (ver Anexo I). Este es un acontecimiento muy común en este tipo de aplicaciones porque los frutos pueden aparecer juntos en muchas ocasiones y si el objetivo es contarlos, solamente con una segmentación no se podría realizar. Es por eso que se analizaron diferentes estrategias con la finalidad de obtener segmentos específicos que representen a un solo limón.

4.2.2.2.1. Detección de bordes de la imagen segmentada

Después de realizar la segmentación de los frutos se utilizaron diferentes métodos de detección de bordes con la idea de delimitar los frutos que se encuentran juntos, se tiene que prewitt es el más efectivo en este caso ya que otras técnicas generaban demasiado ruido como parte de su resultado.

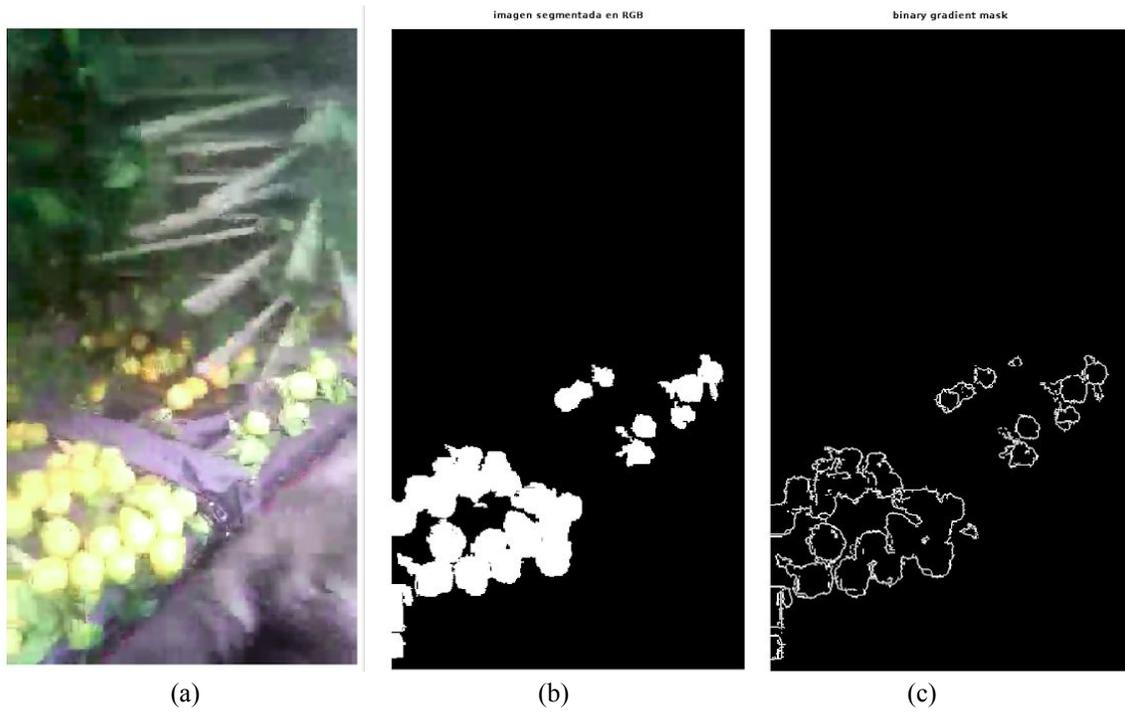


Figura 9. Ejemplo de obtención de bordes para separar limones dentro de la cosechadora. (a) Imagen original. (b) Máscara obtenida de la segmentación de la imagen. (c) Bordes detectados en la imagen.

El siguiente paso consiste en aplicar la operación de sustraer, el borde obtenido es eliminado de la máscara obtenida por la segmentación. Tras diversas operaciones de morfología binaria se obtiene lo siguiente:

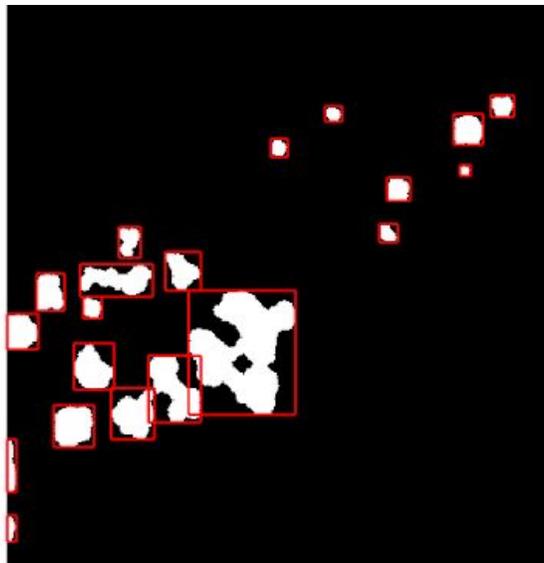


Figura 10. Resultado de restar bordes a la segmentación.

Como se puede observar, en algunos casos los resultados no fueron los esperados y no se pudieron obtener segmentos para cada limón. Se realizaron pruebas con diferentes imágenes de diferentes escenas y los resultados obtenidos tampoco fueron los esperados.

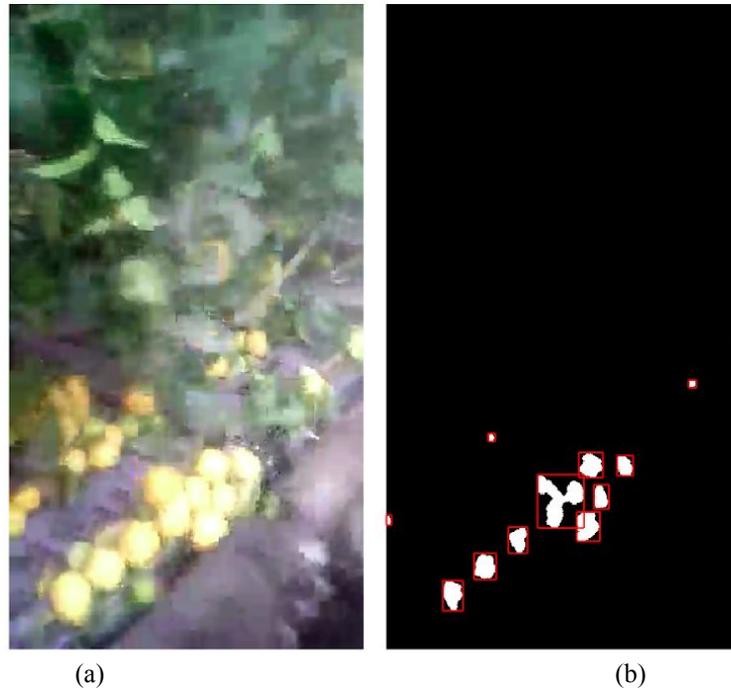


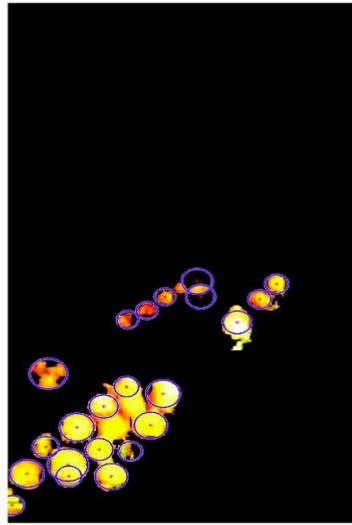
Figura 11. Resultado de restar bordes a la segmentación en otra imagen. (a) Imagen original. (b) Imagen segmentada resultado de aplicar bordes.

4.2.2.2.2. Mapeo de círculos en la imagen a partir de Transformada de Hough

La Transformada de Hough Circular [6] [11] [12] es una técnica para la detección de figuras en imágenes digitales, fue utilizado para encontrar círculos en la imagen. Ya que los limones no tienen forma de círculos, sino que presentan una forma más cercana a una elipse, se espera que este método sea aproximado a lo real. El método es utilizado sobre la máscara binaria obtenida de la segmentación.



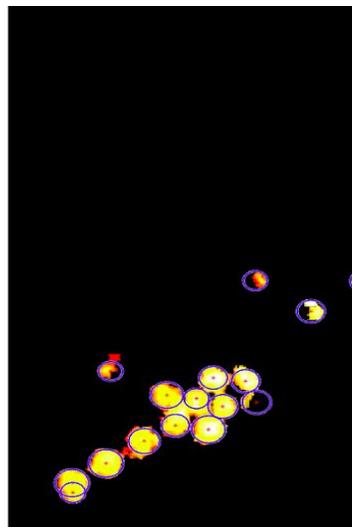
(a)



(b)



(c)



(d)

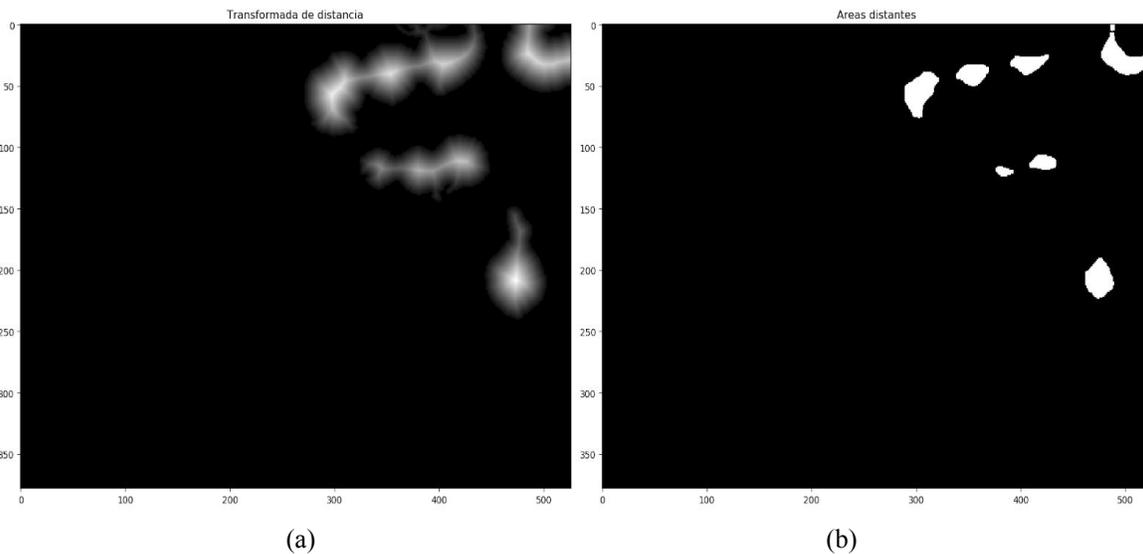
Figura 12. Resultado de aplicar transformada de Hough circular. (a)(c) Imágenes originales. (b)(c) Imágenes aplicando Transformada Hough Circular.

El método se dejó de utilizar porque en la mayoría de los casos encontraba círculos de más en la imagen produciendo demasiado ruido.

4.2.2.2.3. Segmentación Watershed

Luego se propuso tratar las áreas de segmentación mayores donde ocurre una superposición de los frutos, se analizó la posibilidad de implementar el algoritmo de watershed a partir de la transformada de distancia [29]. La transformación de watershed encuentra "cuencas de captación" o "líneas de cresta de cuenca" en una imagen tratándola como una superficie donde los píxeles claros representan elevaciones altas y los píxeles oscuros representan elevaciones bajas. La transformación watershed se puede utilizar para segmentar regiones contiguas de interés en objetos distintos.

Primeramente se obtuvieron las segmentaciones que sobrepasaba un área establecida donde dos o más frutos pueden estar conectados, a las cuales se le aplicó la transformada de distancia (ver Transformada de distancia de la Figura 13 (a)). Los píxeles claros representan elevaciones altas y los píxeles oscuros representan elevaciones bajas para la transformación de watershed. Se obtuvieron las elevaciones altas que se utilizarán para separar los diferentes objetos de la segmentación, luego se aplicó el algoritmo de watershed. A la segmentación devuelta por el algoritmo se le aplicaron operaciones morfológicas para separarlos los segmentos aún más y por último se le sumó la máscara de segmentaciones de áreas no mayores (frutos no conectados).



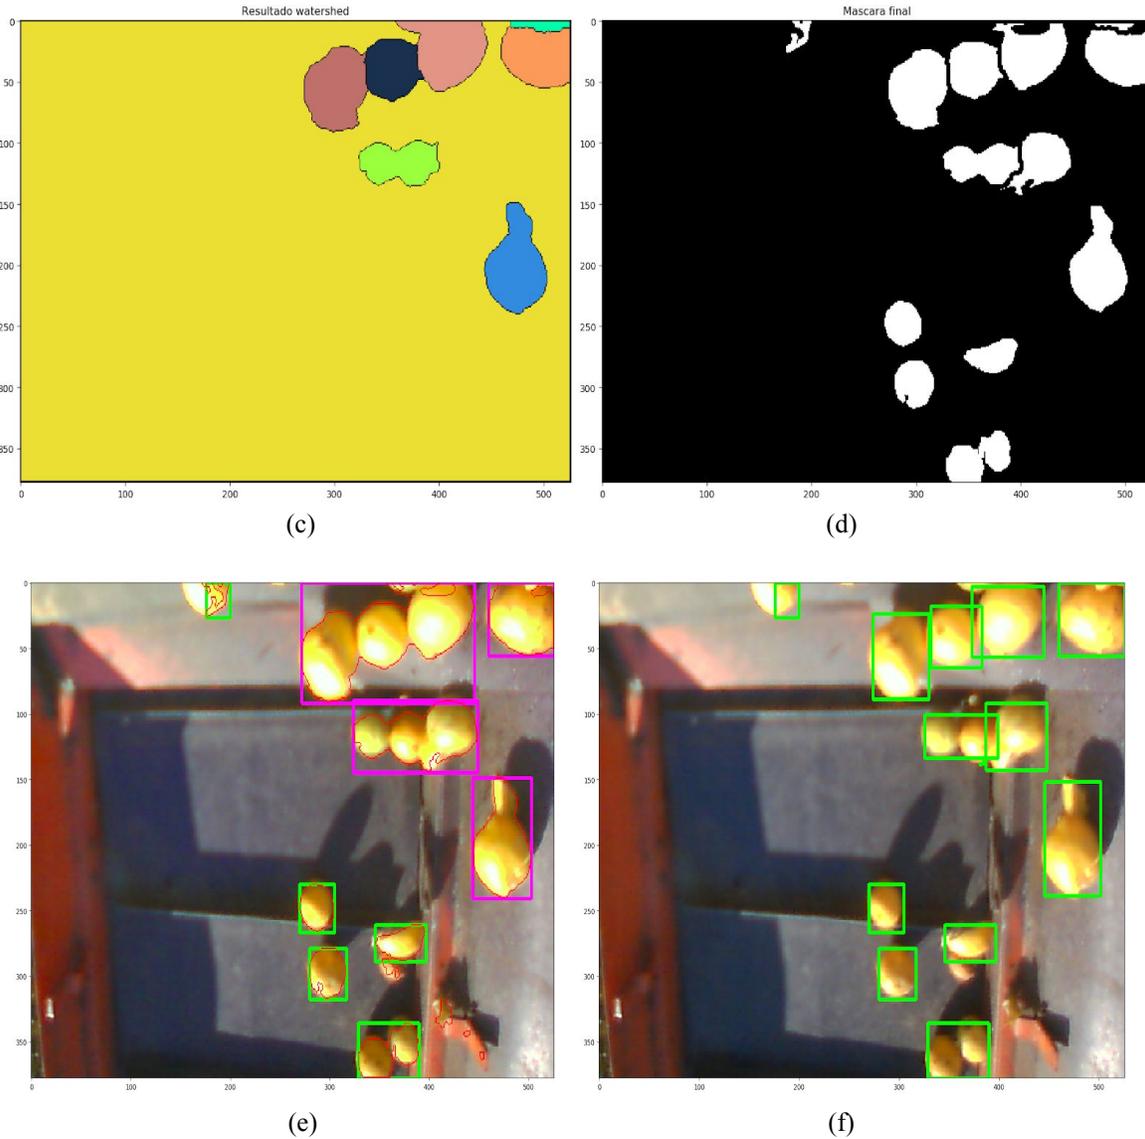


Figura 13. Resultado de aplicar watershed a imagen de la cinta transportadora. (a) Transformada de distancia para áreas con frutos juntos. (b) Elevaciones altas representadas por distancia. (c) Resultado Watershed (d) Segmentación final. (e) Segmentaciones antes de aplicar watershed. (f) Segmentación final en la imagen.

4.2.3. Solución Propuesta

En esta sección se describen las diferentes herramientas y técnicas utilizadas para arribar a una solución teniendo en cuenta lo analizado anteriormente y el contexto del problema.

Se trabaja sobre imágenes de la cinta transportadora a las cuales se le aplica un mejoramiento como parte de su preprocesamiento, para luego realizar un reconocimiento

que permitirá identificar a los objetos que luego el algoritmo de tracking deberá seguir y contar. (Para más información, ver Marco Teórico en la sección Anexo).

4.2.3.1. Preprocesamiento de Imágenes

Para los video de la escena se delimitó una zona de interés o Region Of Interest (ROI) que es donde se va a realizar el procesamiento. Debido a las diferentes condiciones de luz que presentan y problemas de saturación que eso conlleva, se utilizaron diferentes técnicas de preprocesamiento para mejorar la imagen. Como se puede observar en la Figura 14, la ROI en esta escena se ubica en el inicio de la cinta transportadora, en esta etapa los frutos tienden a mantenerse separados facilitando el proceso de conteo.



Figura 14. Escena de la cinta transportadora de frutos. En rojo podemos ver la ROI designada.

La elección de los algoritmos desarrollados se encuentra ligada al manejo eficiente de los recursos de hardware con los cuales se cuenta.

Debido a que las imágenes obtenidas se encuentran en condiciones de luz no controladas, se requiere de un preprocesamiento con el fin de abordar uno de los inconvenientes que aparece que es el de la saturación. Para resolver este problema y obtener una vista más uniforme de los frutos, se aplicaron operaciones de morfología matemática (Ver Anexo I), específicamente apertura morfológica en color en el espacio de color RGB (Figura 15), lo cual también generó una pérdida de ruido y permitió el enfoque en las características principales de los frutos.



Figura 15. Pre-procesamiento de la imagen. (a) Imagen original. (b) Imagen pre-procesada.

4.2.3.2. Técnicas de Segmentación

Luego del preprocesamiento, se procedió a trabajar en la segmentación, donde se utilizó un índice de contraste de color basado en H. Xu and Y. Ying [5] [7] [8] [9]. En dicho trabajo para poder segmentar objetos amarillos se utilizó un índice calculado en el espacio de color RGB (Ver Anexo I). Allí muestran que el índice donde más resaltan los frutos se ve plasmado con el cálculo de (1).

$$R - B \quad (1)$$

$$G - B \quad (2)$$

Las imágenes del paper a las cuales le aplicaron este índice son imágenes de frutos en planta. Después de evaluar el comportamiento de los índices mencionados en los trabajos y sabiendo que el color amarillo es formado por la adición de los colores Red y Green, se encontraron mejores resultados en imágenes propias utilizando los índices (1) y (2) (ver Figura 16). Se aplicó umbralización a ambos índices basado en los intervalos en los cuales se encuentra el fruto, que resultan ser aquellos valores de gris más altos, y se obtuvieron máscaras binarias por separado para posteriormente hacer la intersección de ambas (ver Figura 17 y 18). Esta técnica se utilizó para poder separar los objetos de interés del fondo que los rodea.

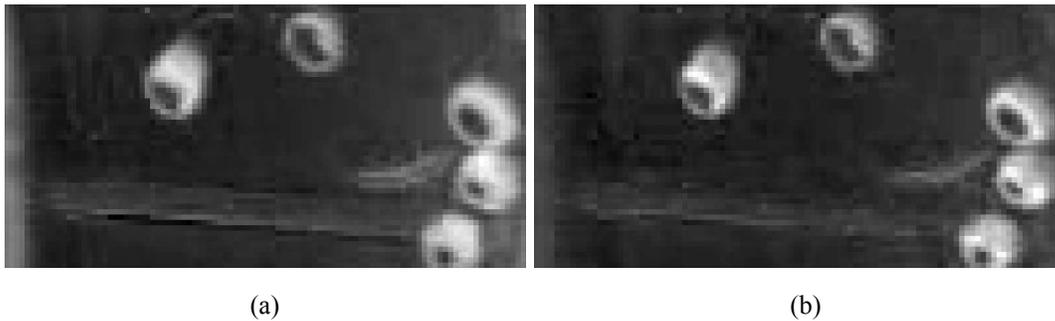


Figura 16. Índices de contraste. (a) Índice R-B. (b) Índice G-B.



Figura 17. Máscaras binarias de los índices. (a) Máscara resultante R-B. (b) Máscara resultante G-B.

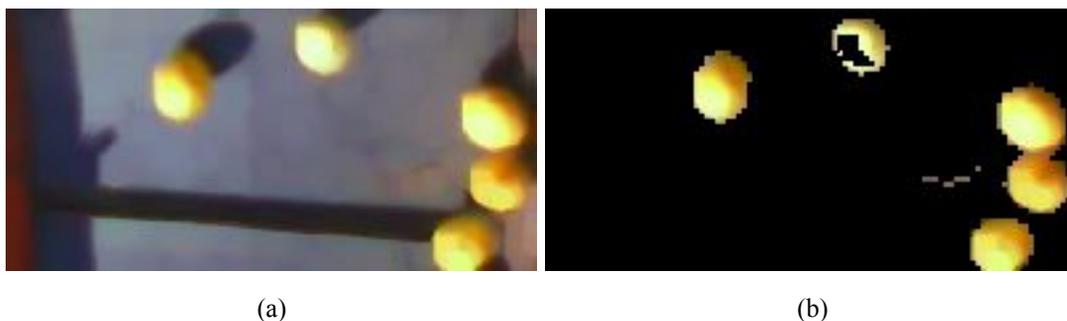


Figura 18. Resultado de la umbralización por índice R-B y G-B. (a) Imagen pre- procesada. (b) Resultado de aplicar un umbral e intersección.

Después de la pre-segmentación calculada a partir de los índices, para mejorar la segmentación y disminuir presencia de ruido, se utilizó segmentación basada en rangos de color con el esquema de color CieLAB (Ver Anexo I) . Teniendo como parámetros los rangos inferiores y superiores de colores que se adaptan al fruto calculados a partir de un análisis de las imágenes obtenidas. Para borrar las hojas que pueden aparecer en la escena se calculó el índice Normalized Difference Index (NDI) (Ver Anexo I) para imágenes RGB [27], índice asociado a niveles de vegetación más altos de un cultivo. De este índice se

obtuvo una máscara a partir de los valores más verdes, a la máscara obtenida de la segmentación se le sustrajo esta máscara de NDI.



Figura 19. Ejemplo de aplicación de índice NDI. (a) Imagen pre-procesada. (b) Máscara resultante NDI.

A esta máscara resultante se le aplicaron operaciones de morfología binaria tales como apertura y relleno de agujeros (Ver Anexo I) . Finalmente se filtra por área para descartar detecciones no deseadas.

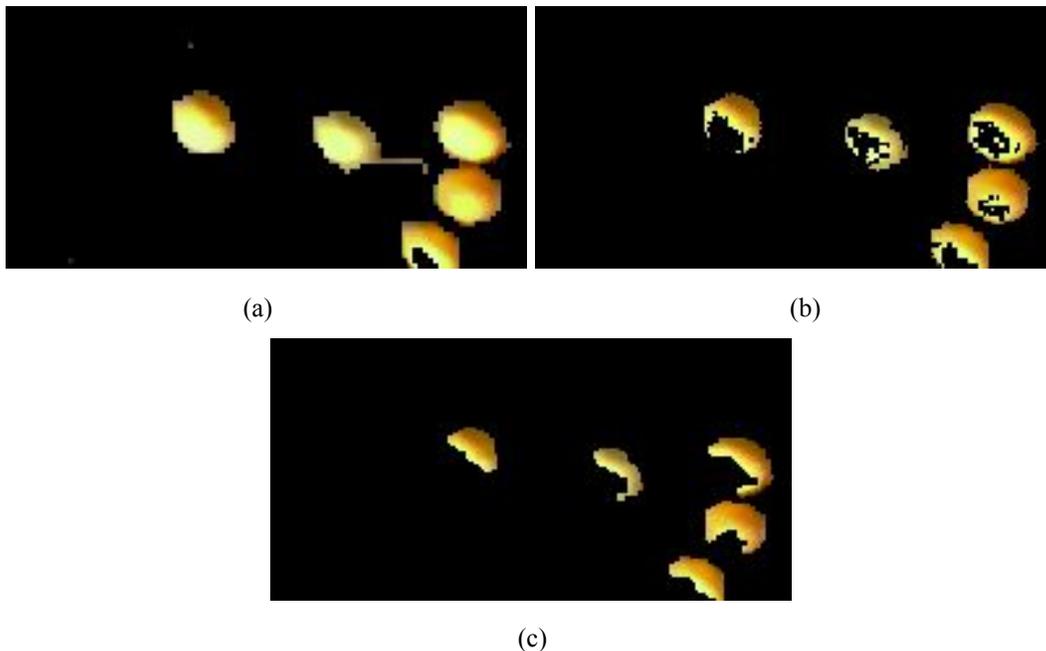


Figura 20. Segmentación obtenida. (a) Pre-segmentación por índices. (b) Segmentación después de la sustracción de máscara NDI. (c) Resultado de aplicar morfología binaria a la segmentación.

Durante la fase de prueba se fueron realizando varios cambios relacionados a la segmentación. Uno de los inconvenientes presentes en este tipo de problemáticas es la presencia de grupos de frutos que debido a la segmentación quedan contemplados como un solo fruto. Además de las técnicas mencionadas en la sección de Pruebas Preliminares, se optó por utilizar la información de un área promedio de fruto, para que cuando se encuentre un fruto con un área mayor pueda ser dividida por esa área promedio. Tras varias pruebas realizadas en el algoritmo se observó que los frutos en la cinta tienden a separarse incluso si en un momento estuvieron juntos. Esto es resultado de la segmentación utilizada donde no se tiene en cuenta todo el fruto sino solo una parte del mismo.

4.2.3.3. Técnicas de Tracking

Una vez obtenidas las máscaras binarias de los frutos se utilizó un proceso de tracking basado en el algoritmo de optimización combinatoria de asignaciones conocido como Algoritmo de Kuhn-Munkres [26]. Dicho algoritmo actúa sobre una matriz de costos generada a partir de distancias de las detecciones en relación a detecciones anteriores. Este algoritmo es el mismo utilizado en “Inverted tracking algorithm for the field survey through artificial vision and robotics” [28], sus parámetros fueron adaptados a fin de satisfacer las nuevas necesidades de detección. Estos parámetros están asociados a la velocidad en que los frutos se mueven por la cinta transportadora, se modificaron los parámetros de aceptación y rechazo de detecciones a partir de las distancias de la matriz de costos y el tiempo de vida de las detecciones.

El algoritmo trabaja sobre un buffer de datos, que indicaremos como buffer de tracks, que se utiliza para almacenar aquellos tracks que se obtienen del procesamiento de cada frame de video. A partir del frame obtenido, se selecciona el área a procesar y luego se binariza (segmenta) la imagen a partir de las técnicas de procesamiento digital especificadas en la sección anterior. Con los contornos resultantes se procede a la asignación de las detecciones a los tracks existentes en el buffer de tracks.

Si la detección que se analiza corresponde a un track existente, o sea que fue asociada por el algoritmo de Kuhn-Munkres, se actualiza el track correspondiente con su posición. Si la detección no fue asignada entonces se la considera como un nuevo track y se incorpora el mismo al buffer de tracks para que quede disponible para la evaluación del siguiente frame. Puede darse el caso de que queden tracks del buffer de tracks que no tengan nuevas asignaciones durante la evaluación de algún frame. Estos tracks que llamaremos tracks perdidos, se mantendrán por un ciclo predeterminado en el buffer y luego serán desestimados.

4.3. Pruebas y resultados

El algoritmo descrito se probó en 6 videos tomados en una misma cosecha. En la Figura 21 se puede observar el algoritmo corriendo sobre uno de esos videos. En rojo se muestra la zona de interés (ROI) donde se realiza el procesamiento y en verde cada uno de los tracks con un número asociado que representa la cantidad de tracks correctos detectados (cantidad de frutos detectados).



Figura 21. Algoritmo de tracking corriendo sobre un video tomado mientras se realizaba la cosecha de los frutos.

Gracias a la segmentación utilizada, el conjunto de frutos que el algoritmo contaba como un solo fruto, logra separarse creando nuevos tracks para cada uno que se separa y manteniendo el track antes grupal pero ahora asignado a un solo fruto.



(a)

(b)

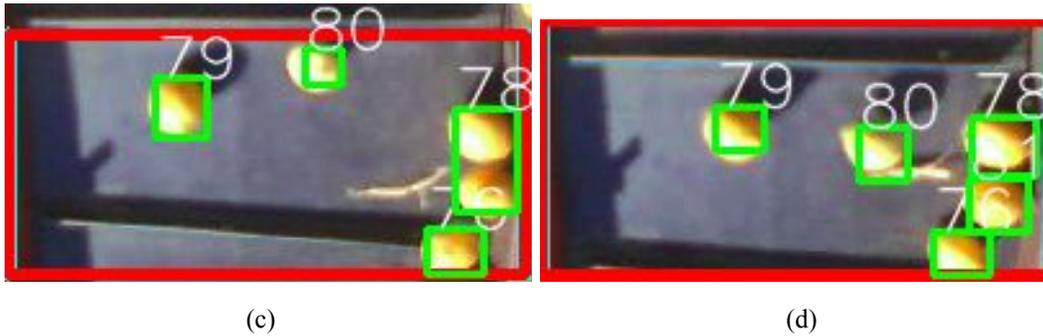


Figura 22. Ejemplos del comportamiento de los frutos. (a) y (c) Frutos juntos. (b) y (d) Frutos separados.

Para valorar la eficiencia de los resultados obtenidos por el algoritmo, se analizaron 6 videos con duraci3n promedio de 25 segundos cada uno. De cada video se analiz3 el comportamiento frame a frame. Por cada segundo (30 frames) se extrajo la verdad de campo a trav3s de un recuento visual de los frutos que fueron pasando por la cinta transportadora. Estos n3meros se fueron comparando con las cantidad brindadas por el algoritmo. A partir de estos datos, se desarroll3 un modelo de regresi3n lineal en el que se puede visualizar la correspondencia del algoritmo con la cantidad real.

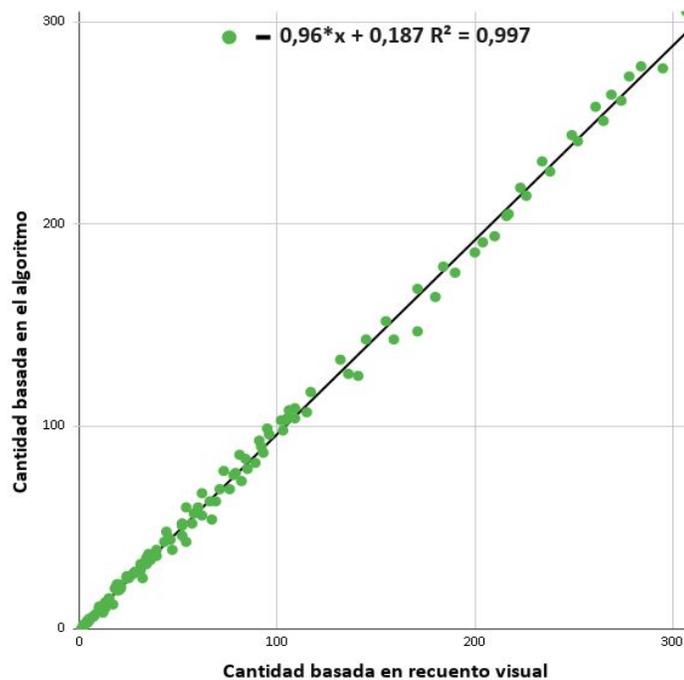


Figura 23. Nube de puntos que relaciona cantidades obtenidas por el algoritmo y recuento visual, con la recta de regresi3n que muestra la correspondencia de ambas variables.

El valor estadístico coeficiente de correlación (R^2) es un valor entre 0 y 1 asociado a la capacidad que tiene el modelo de predecir nuevos datos a partir de la cual se determina la calidad del modelo generado y cómo varían los valores a predecir. En este caso es utilizado para saber la correspondencia de los datos sabiendo con qué calidad puede llegar a producir nuevos. Cuando los valores basados en recuento visual y basados en el algoritmo varían en poca proporción, la recta de regresión obtenida debe ser lo más parecida a una recta identidad ($f(x)=x$), lo que se traduce a cantidad visual = cantidad algoritmo. La recta obtenida es (3).

$$y= 0.96*x+0.187 \quad (3)$$

El coeficiente de correlación igual a 0.997 indica que existe una gran correspondencia entre los datos. Finalmente obtenemos que el algoritmo desarrollado tiene un error promedio del 4,45%.

5. Conclusiones

En este trabajo se desarrolló un algoritmo capaz de reconocer limones en tiempo real en el momento en que se estaba llevando a cabo la cosecha de los mismos. Este algoritmo fue probado en videos tomados en una escena con condiciones de luz natural donde se muestra como son movidos en una cinta transportadora. La implementación del algoritmo utiliza técnicas basadas en índice de color, segmentación por rango de valores en el esquema de color CieLAB, morfología matemática (binaria y en color) y el algoritmo de tracking Kuhn-Munkres.

Es importante mencionar que en este informe se describieron las técnicas finales utilizadas para afrontar el problema y sus resultados en la cinta transportadora, pero antes de ellas se probaron otras técnicas que tuvieron resultados inviables respecto a restricciones relacionadas con su poca efectividad en el reconocimiento y su tiempo de procesamiento. Pruebas realizadas con el mismo algoritmo en otras escenas, como la copa de la planta y el suelo, muestran que las condiciones de luz natural, velocidad de tracking, resolución espacial y radiométrica de la imagen, entre otras, son variables a tener en cuenta y a modificar para que el algoritmo tenga la capacidad de generalizar y obtener resultados aceptables. Algunas de estas técnicas mencionadas fueron especificadas en la sección de Pruebas preliminares con la finalidad de mostrar el trabajo realizado, los inconvenientes encontrados y las experiencias que fueron importantes para llegar al resultado final mencionado en este informe.

Para destacar, este trabajo significó el aprendizaje de un área de la informática como es el procesamiento de imágenes con auge en la actualidad y en los últimos años debido a sus incontables aplicaciones en diferentes disciplinas, lo cual fue de mi atracción desde el

primer momento. Pude llevarlo a cabo gracias al equipo de trabajo reunido en la materia Procesamiento de Imágenes constituido por alumnos y profesores, con el cual participamos de diferentes proyectos de investigación y nos encontramos en constante aprendizaje.

6. Anexos

6.1. Marco teórico

En esta sección se describen los fundamentos teóricos relativos a las técnicas que se han utilizado en las distintas fases que componen el trabajo de investigación. Estos conceptos se encuentran desarrollados en el libro de Gonzales & Woods [30].

6.1.1. Espacios de color

El sistema visual humano (HVS) puede ver una parte del espectro electromagnético, aproximadamente entre los 400 y los 750 nm. En esta franja, denominada espectro visible, es donde se ubican las distintas longitudes de onda que comúnmente se denominan colores.

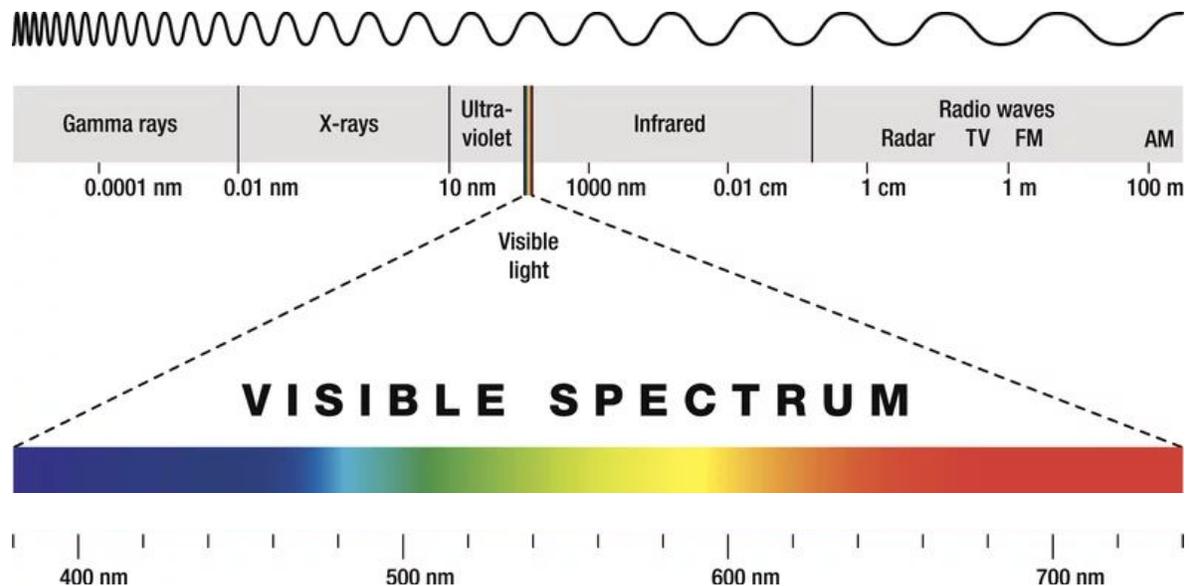


Figura 24. Espectro visible

Un espacio de color es una notación por la que se pueden especificar los colores. Existen múltiples espacios de color, ya que, en el fondo, como no son más que representaciones matemáticas de fenómenos físicos, se puede abordar el tema desde muchas perspectivas. Otro de los motivos por los que existen múltiples modelos es la necesidad para la que se creó cada uno de ellos: algunos están diseñados para que el usuario interactúe con ellos, siendo mejores a la hora de su representación, otros para el procesamiento de datos por computadora los cuales buscan ser lo más eficientes posibles u otros parten de unas necesidades específicas que han de cumplirse.

La elección de un espacio de color es una tarea muy importante para la que se deben conocer y entender las distintas posibilidades y así poder escoger la más adecuada para cada tarea.

6.1.1.1. Espacio de color RGB

Es un modelo basado en los colores que estimulan los 3 tipos de conos en la retina humana y por tanto es un modelo de colores inspirados fisiológicamente que utiliza los tres primarios aditivos rojo (R), verde (G) y azul (B). Se representa como un cubo donde los vértices son los colores primarios y el origen es el negro. Sus valores se normalizan entre 0 y 1, por lo que el (0,0,0) es el negro y el (1,1,1) el blanco puro.

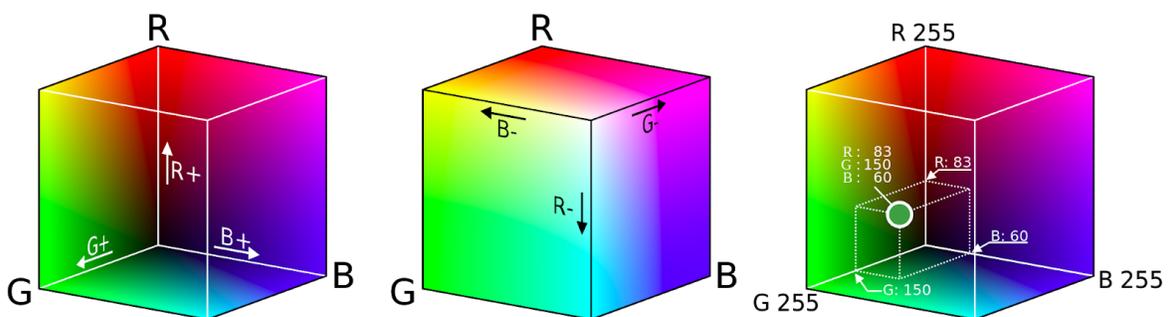


Figura 25. Cubo RGB

Este modelo se asocia fundamentalmente a la representación del color en los monitores y los escáneres. Las relaciones para este modelo aditivo son:

- $G + B = \text{Celeste (Cyan)}$

- $B + R = \text{Magenta (M)}$
- $R + G = \text{Amarillo (Yellow)}$
- $R + G + B = \text{Blanco (W)}$

6.1.1.2. Espacio de color CIE Lab

La CIE (siglas en francés de la comisión internacional de la iluminación) es una organización dedicada a la cooperación internacional y el intercambio de información relacionada con el arte y la ciencia de la luz y la iluminación, el color y la visión, la fotobiología y la tecnología de la imagen. El primer espacio de color creado por la CIE fue el XYZ, que es un espacio de color artificial, cuya característica más importante es la independencia de sus componentes obtenidas a partir del espectro de reflectancia $R(\lambda)$ de un objeto, iluminado por una fuente $S(\lambda)$. Utilizando fórmulas estándares los valores RGB de las cámaras digitales se transforman en valores triestímulo CIE-XYZ y posteriormente a valores CIELab.

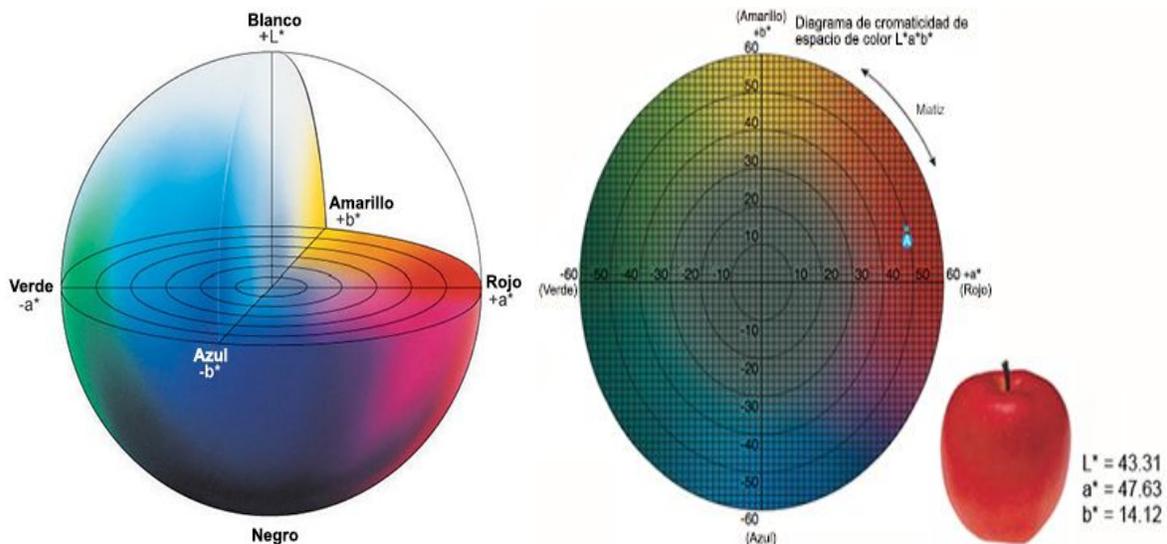


Figura 26. Espacio de color CIELab

Los parámetros de color L, a y b, designan: L, la luminosidad; a, el color rojo (valores positivos) o verde (valores negativos) y b, el color amarillo (valores positivos) o azul (valores negativos).

6.1.2. Segmentación

La segmentación de imágenes consiste en descomponer una imagen en las partes que la constituyen, es decir, los objetos de interés y el fondo, esto se realiza a partir de diferentes características locales. La mayoría de las imágenes están constituidas por regiones o zonas que tienen características homogéneas (textura, nivel de gris, etc.).

La segmentación basada en similitudes divide la imagen basándose en la búsqueda de zonas que tengan valores similares, conforme a unos criterios prefijados. La umbralización es el método más simple para la segmentación de una imagen. Los umbrales actúan como separadores que permitirán decidir qué conjunto de tonos de gris pertenece a una determinada región.

El objetivo de la segmentación es cambiar y/o simplificar la representación de la imagen de forma que la nueva imagen sea más significativa y resulte más fácil de analizar.

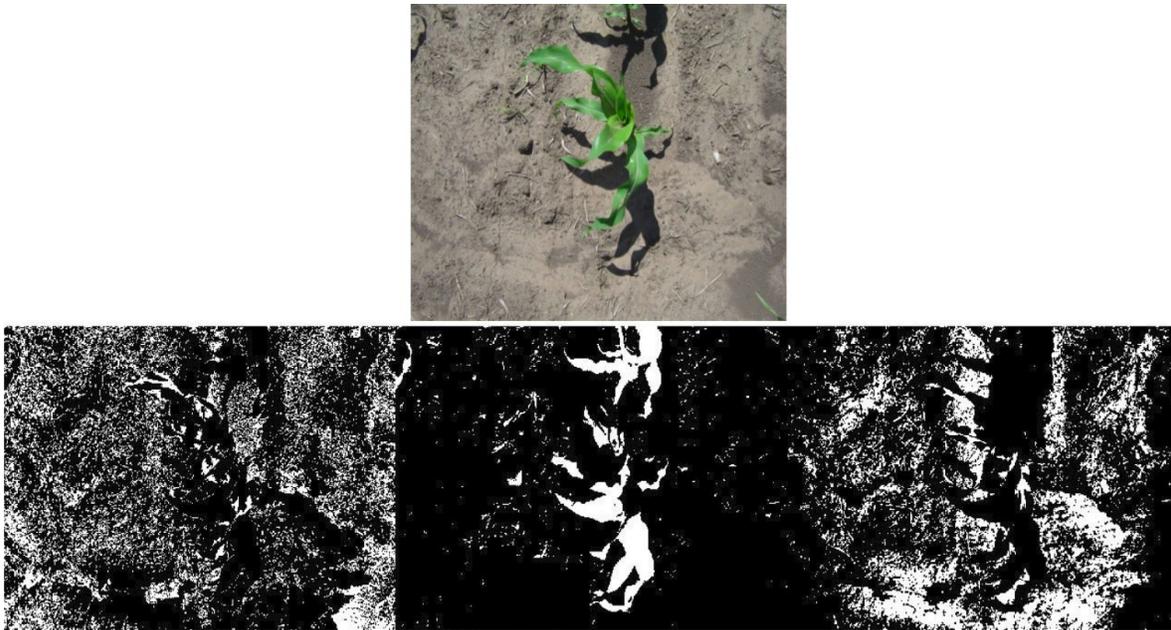


Figura 27. Ejemplo de umbralización de las capas R, G y B.

6.1.3. Índices cromáticos de vegetación

Los índices de vegetación (VI, vegetation index) son medidas empíricas obtenidas al cuantificar y combinar dos o más bandas del espectro electromagnético, normalmente el infrarrojo cercano y la luz visible, que reflejan la vegetación. Con los VI se trata de obtener

datos con los que caracterizar el tipo, la cantidad, el estado y la situación de la vegetación en el escenario que se quiere analizar. Dentro de estos índices es posible hacer una diferenciación, por un lado están los que emplean el espectro infrarrojo cercano (NIR) y por otro los que hacen uso únicamente del espectro visible.

Existe un índice denominado normalized difference vegetation index (NDI) creado con la finalidad de separar plantas del suelo y otros residuos externos, que se calcula a partir del esquema de color RGB y utiliza solo las capas R y G. Está dado por:

$$NDI = \frac{G - R}{G + R}$$

A partir del cálculo del índice se pueden aplicar diferentes técnicas de segmentación con el objetivo de obtener la planta:

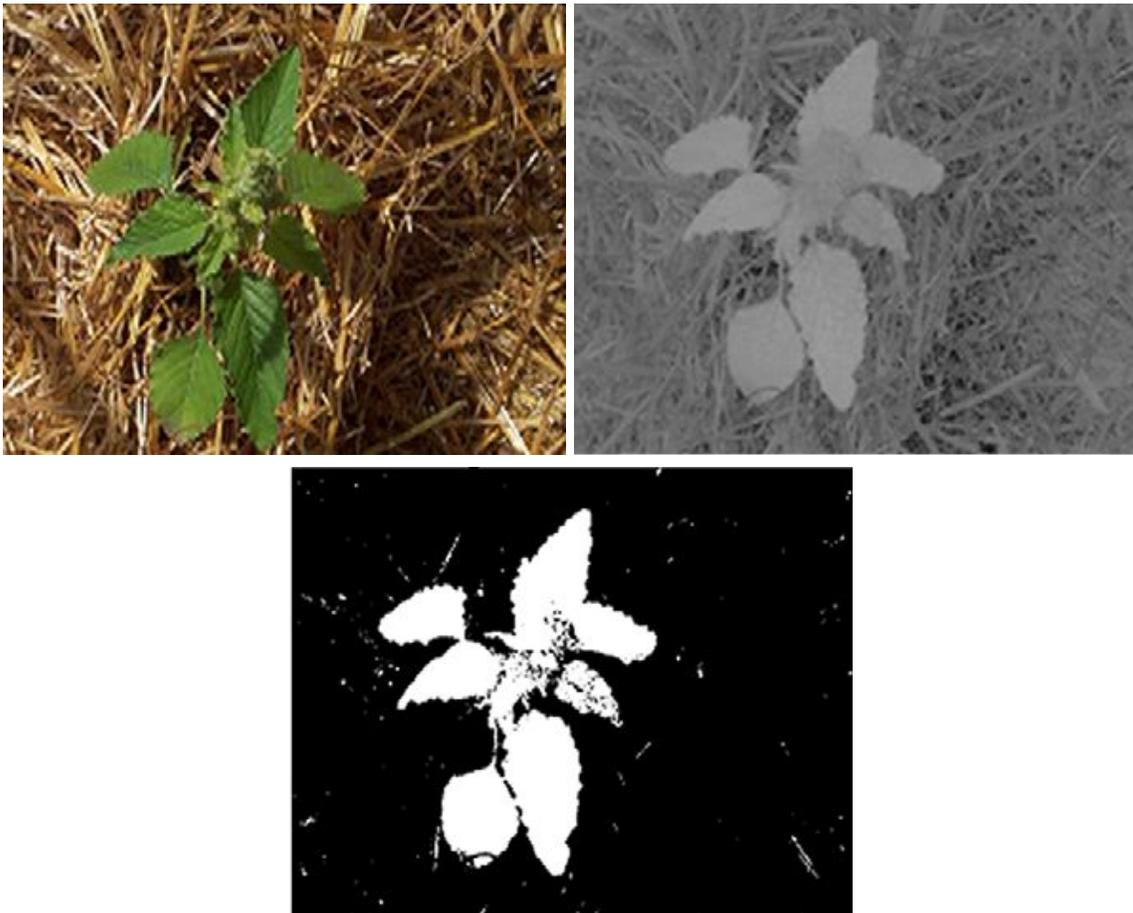


Figura 28. Ejemplo de utilizar índice NDI con segmentación por el método Otsu.

6.1.4. Morfología matemática

La descripción básica de la Morfología Matemática descansa en la ‘teoría de conjuntos’, toda operación morfológica es el resultado de una o más operaciones de conjuntos (unión, intersección, complementación) haciendo intervenir dos conjuntos X , Y , ambos subconjuntos de un conjunto espacio Z . De los dos subconjuntos, Y recibe el nombre de elemento estructurante que, para operar con X , se desplazará a través del espacio Z . El tamaño y la forma de este elemento se escoge, a priori, de acuerdo la morfología del conjunto sobre el que va a interaccionar y de acuerdo a la extracción de formas que se desean obtener. El elemento estructurante consiste en una matriz binaria de tamaño predefinido conteniendo una forma geométrica particular.

Se pueden encontrar aplicaciones tales como la segmentación, restauración, detección de bordes, aumento de contraste, análisis de texturas, compresión, etc

6.1.4.1. Erosión

La transformación de erosión es el resultado de comprobar si el elemento estructurante B está totalmente incluido dentro del conjunto X . Cuando esto no ocurre, el resultado de la erosión es el conjunto vacío.

$$ero^B(X) = \{x \in X : B_x \subset X\} \quad \text{siendo } B_x = \{b + x : b \in B\}$$

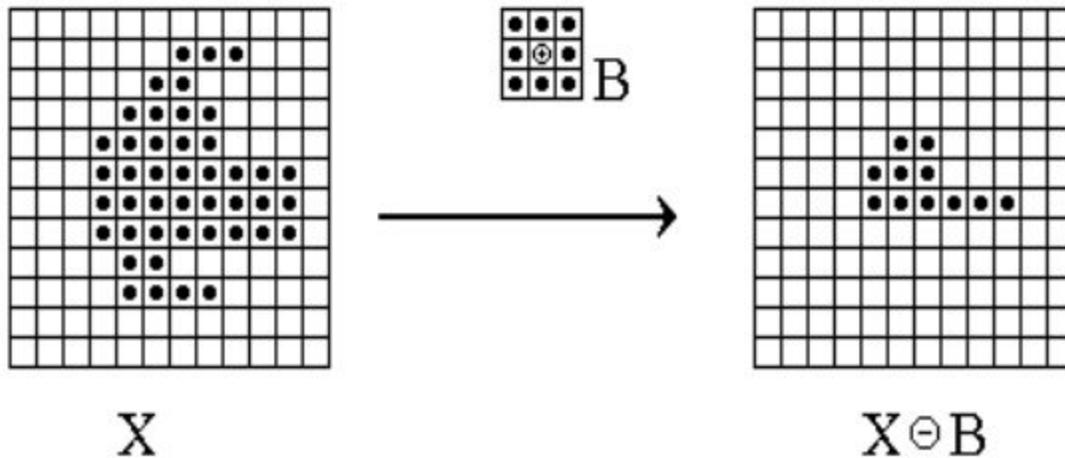


Figura 29. Ejemplo de erosión binaria

Esta operación combina dos conjuntos usando la resta vectorial. Retorna sólo aquellos píxeles de X para los cuales todas las posibles traslaciones de B están también en X .

El resultado de la erosión en señales bidimensionales de escala de grises es una señal de menor valor, es decir, una imagen más oscura, puesto que la erosión pretende minimizar el valor de la señal que, en el caso de los grises tiene una definición $[0,255]$.

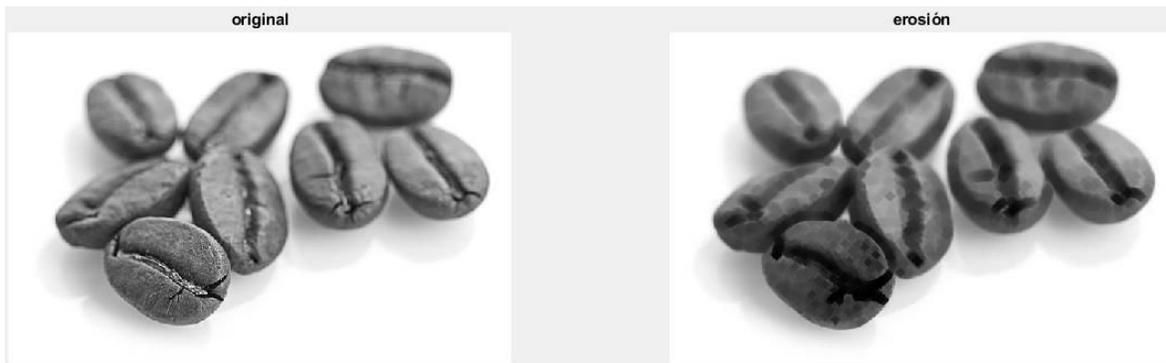


Figura 30. Ejemplo de erosión en grises

6.1.4.2. Dilatación

La dilatación es la operación dual de la erosión. El resultado de la dilatación es el conjunto de puntos origen del elemento estructurante B tales que el elemento estructurante contiene

algún elemento del conjunto X , cuando el elemento se desplaza por el espacio que contiene a ambos conjuntos.

$$dil^B(X) = \{x \in X : B_x \cap X \neq \emptyset\} \text{ siendo } B_x = \{b + x : b \in B\}$$

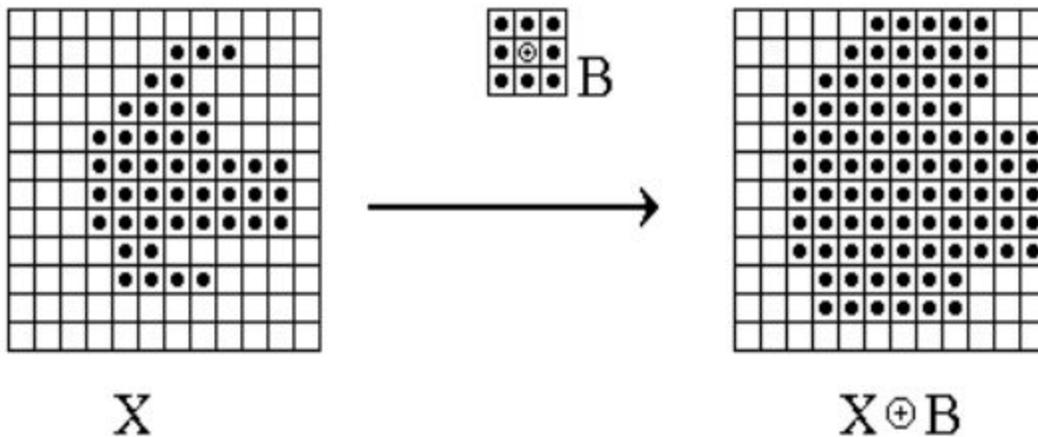


Figura 31. Ejemplo de dilatación binaria

Esta operación hace que los objetos se expandan. La cantidad y forma en la que lo hacen depende del elemento estructurante.

El resultado de la dilatación en señales bidimensionales de escala de grises es, generalmente, una señal de mayor valor, es decir, una imagen más clara, puesto que la dilatación maximiza el valor de la señal.

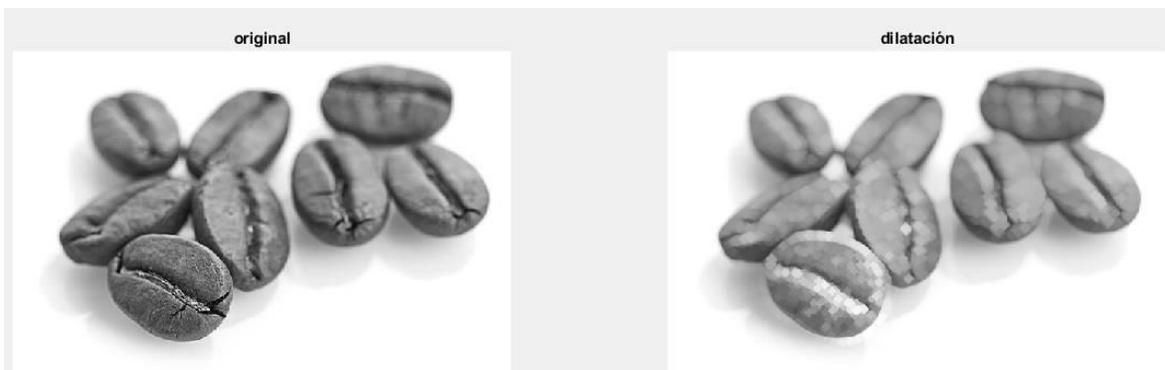


Figura 32. Ejemplo de dilatación en grises

6.1.4.3. Apertura

La operación de apertura se define como la combinación de la operación de erosión con un elemento estructurante B seguida de la dilatación por el mismo elemento estructurante.

$$AB = dil^B(ero^B(A))$$

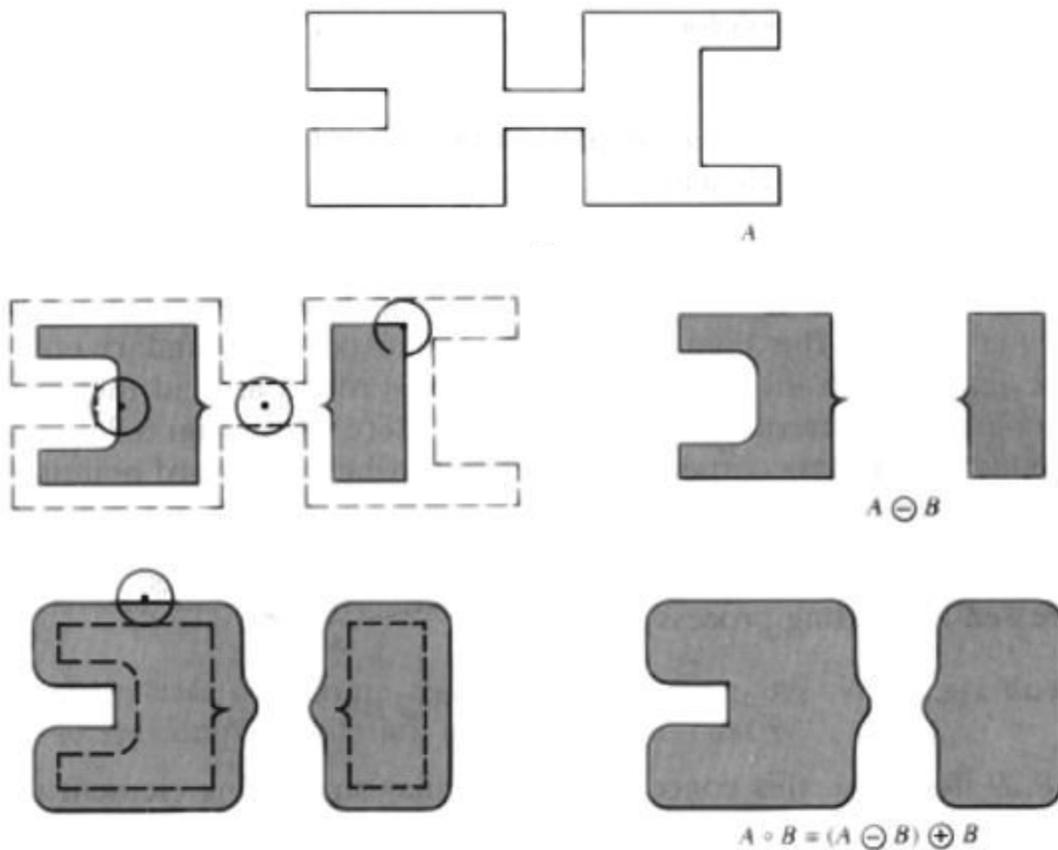


Figura 33. Ejemplo de apertura binaria con un disco como elemento estructurante.

El objeto de esta operación es suavizar los bordes de los objetos, también se usa para eliminar elementos pequeños.

La apertura en grises se usa para borrar detalles claros que sean pequeños en comparación con el elemento estructural, manteniendo el resto de la imagen prácticamente igual (la erosión también elimina pequeños detalles claros pero oscurecía toda la imagen).

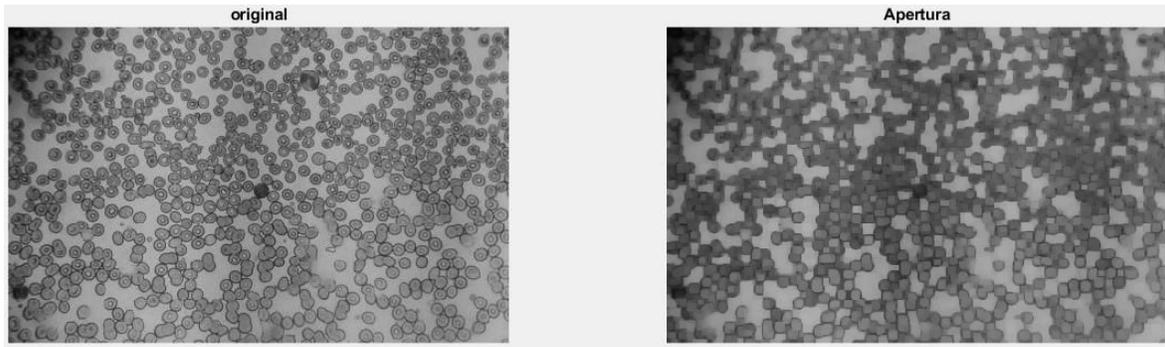
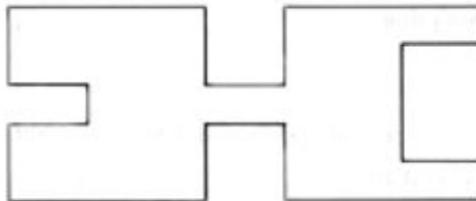


Figura 34. Ejemplo de apertura en grises.

6.1.4.4. Cierre

La operación de apertura se define como la combinación de la operación de erosión con un elemento estructurante B seguida de la dilatación por el mismo elemento estructurante.

$$A \bullet B = \text{ero}^B (\text{dil}^B (A))$$



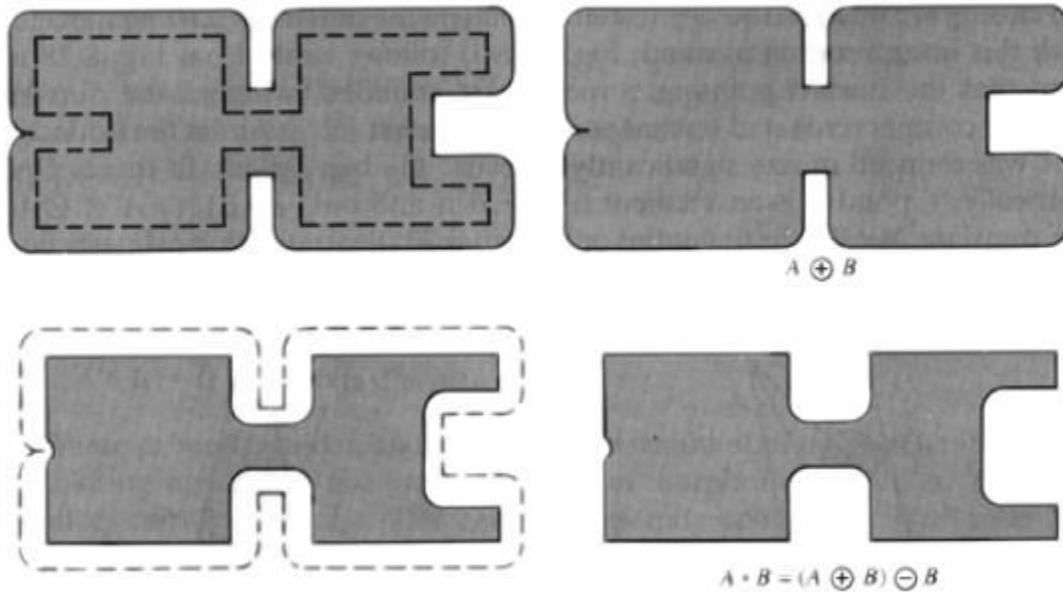


Figura 35. Ejemplo de cierre binaria con un disco como elemento estructurante.

Se usa para rellenar espacios tipo “agujeros” en las componentes, también se usa para unir elementos cercanos.

El cierre en grises elimina detalles oscuros de la imagen, dejando el resto prácticamente igual (la dilatación también elimina detalles oscuros, pero aclaraba la imagen en general).

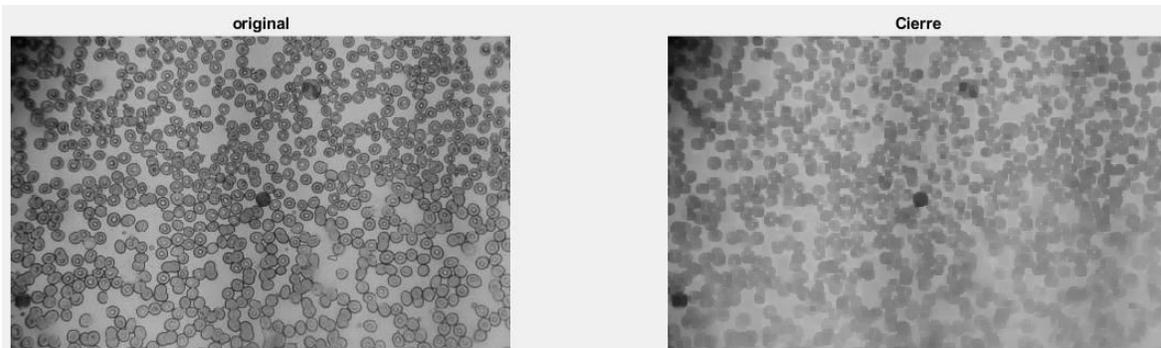


Figura 36. Ejemplo de cierre en gris.

7. Bibliografía

- [1] E. García and F. Flego, "Tecnología agropecuaria. Agricultura de precisión", 2020. [Online]. Available: <https://www.palermo.edu/ingenieria/downloads/pdfwebc&T8/8CyT12.pdf>. [Accessed: 12- Jun- 2020].
- [2] M. Bagrachini, A. Mendez, F. Scaramuzza, "Monitor de Rendimiento y Conocimientos de Calibración", Proyecto Agricultura de Precisión - INTA Manfredi, 2015.
- [3] Z. Zhai, J. Martínez, V. Beltran and N. Martínez, "Decision support systems for agriculture 4.0: Survey and challenges", *Computers and Electronics in Agriculture*, vol. 170, p. 105256, 2020. Available: 10.1016/j.compag.2020.105256 [Accessed 13 June 2020].
- [4] A. Gongal, S. Amatya, M. Karkee, Q. Zhang and K. Lewis, "Sensors and systems for fruit detection and localization: A review", *Computers and Electronics in Agriculture*, vol. 116, pp. 8-19, 2015. Available: 10.1016/j.compag.2015.05.021.
- [5] H. Xu and Y. Ying, "Citrus fruit recognition using color image analysis", *Intelligent Robots and Computer Vision XXII: Algorithms, Techniques, and Active Vision*, 2004. Available: 10.1117/12.570736 [Accessed 13 June 2020].
- [6] H. Li, W. Lee and K. Wang, "Immature green citrus fruit detection and counting based on fast normalized cross correlation (FNCC) using natural outdoor colour images", *Precision Agriculture*, vol. 17, no. 6, pp. 678-697, 2016. Available: 10.1007/s11119-016-9443-z [Accessed 13 June 2020].
- [7] P. Li, S. Lee, H. Hsu and J. Park, "Nonlinear Fusion of Multispectral Citrus Fruit Image Data with Information Contents", *Sensors*, vol. 17, no. 12, p. 142, 2017. Available: 10.3390/s17010142 [Accessed 13 June 2020].
- [8] P. Li, S. Lee and H. Hsu, "Fusion on Citrus Image Data from Cold Mirror Acquisition System", *International Journal of Computer Vision and Image Processing*, vol. 2, no. 4, pp. 11-24, 2012. Available: 10.4018/ijcvip.2012100102 [Accessed 13 June 2020].
- [9] P. Li, S. Lee and H. Hsu, "Study on citrus fruit image data separability by segmentation methods", *Procedia Engineering*, vol. 23, pp. 408-416, 2011. Available: 10.1016/j.proeng.2011.11.2522.
- [10] J. Gené-Mola et al., "Fruit detection in an apple orchard using a mobile terrestrial laser scanner", *Biosystems Engineering*, vol. 187, pp. 171- 184, 2019. Available: 10.1016/j.biosystemseng.2019.08.017 [Accessed 13 June 2020].
- [11] D. Choi, W. Lee, J. Schueller, R. Ehsani, F. Roka and J. Diamond, "A performance comparison of RGB, NIR, and depth images in immature citrus detection using deep

learning algorithms for yield prediction", 2017 Spokane, Washington July 16 - July 19, 2017, 2017. Available: 10.13031/aim.201700076 [Accessed 13 June 2020].

[12] S. Sengupta and W. Lee, "Identification and determination of the number of immature green citrus fruit in a canopy under different ambient light conditions", *Biosystems Engineering*, vol. 117, pp. 51- 61, 2014. Available: 10.1016/j.biosystemseng.2013.07.007 [Accessed 13 June 2020].

[13] S. Chaivivatrakul and M. Dailey, "Texture-based fruit detection", *Precision Agriculture*, vol. 15, no. 6, pp. 662-683, 2014. Available: 10.1007/s11119-014-9361-x [Accessed 13 June 2020].

[14] R. Linker, O. Cohen and A. Naor, "Determination of the number of green apples in RGB images recorded in orchards", *Computers and Electronics in Agriculture*, vol. 81, pp. 45-57, 2012. Available: 10.1016/j.compag.2011.11.007 [Accessed 13 June 2020].

[15] M. Hannan, T. Burks and D. Bulanon, "A Machine Vision Algorithm Combining Adaptive Segmentation and Shape Analysis for Orange Fruit Detection", *Cigrjournal.org*, 2020. [Online]. Available: <https://cigrjournal.org/index.php/Ejournal/article/view/1281>. [Accessed: 13- Jun- 2020].

[16] D. Font et al., "Counting red grapes in vineyards by detecting specular spherical reflection peaks in RGB images obtained at night with artificial illumination", *Computers and Electronics in Agriculture*, vol. 108, pp. 105-111, 2014. Available: 10.1016/j.compag.2014.07.006 [Accessed 13 June 2020].

[17] I. Sa, Z. Ge, F. Dayoub, B. Upcroft, T. Perez and C. McCool, "DeepFruits: A Fruit Detection System Using Deep Neural Networks", *Sensors*, vol. 16, no. 8, p. 1222, 2016. Available: 10.3390/s16081222.

[18] M. Rahnemoonfar and C. Sheppard, "Deep Count: Fruit Counting Based on Deep Simulated Learning", *Sensors*, vol. 17, no. 4, p. 905, 2017. Available: 10.3390/s17040905.

[19] N. Häni, P. Roy and V. Isler, "A comparative study of fruit detection and counting methods for yield mapping in apple orchards", *Journal of Field Robotics*, 2019. Available: 10.1002/rob.21902 [Accessed 13 June 2020].

[20] A. Koirala, K. Walsh, Z. Wang and C. McCarthy, "Deep learning for real-time fruit detection and orchard fruit load estimation: benchmarking of ‘MangoYOLO’", *Precision Agriculture*, vol. 20, no. 6, pp. 1107-1135, 2019. Available: 10.1007/s11119-019-09642-0 [Accessed 13 June 2020].

[21] S. Chen et al., "Counting Apples and Oranges With Deep Learning: A Data-Driven Approach", *IEEE Robotics and Automation Letters*, vol. 2, no. 2, pp. 781-788, 2017. Available: 10.1109/lra.2017.2651944 [Accessed 13 June 2020].

- [22] L. Zhang, D. He and H. Song, "Automatic tracking of multi-fruit targets with oscillation under natural growth conditions", *Information Processing in Agriculture*, 2019. Available: 10.1016/j.inpa.2019.11.004 [Accessed 13 June 2020].
- [23] X. Liu et al., "Robust Fruit Counting: Combining Deep Learning, Tracking, and Structure from Motion", 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2018. Available: 10.1109/iros.2018.8594239 [Accessed 13 June 2020].
- [24] X. Liu et al., "Monocular Camera Based Fruit Counting and Mapping With Semantic Data Association", *IEEE Robotics and Automation Letters*, vol. 4, no. 3, pp. 2296-2303, 2019. Available: 10.1109/lra.2019.2901987 [Accessed 13 June 2020].
- [25] "Maqtec", Maqtec.com, 2020. [Online]. Available: <http://www.maqtec.com/>. [Accessed: 13- Jun- 2020].
- [26] H. Cui, J. Zhang, C. Cui and Q. Chen, "Solving large-scale assignment problems by Kuhn-Munkres algorithm", *Proceedings of the 2nd International Conference on Advances in Mechanical Engineering and Industrial Informatics (AMEII 2016)*, 2016. Available: 10.2991/ameii- 16.2016.160 [Accessed 13 June 2020].
- [27] G. Meyer and J. Neto, "Verification of color vegetation indices for automated crop imaging applications", *Computers and Electronics in Agriculture*, vol. 63, no. 2, pp. 282-293, 2008. Available: 10.1016/j.compag.2008.03.009 [Accessed 13 June 2020].
- [28] E. Alvarez, S. Serafino, B. Cicerchia, A. Balmer, C. Russo and H. Ramon, "Inverted tracking algorithm for the field survey through artificial vision and robotics", 2017 XLIII Latin American Computer Conference (CLEI), 2017. Available: 10.1109/clei.2017.8226374 [Accessed 13 June 2020].
- [29] U. Dorj, M. Lee and S. Yun, "An yield estimation in citrus orchards via fruit detection and counting using image processing", *Computers and Electronics in Agriculture*, vol. 140, pp. 103-112, 2017. Available: 10.1016/j.compag.2017.05.019 [Accessed 4 December 2020].
- [30] R. C. González, R. E. Woods. *Digital Image Proccesing*. 3rd ed. 2008

8. Agradecimientos

En esta ocasión quiero agradecer a todas las personas que formaron parte de este proceso.

A mi familia, en especial a mi madre que me adjudicó su experiencia acerca de lo importante que es el estudio. Invaluables palabras han de ser dichas para permanecer en nuestros corazones.

A mis directores de proyecto, Sandra y Benjamín que de buena voluntad siempre estuvieron para dar una mano, mostrando el camino que hizo este trabajo posible.

Especial nombramiento a aquellas fuerzas mayores y exquisitas energías que así lo permitieron, estuvieron presentes cuando más se necesitó. Voluntad, perseverancia, amistad, felicidad, frustración, desarraigo, esperanzas.

Gracias por perdurar *.

**El perdurantismo trata de la persistencia y de la identidad. Defiende que los objetos tienen partes temporales o fases en cualquier momento de su existencia, las fases pueden ser pasadas o futuras pero eso no las hace menos reales que las fases que pueden ser accedidas en cualquier momento del presente.*