



UNIVERSIDAD TÉCNICA DE AMBATO

**FACULTAD DE CIENCIA E INGENIERÍA EN ALIMENTOS Y
BIOTECNOLOGÍA**

CARRERA DE INGENIERÍA EN ALIMENTOS

Control de maduración de aguacate mediante análisis de imagen.

Trabajo de Titulación, Modalidad Proyecto de Investigación, previo la obtención del Título de Ingeniero en Alimentos, otorgado por la Universidad Técnica de Ambato, a través de la Facultad de Ciencia e Ingeniería en Alimentos y Biotecnología.

Autor: Andrés Leonardo Pasato Guanga

Tutor: Dr. Esteban Mauricio Fuentes Pérez

Ambato - Ecuador

Septiembre – 2022

APROBACIÓN DEL TUTOR

Dr. Esteban Mauricio Fuentes Pérez

CERTIFICA:

Que el presente documento ha sido prolijamente revisado. Por lo tanto, autorizo la presentación de este trabajo de Titulación bajo la modalidad Proyecto de Investigación, el mismo que responde a las normas establecidas en el Reglamento de Títulos y Grados de la Facultad de Ciencia e Ingeniería en Alimentos y Biotecnología.

Ambato, 07 de febrero del 2022

Dr. Esteban Mauricio Fuentes Pérez

C.I.: 1803321502

TUTOR

DECLARACIÓN DE AUTENTICIDAD

Yo, Andrés Leonardo Pasato Guanga, manifiesto que los resultados obtenidos en el presente Trabajo de Titulación, modalidad Proyecto de Investigación, previo a la obtención del título de Ingeniera en Alimentos, son absolutamente originales, auténticos y personales, a excepción de las citas bibliográficas.

A handwritten signature in black ink, appearing to read "Andrés Leonardo Pasato Guanga". The signature is stylized with a large initial 'A' and a long horizontal stroke.

Andrés Leonardo Pasato Guanga

C.C. 0106240344

AUTOR

APROBACIÓN DE LOS MIEMBROS DEL TRIBUNAL DE GRADO

Los suscritos Profesores Calificadores, aprueban el presente Trabajo de Titulación, modalidad proyecto de investigación, mismo que ha sido elaborado de conformidad con las disposiciones emitidas por la Facultad de Ciencia e Ingeniería en Alimentos y Biotecnología de la Universidad Técnica de Ambato.

Para constancia firman:

Presidente del Tribunal

Dra. Jacqueline de las Mercedes Ortiz Escobar
C.I. 1802171353

Rubén Darío Vilcacundo Chamorro PhD
C.I. 1802738102

Ambato, 08 de agosto del 2022

DERECHOS DE AUTOR

Autorizo a la Universidad Técnica de Ambato, para que haga de este Trabajo de Titulación o parte de él, como documento disponible para su lectura, consulta y procesos de investigación, según las normas de la Institución.

Cedo los Derechos en línea patrimoniales de mi Trabajo de Titulación, con fines de difusión pública, además apruebo la reproducción de este, dentro de las regulaciones de la Universidad, siempre y cuando esta reproducción no suponga una ganancia económica y se realice respetando mis derechos de autor.



Andrés Leonardo Pasato Guanga

C.I.: 0106240344

AUTOR

DEDICATORIA

A mi padre Segundo, quien me ha enseñado que con esfuerzo se alcanzan los sueños, que los logros sin ética no tienen sentido. Quien me ha predicado con ejemplos el valor del sacrificio y me ha mostrado el camino que quiero seguir. Por ser mi mentor, mi compañero, mi líder y mi amigo.

A mi madre, Isabel, por enseñarme que siempre hay espacio para el amor y la ternura. Por confiar en mi incluso cuando yo no lo hacía, por las acciones y los sacrificios durante toda mi vida.

A toda mi familia que me acompañó en cada etapa de mi vida y me dieron la oportunidad de salir y estudiar mi carrera universitaria. Por demostrarme que después de todo, siempre tenemos a nuestra familia.

Andrés

AGRADECIMIENTO

Agradezco de manera infinita a mis padres que por el sacrificio que han hecho por estos seis años de mi carrera que pese a las situaciones difíciles por las que ha pasado el mundo, su apoyo ha sido inquebrantable.

A mi hermano José por sustituirme en mis labores el día en que decidí salir de mi cantón a estudiar en la Universidad.

Siempre pude contar con el apoyo de mi abuelita Eloisa, quien me alentaba a seguir en la universidad y obtener un título profesional.

A mis compañeros de aula, Maribel, Bryan y Paúl con quienes siempre pude contar en situaciones difíciles, compartir momentos inolvidables y que se volvieron mi familia durante mi estadía en la ciudad de Ambato.

A la Facultad de Ciencia e Ingeniería en Alimentos, las autoridades, los docentes, todo el personal. A mi tutor, el Dr. Esteban Fuentes por ayudarme en la elaboración de mi proyecto de grado y por permitirme realizar mi primera publicación.

ÍNDICE GENERAL DE CONTENIDOS

APROBACIÓN DEL TUTOR.....	ii
DECLARACIÓN DE AUTENTICIDAD	iii
APROBACIÓN DE LOS MIEMBROS DEL TRIBUNAL DE GRADO	iv
DERECHOS DE AUTOR	v
DEDICATORIA	vi
AGRADECIMIENTO.....	vii
CAPÍTULO I.....	1
MARCO TEÓRICO.....	1
1.1. Antecedentes investigativos.....	1
1.1.1. Justificación	1
1.1.2. Antecedentes.....	2
1.1.2.1. Estado de madurez en aguacate	2
1.1.2.2. Ensayos tradicionales para determinar madurez en aguacate.....	4
1.1.2.3. Tecnología en la cadena agroalimentaria	6
1.1.2.4. Técnicas no convencionales aplicados en alimentos.....	7
1.1.2.5. Análisis de imagen en alimentos.....	8
1.1.2.5.1. Sistema de análisis de imagen.....	9
1.1.2.5.2. Análisis de imagen en frutos.....	10
1.1.2.5.3. Hardware y software empleado.....	11
1.1.2.5.4. Ensayos realizados	12
1.1.2.5.5. Limitaciones del método	13
1.1.2.5.6. Tendencias	13
1.2. Objetivos	14
1.2.1. Objetivo General:.....	14
1.2.2. Objetivos Específicos:	14

CAPÍTULO II.....	15
METODOLOGÍA.....	15
2.1. Materiales.....	15
2.2. Métodos.....	15
2.2.1. Definición del problema.....	15
2.2.2. Búsqueda de la información.....	15
2.2.3. Organización de la información.....	16
2.2.4. Análisis de la información.....	17
CAPÍTULO III.....	18
RESULTADOS Y DISCUSIÓN.....	18
3.1. Análisis y discusión de los resultados.....	18
3.2. Análisis de imagen en frutos frescos.....	18
3.3. Espacio de color RGB.....	18
3.3.1. Instrumentación.....	19
3.3.2. Trabajos relacionados.....	19
3.4. Espacio de color CieLab.....	21
3.4.1. Instrumentación.....	23
3.4.2. Trabajos relacionados.....	23
3.5. Imágenes multiespectrales.....	25
3.5.1. Imagen de resonancia magnética (RMI).....	25
3.5.2. Infrarrojo cercano.....	26
3.5.3. Análisis de imágenes térmicas.....	28
3.5.4. Análisis de imagen hiperespectral (HSI).....	31
CAPÍTULO IV.....	33
CONCLUSIONES Y RECOMENDACIONES.....	33
4.1. Conclusiones.....	33
4.2. Recomendaciones.....	34

REFERENCIAS BIBLIOGRÁFICAS..... 35

ÍNDICE DE TABLAS

Tabla 1: Compuestos bioactivos presentes en el fruto de aguacate	16
Tabla 2: Procedimiento de un sistema de análisis de imagen en general	22
Tabla 3: Fuentes de información	29
Tabla 4: Aplicación de análisis de imagen en frutos frescos	31
Tabla 5: Sistemas NIR desarrollados	39
Tabla 6: Efectividad de los algoritmos en clasificación de madurez para aguacate.....	43

ÍNDICE DE FIGURAS

Figura 1: Intensidad de los canales RGB frente a los días de maduración en muestras de aguacate	33
Figura 2: Histogramas de los canales RGB para los frutos de aguacate maduros e inmaduros	34
Figura 3: Modelo o espacio de color CIELAB representado en un sistema cartesiano en coordenadas polares y cartesianas	35
Figura 4: El contenido de clorofila con relación a las coordenadas a^* y b^*	37
Figura 5: Firmeza medida por un punzómetro frente a la firmeza predicha por análisis de los parámetros Lab	38
Figura 6: Variación de la temperatura obtenida por procesamiento de imágenes térmicas durante la maduración de aguacate <i>Hall</i>	43
Figura 7: Regresión entre resultados de materia seca por el método tradicional vs el empleo de imágenes hiperespectrales	45

RESUMEN

El estado de madurez de los frutos frescos es un parámetro fundamental en la comercialización o procesamiento industrial. Tradicionalmente la determinación de madurez se ha realizado en laboratorios, analizando con una metodología y parámetros específicos cada fruto según su naturaleza. Para el fruto de aguacate se cuantifica la firmeza o el contenido de materia seca para estimar su madurez, estos ensayos se han adoptado por su alta fiabilidad y reproducibilidad. El estado de madurez en los frutos se diagnostica también por paneles de catadores o agricultores expertos, dejando espacio a la subjetividad. Las cadenas agroalimentarias han incorporado tecnología como soporte de la agricultura 4.0, sostenibilidad y producción orgánica, pilares principales de la calidad y seguridad alimentaria. Los métodos no invasivos de análisis son herramientas tecnológicas en la cadena alimentaria que posibilita disminuir errores por subjetividad y detectar con precisión parámetros no perceptibles al ojo humano. La tecnología de análisis de imagen permite cuantificar parámetros ópticos y correlacionarlos con fenómenos biológicos para automatizar procesos agrícolas. En este documento se examina la aplicación de análisis de imagen para controlar el estado de madurez en frutos de aguacate. Se aborda diferentes metodologías empleadas para la predicción de la madurez, mencionando hardware & software, datos de correlación. Los métodos desarrollados por investigadores difieren en sus fundamentos, pese a ello, mantienen valores altos de rendimiento en clasificación por madurez. Los resultados indican que, mediante la combinación de inteligencia artificial, periféricos y datos de post cosecha se puede predecir el estado de madurez mediante análisis de imagen eficientemente.

Palabras clave: Investigación bibliográfica, análisis de imagen, control de procesos, métodos no invasivos, aguacate, tecnología agroalimentaria, atributos visuales.

ABSTRACT

The state of maturity of fresh fruits is a fundamental parameter in commercialization or industrial processing. Traditionally, the determination of maturity has been carried out in laboratories, analyzing each fruit according to its nature with a specific methodology and parameters. For the avocado fruit, the firmness or dry matter content is quantified to estimate its maturity, these tests have been adopted for their high reliability and reproducibility. The state of maturity in the fruits is also diagnosed by panels of tasters or expert farmers, leaving room for subjectivity. Agrifood chains have incorporated technology as a support for agriculture 4.0, sustainability and organic production, main pillars of quality and food safety. Non-invasive methods of analysis are technological tools in the food chain that make it possible to reduce errors due to subjectivity and accurately detect parameters not perceptible to the human eye. Image analysis technology allows optical parameters to be quantified and correlated with biological phenomena to automate agricultural processes. This document examines the application of image analysis to control the state of maturity in avocado fruits. Different methodologies used for the prediction of maturity are addressed, mentioning hardware & software, correlation data. The methods developed by researchers differ in their fundamentals, despite this, they maintain high performance values in classification by maturity. The results indicate that, by combining artificial intelligence, peripherals and post-harvest data, the state of maturity can be efficiently predicted by image analysis.

Keywords: Literature review, image analysis, process control, non-invasive methods, avocado, food technology, visual attributes.

CAPÍTULO I

MARCO TEÓRICO

1.1. Antecedentes investigativos

1.1.1. Justificación

Un país agroindustrial que se apoye con programas estratégicos para resolver problemas mediante la implementación de tecnología permitirá el incremento de la producción y la optimización de los recursos enfocando al sector agrícola al desarrollo sostenible (Brenes et al., 2020). El control de los procesos productivos, hoy en día se puede realizar de manera remota aplicando tecnologías emergentes para analizar atributos en productos de producción primaria y procesados (Fernández Donoso, 2020).

En el entorno agrícola, los procesos asistidos por tecnología permiten un óptimo desarrollo económico y productivo de una región, el control de procesos mediante periféricos tecnológicos y uso de algoritmos posibilita a la cadena de producción adquirir resultados de manera rápida, suprimiendo la subjetividad y variabilidad del factor humano (Bhargava & Bansal, 2018). El aumento de lotes de producción en los cultivos agrícolas demanda un mayor número ensayos de control, la teledetección es una herramienta que facilita mapear de manera eficaz frutos y plantas para cuantificar las variables de interés comercial o industrial (Tu et al., 2020). La llamada *agricultura inteligente* se basa en la adopción de tecnología avanzada para asistir a ciertas etapas en la producción agraria que a su vez generan una serie de ventajas que permite la optimización de recursos y elevan la competitividad de la cadena productiva (Ramírez-Gil et al., 2018).

Las etapas posteriores a la cosecha demandan controles eficientes de procesos para combatir la corta vida útil que ofrecen los frutos frescos, con la finalidad de mantener la calidad y reducir las pérdidas (Anaya-Esparza et al., 2020). Los métodos no convencionales no invasivos facilitan el aumento de la eficiencia energética y la confiabilidad, al mismo tiempo se disminuye considerablemente el uso de reactivos de laboratorio, posibilitando la obtención de productos con certificación orgánica (Moscetti et al., 2021).

Considerando que la industria agroalimentaria se encamina a la generación 4.0 de la industria y que parte del paradigma de esta nueva generación es la implementación de

técnicas no convencionales (Luque et al., 2017), resulta necesario abordar el empleo de análisis de imagen como método de control de madurez en frutos. Se tiende a considerar que la adopción de tecnología para analizar alimentos tiene un potencial todavía no explotado en nuestro país. Este estudio busca demostrar que el análisis de imagen en maduración de frutos es una herramienta que facilita el análisis de madurez en aguacate con un alto nivel de confiabilidad, que no demanda alto costos en implementación, que es una técnica sencilla y que además se adapta a los aspectos de la sostenibilidad.

1.1.2. Antecedentes

Los frutos frescos o mínimamente procesados son alimentos altamente perecederos debido a su estructura celular y al metabolismo posterior a la cosecha. Estos dos factores de deterioro han causado en la cadena productiva pérdidas de hasta del 40% durante las etapas previas a la venta, alegando un estado de madurez no apropiado (Martínez-González et al., 2017).

1.1.2.1. Estado de madurez en aguacate

La calidad de atributos propios de los alimentos y la percepción de los mismos por los consumidores, han hecho que las características de los alimentos sean de elementales importancia para procesos de comercialización (Bhargava & Bansal, 2018).

En la gran mayoría de las frutas, el color de la corteza es el principal de parámetro evaluado para determinar el estado de madurez, asociando la coloración verde a estados inmaduros para la gran mayoría, y para estados maduros se le asigna el color amarillo, rojo o naranja de manera general. El aguacate presenta la particularidad de un cambio en su coloración mínimo o poco perceptible durante el ripening pese a la degradación de la clorofila (Gurupatham et al., 2018). La producción de etileno y la tasa de respiración alta generan la pérdida de peso e incremento de la materia seca en el aguacate, acompañado de ablandamiento del mesocarpio (Putri et al., 2019). El fruto de aguacate presenta la textura, el sabor y los compuestos volátiles de la pulpa con el mayor agrado sensorial cuando ha obtenido el contenido ideal de aceite (Herrera-González et al., 2017).

Contenido nutricional

El contenido nutricional del aguacate es de interés para el consumidor por la capacidad antioxidante que presenta debido a la presencia de ácidos poliinsaturados, que se ven reducidos en las etapas de sobre maduración (Lopez-Vega et al., 2021). La pulpa de aguacate aporta proteína (1-3%), carbohidratos (1-5%), fibra dietética (soluble e insoluble), vitaminas (C, E, K) y minerales (1-1.5%), sin embargo el fruto es reconocido por ser fuente de lípidos, en su mayoría ácidos grasos poliinsaturados (Salazar-López et al., 2020). El fruto del aguacate presenta un alto contenido de ácidos fenólicos, taninos y flavonoides entre sus compuestos más relevantes (Tremocoldi et al., 2018) ver Tabla 1. En la pulpa del aguacate *Hass, el más común*, se encuentra β -sitosterol, que es un fitoesterol en una cantidad que ronda los 35 mg /100g ps dependiendo de su estado de madurez, en la semilla se encuentra otros tipos de fitoesterol en menores proporciones (Barrera López & Arrubla Vélez, 2017).

Tabla 1

Compuestos bioactivos presentes en el fruto de aguacate.

Compuesto	Método	Concentración	Referencia
Alcaloides (semilla)	Remojo 24H	hiosciamina 0.6, atropina 0.46, escopolamina 0.24, norhiosciamina 0.04, solanidina 0.041, solanina 0.04, solasolina 0.08 mg/100g ms	(Oboh et al., 2016)
Fitoesteroles (semilla)	Remojo cloroformo	campesterol nd, estigmasterol 1.11, β -sitosterol 2 %.	(Alkhalaf et al., 2019)
Tocoferoles (pulpa)	Vortex: hexano	A-tocoferol 51-57, β -tocoferol 26-32 μ g/g ms	(Campos et al., 2020)
Fitoesteroles (pulpa)	Soxlet, aceite saponificado	campesterol 15-20, stigmasterol 6.01-6.17, β -sitosterol 142-166 mg/100 g ms	(Campos et al., 2020)

Parámetros de madurez a nivel comercial e industrial

A nivel comercial e industrial, la madurez de los aguacates es un factor muy importante debido a que existen trastornos en la pulpa cuando los frutos se encuentran muy maduros. Por el contrario, cuando los frutos se encuentran por debajo del índice de madurez la aceptabilidad por parte del consumidor disminuye (Rodríguez et al., 2018).

Existen diversos métodos para estimar el índice de madurez en este fruto. Se utiliza el contenido de humedad o el contenido de aceite en el mesocarpio (Magwaza & Tesfay, 2015); también se ha realizado analizando el contenido de materia seca (Escobar et al., 2019).

1.1.2.2. Ensayos tradicionales para determinar madurez en aguacate.

Los frutos, de acuerdo a su proceso de maduración, se clasifican en climatérico y no climatéricos. En el grupo de los frutos climatéricos, las tasas de respiración y de producción de etileno se incrementan luego de la cosecha; mientras que los frutos no climatéricos se mantiene o disminuye dichas tasas (Y. Chen et al., 2018). Los frutos climatéricos como el tomate, el aguacate o el plátano, por su proceso de maduración constante, requieren un mayor control del estado de madurez en las operaciones de distribución y almacenamiento (Pérez-Llorca et al., 2019).

Tradicionalmente, el estado o nivel de madurez de una fruta se determina a partir del análisis de diferentes parámetros físico-químicos, empleando equipos y utensilios de laboratorio (Chandy, 2019).

Ensayos físicos

Comúnmente se analizan parámetros como el diámetro polar y el color en frutos que cambian su color en las etapas de madurez. Se mide el diámetro polar utilizando reglas o regletas, en centímetros, como unidades frecuentes; se evalúa el color utilizando colorímetros, donde se registra los valores de luminosidad, cromaticidad y matiz. Adicionalmente y como pruebas de soporte se calcula la pérdida de peso en porcentaje; se determina la firmeza mediante el uso de un texturómetro donde se registra la fuerza con la que se penetra en la corteza del fruto, las unidades que se emplea con Newtons.

En frutos que contienen ácidos orgánicos, se mide la acidez titulable (AT) mediante una valoración ácido-base, para el caso del aguacate, el ácido predominante es el ácido oleico. Se cuantifica los sólidos solubles totales (SST) mediante un refractómetro óptico o digital,

las unidades son grados Brix; el índice de madurez es el resultado de la relación SST/AT, utilizados ampliamente en la industria para frutos en los procesos productivos (Pérez-Díaz et al., 2020).

Ensayos químicos

En frutas tropicales básicamente se analiza el contenido de azúcares en relación con la acidez titulable (Astudillo-Ordoñez & Rodríguez, 2018) mientras que en frutos con materia grasa considerable, como lo es el aguacate, se cuantifica dicho contenido. La determinación del contenido de aceite como indicador de madurez en el aguacate se realiza aplicando la guía de la AOAC (1984) y los valores varían de acuerdo al clima en el que se han cultivado y a la variedad, tal es así que para la variedad *Hass* tenemos un contenido que oscila entre 20,8% de la materia seca y para la variedad y en la raza mexicana puede presentar contenidos desde 12 a 27% de la materia seca (Medina-Torres et al., 2017).

Durante el ripening las propiedades fisiológicas de interés comercial como la tasa de respiración o la tasa de producción de etileno también se sufren cambios (Villa-Rodríguez et al., 2011). No se puede descartar que en la producción local aún prevalece el veredicto de un agricultor experto, que analiza las características organolépticas mediante un análisis sensorial donde la textura es el parámetro principal (Cañete et al., 2018).

Ensayos asistidos por tecnología

El uso de tecnología para analizar índices de madures en frutos frescos perecederos (climatéricos) toma mayor fuerza en las industrias agroalimentarias en busca optimizar los procesos productivos (Padrón-Pereira et al., 2016).

La calidad de los frutos es fundamental en la selección por parte de los consumidores y está relacionada directamente con el estado de madurez. En años anteriores la determinación de calidad de un frutos se ha compuesto de pruebas subjetivas, destructivas y laboriosas (Saha & Manickavasagan, 2021). El desarrollo y aplicación de métodos no convencionales de análisis dan lugar a un instrumento de inspección en línea, que permiten evaluar de manera rápida y no invasiva parámetros de calidad y de seguridad en diferentes áreas de la industria y de la ciencia (Bonah et al., 2020). En la industria alimenticia, estas sofisticadas técnicas analizan en tiempo real atributos internos físicos, químicos, fisiológicos y patológicos en los alimentos, cualificando y cuantificando los

atributos físicos externos de las muestras (Galletti et al., 2020). Los métodos no convencionales emulan un catador o un panel de catadores y buscan medir principalmente las características organolépticas de un alimento. Además, con estas herramientas novedosas se puede analizar parámetros sensoriales muy complejos, como por ejemplo, los sabores umami y astringente (Hwang et al., 2020).

1.1.2.3. Tecnología en la cadena agroalimentaria

Las organizaciones gubernamentales y empresas en la actualidad se preparan, organizan y ejecutan planes estratégicos considerando el impacto que tendrá la industria 4.0 en la humanidad en un futuro cercano (Mhlanga, 2021). La digitalización y la adaptación de las empresas a esta cuarta revolución, son realidades que viven principalmente las cadenas de suministro que brindan productos y servicios para las necesidades básicas del ser humano (Khudyakova et al., 2019). Los pilares en los que se sostiene el desarrollo de estas industrias 4.0 son principalmente el manejo e implementación de herramientas tecnológicas que interactúan con inteligencia artificial con el único propósito de automatizar de las tareas ejecutadas por personas, utilizando controles basados en sensores inteligentes y actuadores guiados por señales desde un procesador (Best & Vargas, 2020).

Pese a que varias herramientas de la agricultura 4.0, como los métodos no convencionales de análisis, ya han sido aplicadas en cadenas agro-productivas, aún existen espacios en los que puede innovar con tecnología y obtener beneficios de su aplicación, principalmente en sectores rurales (Lima et al., 2020).

Incorporación de tecnología al sector agroindustrial

La *agricultura inteligente* se basa en la adopción de tecnología avanzada en varios procesos agrarios que a su vez generan una serie de ventajas que permite la optimización de recursos y elevan la competitividad de la cadena productiva (Ramírez-Gil et al., 2018). Las etapas posteriores a la cosecha demandan procesos que necesitan ser controladas de manera eficiente y rápida debido a la corta vida útil de los frutos frescos. En una planta de procesamiento de alimentos, durante las etapas de transformación, los análisis de calidad tradicionales requieren de mano de obra frente a métodos de análisis no convencionales. Los métodos no convencionales no invasivos permiten aumentar la eficiencia energética y la confiabilidad descartando el uso de reactivos de laboratorio, posibilitando la obtención de productos orgánicos (Moscetti et al., 2021). El aprendizaje

automático y aprendizaje profundo son campos de la inteligencia artificial que pueden trabajar conjuntamente con métodos de análisis no invasivos, estos mecanismos, por lo general son electrónicos y se prevé que en el futuro se emplearán para analizar un número mayor de parámetros (Zhu et al., 2021).

1.1.2.4. Técnicas no convencionales aplicados en alimentos

El análisis no destructivo en frutos engloba evaluaciones que se realizan en la superficie del producto, excluyendo pruebas intrusivas que dañen el aspecto y la calidad de los mismos (El-Mesery et al., 2019). Estos métodos no convencionales de análisis basan su funcionamiento en el uso de sensores o biosensores que combinados con método de procesamiento de datos validados por investigaciones previas para obtener cuantificación y cualificación de propiedades en los alimentos (Zhou et al., 2020). El uso de la tecnología permite aplicar nuevos métodos para realizar test de diferente índole en alimentos que por su bajo costo y peso son de gran utilidad para estimar de manera rápida, sencilla y económica parámetros de calidad en productos agrícolas (Abasi et al., 2018).

Los métodos no destructivos emulan los sentidos del ser humano mediante sensores especializados que permiten reducir el uso de reactivos químicos y evitando técnicas e instrumentación voluminosa realizada únicamente por personal capacitado (Ordoñez-Araque et al., 2020; Pena-Pereira et al., 2020). El desarrollo de sentidos electrónicos, ha constituido la respuesta al crecimiento de la producción de las industrias agroalimentarias. Aspectos como la velocidad, reproducibilidad, consistencia y robustez hacen que estos métodos de detección artificial satisfagan a las necesidades de las cadenas agro productivas (Ordoñez-Araque et al., 2020).

Técnicas como el ultrasonido de baja potencia permite detectar de manera no destructiva ciertas propiedades internas de un producto alimenticio, haciendo posible la ejecución tareas de clasificación y discriminación con valores de precisión de hasta 86% (Adegbenjo et al., 2020). La imagen por ultrasonido, en carnes y sus derivados, posibilita la determinación de características mecánicas y composición de la carne aún en etapas previas al faenamiento (Fabbri et al., 2021). La contenido de humedad es de vital importancia en las diferentes etapas de producción de un alimentos, existen varios métodos no destructivos para determinar este parámetro, incluyendo un sensores de capacitancia y sensores de microondas (Uyeh et al., 2021).

Enfoque sensorial

Las técnicas no convencionales y no destructivas como lenguas, ojos y narices electrónicas pueden sustituir a los órganos de los sentidos de los supervisores de materia prima, eliminando la subjetividad del análisis del criterio. Los datos son recogidos por sensores y procesados por un software especializado que fundamenta su funcionamiento en una serie de algoritmos. Tomando en cuenta que el control de calidad para los productos frescos se basa en caracterizar la apariencia y las propiedades sensoriales básicas (Özdoğan et al., 2021), los métodos de análisis no invasivos requieren de una calibración previa. El desarrollo constante hace posible que estos métodos innovadores no se limiten solo a este tipo de análisis organolépticos, llegando incluso a la determinación de microcomponentes o propiedades bioactivas en los alimentos (Baldeón et al., 2015).

Se puede señalar que las técnicas de evaluación no destructivas permiten obtener datos de una muestra de un producto generalmente sin pretratamientos y sin afectar su aspecto y calidad (El-Mesery et al., 2019). Una gran ventaja que es común en las técnicas de análisis no invasivo es la obtención de datos en tiempo real, posibilita también la realización de ensayos hasta veinte veces más rápida que por métodos tradicionales. La nariz electrónica (e-nose) recolecta datos de sustancias químicas volátiles que determinan los olores. En producciones por batch se puede cuantificar mediante ensayos tradicionales las tasas de CO_2 y etileno en cada etapa.

Mediante e-nose y algoritmos como K-Neighbours Neighbours se puede categorizar el nivel de madurez fisiológico (Hafeez et al., 2019), el objetivo es apoyar a la logística de distribución y evitar pérdidas. La combinación de sentidos electrónicos es una rama poco estudiada de las técnicas no destructivas. Los datos que se pueden obtener de un sistema combinado de análisis sensorial artificial sería la predicción de estados de madurez y senescencia de una cantidad innumerable de productos alimenticios de diferente categoría (Bratu et al., 2021).

1.1.2.5. Análisis de imagen en alimentos

El empleo de tecnologías de monitoreo apoya a las tareas agrícolas de precisión aumentando la eficiencia y reduciendo los impactos ambientales. La diversidad de modalidades de detección ha permitido simular la inspección de un operario y detectar procesos biológicos un poco más esquivos a la visión humana (Mavridou et al., 2019). En

una línea de producción, los métodos convencionales presentan los inconvenientes de ser destructivos y se aplican fuera de línea. Las técnicas de visión por computador se presentan como una alternativa para realizar de manera eficiente análisis de atributos en frutos y vegetales, realizando un testeo de un mayor número de muestras y examinando macroelementos y elementos considerados traza (Hussain et al., 2018).

1.1.2.5.1. Sistema de análisis de imagen

En un sistema de visión artificial, una imagen es analizada como una matriz de valores, capturada y digitalizada por una cámara que la transmite hacia un software o procesador. La imagen digital, como si de una matriz $M \times N$ se tratara, donde cada valor de la matriz es representado por un pixel. El número de pixeles es variado y depende del sistema de digitalización de la imagen. Cada pixel presenta parámetros de color como: brillo, tono, colorido, luminosidad, croma, saturación que se cuantifican mediante operaciones. Los valores de los parámetros mencionados son almacenados y procesados por algoritmos (Alegre et al., 2016). El proceso completo se puede apreciar en la Tabla 2.

Tabla 2

Procedimiento de un sistema de análisis de imagen en general.

Procesos	Nivel de visión	Entrada	Salida	Área
1. Captura	Bajo	Imagen	Imagen	Procesamiento de imágenes
2. Preprocesamiento				
3. Segmentación	Medio	Imagen	Grupo de pixeles	Análisis de imágenes
4. Descripción		Objetos o regiones	Información cuantitativa de pixeles	
5. Reconocimiento (clasificación)		Información cuantitativa	Objetos clasificados	
6. Interpretación	Alto	Objetos clasificados en categorías	Comprensión de la escena	Visión por computador

Nota. (Sarfraz, 2020)

1.1.2.5.2. Análisis de imagen en frutos

Posterior a la captura, en la etapa de procesamiento se analiza la información en la imagen tales como nitidez, brillo, contorno, bordes, etc. Se extraen información basándose en conceptos de estadística descriptiva de la imagen, distribución de color y métricas globales de los píxeles (Fernandes et al., 2020). El método de análisis de imagen en frutos permite cuantificar de manera rápida y objetiva parámetros como el color, forma, tamaño, pero también atributos imperceptibles al ojo humano. Mediante procesamiento de las imágenes capturadas se reduce la subjetividad en la apreciación de parámetros principales de los alimentos que contribuyen de manera significativa a la oferta de productos de calidad en el mercado, aumentando así el valor del producto (Haque et al., 2021). Mediante el análisis de color, canales y espectros se pueden determinar varios aspectos en la calidad del fruto, como por ejemplo, daños físicos, contenido de elementos bioactivos, estado de madurez, etc. (Cömert et al., 2020). El color es el factor principal en las evaluaciones no invasivas de una fruta (Lazaro et al., 2019), y el mismo se encuentra distribuido de manera heterogénea, se sugiere analizar la imagen como un todo tanto para la calibración como para la determinación (Sanaeifar et al., 2016).

Imágenes hiperespectrales (HSI)

El análisis de imágenes para obtener datos de manera cuantitativa en frutos se mantiene en constante evolución, tal es el caso del empleo de fundamentos del espectro electromagnético. Las imágenes hiperespectrales (HSI) captan información a lo largo del espectro electromagnético, y procesar datos no perceptibles al ojo humano (Bernabé, 2017), datos que permiten analizar atributos internos de las frutas. Las técnicas se combinan para con el fin de ampliar su campo de aplicación. La toma de imágenes hiperespectrales conjuntamente con la fotografía común componen una técnica de evaluación compleja, donde se obtiene información espectral y de los píxeles de una imagen bidimensional (Hussain et al., 2018).

La técnica funciona realizando operaciones de reflectancia, transmitancia, fluorescencia o dispersión del color. Mediante el empleo de HSI se pueden obtener coeficientes de correlación confiables para determinar parámetros como firmeza, índice de madurez, contenido fenólico, etc. Los modelos predictivos y los rangos espectrales se utilizan de acuerdo a los parámetros que se desean cuantificar donde la calibración previa es

fundamental. Los rangos que mejores resultados han presentado para la determinación de madurez se encuentran en el infrarrojo cercano (Teerachaichayut & Ho, 2017).

Termografía

La termografía es una técnica emergente la determinación de calidad de los frutos. Básicamente se trata de imprimir los rayos infrarrojos que se desprenden de una superficie. El método se basa en que los diferentes fenómenos que ocurren en un cuerpo vivo generan calor que pueden ser cuantificados y cualificados en termogramas (Pathmanaban et al., 2019). El empleo de análisis de imágenes térmicas está creciendo en la industria de los alimento debido a la amplitud de aplicaciones (Mangus et al., 2016).

1.1.2.5.3. Hardware y software empleado

La calidad de la obtención de una imagen en 2D depende de los sensores o cámaras que se utilicen, mientras mayor sea la calidad y la precisión en la obtención de datos, mayor será la confiabilidad de los resultados (Méndez-Perez et al., 2017). Los sistemas de iluminación son relevantes al momento de la captura de la imagen para reducir la variabilidad por la luz del ambiente (Sun, 2016). Los programas informáticos que procesan y almacenan la información de las imágenes digitales deben ser confiables y a su vez versátiles en el manejo e implementación, considerando que los usuarios de esta tecnología en su gran mayoría son agricultores de zonas rurales (Roslin et al., 2021). El algoritmo de un software que procesa imágenes de diferente obtenidas con diferentes métodos y tecnología.

El aprendizaje automático (ML) es una herramienta que conjuga diversos patrones para encontrar características en frutos como el cambio de color, estado de maduración o firmeza durante el periodo de vida útil. Los patrones se encuentran en programas informáticos ejecutados por ordenadores fijos o móviles que buscan remplazar el trabajo manual (Cho et al., 2020).

El aprendizaje profundo (DL) a diferencia del ML, no se limita a comparar patrones prediseñados, sino que a través de diversas capas de algoritmos tiene la facultad de crear patrones con múltiples niveles de abstracción. El DL es un conjunto conformado por modelos probabilísticos, redes neuronales y variedad de algoritmos de aprendizaje que buscan la emulación del cerebro humano (Voulodimos et al., 2018). Cabe destacar que los mecanismos de calibración para los patrones mencionados son obtenidos mediante un

análisis discriminante de mínimos cuadrados en su gran mayoría, obteniendo coeficientes de regresión confiables superiores a 0,97 (Amodio et al., 2017).

1.1.2.5.4. Ensayos realizados

Se ha utilizado análisis de imagen, como método no convencional, para determinar parámetros de calidad en diferentes frutos frescos obteniendo resultados con un alto nivel de confiabilidad y logrando optimizar recursos. Escobar-Peláez & Castaño-García (2018), realizaron un sistema de determinación de madurez en aguacate *Hass* mediante análisis de imagen, los parámetros evaluados fueron tamaño, forma y color. El método empleado fue “ponderado aritmético” de cada pixel que forma la imagen digital del fruto; todos los patrones de clasificación fueron obtenidos mediante un entrenamiento previo. Se utilizó un modelo de red neuronal como herramienta de aprendizaje automatizado para evaluaciones futuras y conformar una base de datos.

Santos Pereira et al. (2018), utilizaron las regiones RGB (red, green, blue), CieLab y HSV (hue, saturation and value) para determinar el color en papayas, el método empleado fue bosques aleatorios con conjuntos de datos, obteniendo el mayor rendimiento de clasificación en el sistema de canales RGB, debido al notable cambio de color en la corteza de la fruta. En la metodología de análisis de imágenes, el conjunto de tareas se clasifica por niveles, el nivel de procesamiento va enfocado según el parámetros óptico del alimento que se desea analizar o clasificar (Zhu et al., 2021).

El nivel bajo de procesamiento, generalmente se utiliza para clasificación por tamaño o por color utilizando patrones (estado de madurez). El nivel de procesamiento intermedio permite realizar un análisis segmentado de la muestra, es decir, que el objeto de análisis debe ser aislado de las demás muestras, generalmente se utiliza para caracterizar formas y reconocer la variedad (Momin et al., 2017), en este nivel de procesamiento también se incluyen el análisis de imágenes hiperespectrales, que posibilitan la predicción de índices de madurez alternativos como por ejemplo la textura (Mendoza et al., 2011).

El uso de imágenes hiperespectrales combinado con visión por computador permite alcanzar resultados de hasta 95% de fiabilidad al momento de analizar alimentos con altos contenidos de aceite (El-Bendary et al., 2015). A diferencia del sistema RGB donde contamos con tres canales, en las imágenes hiperespectrales contamos con cientos de canales que nos permiten obtener información más precisa de los pixeles, donde también podemos detectar magulladuras (Zhou et al., 2020). En los niveles procesamiento alto, el

análisis de imágenes interactúa con inteligencia artificial para el aprendizaje automático y aprendizaje profundo (Misimi et al., 2016; Zhu et al., 2021).

1.1.2.5.5. Limitaciones del método

Un cuello de botella en el desarrollo y creación de prototipos de análisis de imagen es la falta de datos de imágenes públicas. Desde el año 2015 se han puesto a disposición al público varios conjuntos de imágenes con el objetivo de aliviar esta dificultad en las diferentes tareas de la cadena agroalimentaria (Lu & Young, 2020). Los datos son reducidos y poco específicos, lo que obliga a realizar una etapa de calibración para desarrollar un análisis, incluyendo numerosas muestras patrón analizadas con procesos convencionales.

Los procesos de visión por computador, principalmente los que se fundamentan en la colorimetría, tal es el caso de sistema RGB-D o CieLab, demandan condiciones homogéneas para mantener su eficiencia. Las cámaras convencionales son susceptibles a los factores del ambiente, por lo que el proceso de calibrado y el análisis de determinación deben mantener en lo posible condiciones similares. Los factores ambientales generan el mayor índice de perturbación tanto en la calibración como en la aplicación (Fu et al., 2020).

Para efectos de clasificación los algoritmos de discriminación como SVM, que es uno de los más comunes, no reconocen de manera eficiente los daños mecánicos o biológicos (Ting & Tang, 2019).

1.1.2.5.6. Tendencias

La adopción del método de análisis de imagen en frutos se encuentra en crecimiento por las ventajas que ofrece. La portabilidad del método es una temática muy importante en la agricultura rural y agricultura 4.0. Los teléfonos inteligentes, por su accesibilidad se ha convertido en una herramienta utilizada en diferentes ámbitos por parte del ser humano (Kalinowska et al., 2021). La disponibilidad de un procesador de datos, una batería, una cámara digital de alta resolución, pantalla e interfaz de usuario y conexión a redes inalámbricas, hacen de un teléfono inteligente un equipo capaz de ejecutar un análisis de imágenes con alta confiabilidad (Rateni et al., 2017).

La alineación de tecnología en la agricultura moderna permite que los datos procesados en los procesos de producción, transporte y almacenamiento sean almacenados en una red neuronal artificial (ANN). El propósito de utilizar una ANN en una cadena de producción

agrícola es combinar valores históricos con inteligencia artificial para tomar decisiones acertadas en un futuro (Kujawa & Niedbała, 2021).

El monitoreo en tiempo real establecidas líneas de producción, cultivos o reactores es un espacio mínimamente indagado. La refrigeración es un método de conservación de alimentos muy utilizado, sin embargo, la extracción de calor es calculada por ecuaciones de termodinámica. La temperatura es un factor crítico que el análisis de imágenes térmicas lo proyecta en tiempo real desde el interior de la cámara fría (Mohd Ali et al., 2020). El análisis de imagen como herramienta de control en reactores puede cumplir la función de sensor de un lazo cerrado, otorgando datos para el control PID, máxima expresión en sistema de automatización (Sevenich, 2022).

1.2. Objetivos

1.2.1. Objetivo General:

Describir la aplicación de análisis de imagen destinado al control del proceso de maduración de aguacate en base a una revisión bibliográfica.

1.2.2. Objetivos Específicos:

Comprender los fundamentos del análisis de imagen y su aplicación en el control de maduración de frutos frescos.

Establecer parámetros físicos de madurez en el aguacate evaluados posteriormente en análisis de imagen.

Determinar las variables que participan en el proceso de análisis de imagen aplicado al control de maduración de aguacate.

Identificar herramientas enfocadas en el análisis de imagen y su potencial aplicación en control de madurez de frutos frescos.

CAPÍTULO II

METODOLOGÍA

2.1. Materiales

Los materiales utilizados para la construcción de esta revisión bibliográfica fueron elementalmente:

- Computador
- Internet
- Bibliotecas virtuales de la Universidad Técnica de Ambato (Wiley Online Library, Pro – Quest, Ebook Central, entre otras).
- Bibliotecas virtuales de acceso libre (PubMed, EMBASE, SciELO, Science Direct y Google Scholar).
- Gestor documental Mendeley.

2.2. Métodos

2.2.1. Definición del problema

El problema en el que se fundamentó la presente investigación es la falta de información sobre el análisis de madurez en el fruto de aguacate mediante tecnología no invasiva. Las herramientas de visión por computador ya es un tema maduro para la agricultura de precisión y permite analizar características internas y externas de un fruto del fruto, las características analizadas se correlacionan con el estado de madurez. Esta información contribuirá a que las cadenas agroalimentarias del país se interesen por el uso de tecnologías de bajo costo, sostenibles y con un gran potencial.

2.2.2. Búsqueda de la información

Las fuentes principales de donde se obtuvieron los fueron las plataformas digitales científicas de Springer, EMBASE, sitios web de acceso gratuito biblioteca digital de la Universidad Técnica de Ambato apoyando la búsqueda en Google Académico, se muestran de la búsqueda en la Tabla 1. PubMed, es una plataforma de publicaciones científicas enfocado a temáticas de medicina y enfermería, pese al enfoque de la plataforma, se encontró información actualizada sobre visión por computador y procesamiento digital de imágenes. Se buscaron trabajos en donde se presenten resultados experimentales y utilizando diferentes métodos. Las palabras de búsqueda fueron: análisis

de imagen, visión por computador, aguacate, ripening, machine learning, deep learning, cadenas agroalimentarias, agricultura 4.0, métodos de análisis no destructivo, sentidos electrónicos, sistemas de visión por computador, etc. Se obtuvo un compendio total de 178 documentos, de los cuales, mediante un filtro de: enfoque, claridad de los resultados, antigüedad, relación con la definición del problema. Se realizó una búsqueda sistemática sobre los subtítulos tratados en la revisión, subtítulos como: Incorporación de tecnologías en las cadenas agroalimentarias, Análisis de imagen en fruto y cultivos, tendencias de visión por computador, procesamiento de imágenes, métodos de digitalización, etc. Los artículos fueron recopilados en su gran mayoría con su archivo pdf para posterior manejo y organización documental. En la recopilación de archivos, se enfatizó en la fecha de publicación, resultados sobre clasificación de los estados de madurez, bibliografía actualizada, publicada durante los últimos 5 años con excepciones cuando existe información relevante.

Tabla 3

Fuentes de información.

Fuentes de información	Sitio
1. Primaria	DirectScience, EMBASE, Springer, revistas científicas en línea & E-Libro. Biblioteca Virtual UTA: Wiley Online Library, ProQuest, Ebook Central, etc.
2. Secundaria	Artículos disponibles en línea, Libros electrónicos y conferencias, PubMed. Plataformas de acceso libre: Google Scholar, Scielo.

Nota. Adaptado de (Vilanova, 2012).

2.2.3. Organización de la información

Se procedió a almacenar de manera organizada por información potencial los artículos recuperados. Se empleó la herramienta de gestión documental Mendeley para organizar los archivos y disponer de la bibliografía de manera instantánea y automática en el formato solicitado. En el gestor Mendeley se crearon carpetas según la información relevante para la reacción como es el caso de precisión, parámetros analizados, datos cualitativos y cuantitativos, método empleado, resultados, antecedentes, generalidades y temas similares. En cada carpeta se colocaron los documentos acordes al título incluyendo

subcarpetas. En la sección de notas que se dispone en Mendeley, se anotaron frases de utilidad para el desarrollo del proyecto, mencionando la sección del documento en la que encuentra la información de interés. Se creó una carpeta adicional donde se colocaron los documentos que contenían experimentación cuantitativa, destinado para la extracción y presentación de resultados. Los documentos recopilados a la base de datos de este proyecto de investigación fueron añadidos de manera inmediata a las carpetas respectivas en Mendeley.

2.2.4. Análisis de la información

La primera etapa del análisis de la información fue indagar en el abstract y las conclusiones, para determinar los aspectos más relevantes tratados en cada uno de los artículos. La lectura crítica de los resúmenes en los documentos permitió categorizar la información potencial para la investigación. Los resultados fue un aspecto fundamental en el momento de diseñar el desarrollo de los antecedentes investigativos. La lectura pormenoriza de la introducción y los subtítulos, diferenciando el tipo de documento, permitieron la construcción de la revisión bibliográfica principalmente y aportó en la discusión. Se revisaron los resultados disponibles para plantear la presentación de los mismos, buscando en artículos enfocados en aguacate exclusivamente o revisiones donde se incluían un grupo de investigaciones con frutos similares. La revisión de las tablas o figuras con las que los autores presentan los resultados, facilita la comprensión de la investigación y permite relacionar los artículos de acuerdo al enfoque. Una vez realizada la tarea de revisión pormenorizada, se procedió a filtrar los documentos según los resultados obtenidos, reduciendo así el número de artículos utilizados para redactar cada capítulo de la investigación.

CAPÍTULO III

RESULTADOS Y DISCUSIÓN

3.1. Análisis y discusión de los resultados

3.2. Análisis de imagen en frutos frescos

Los trabajos desarrollados para robustecer el monitoreo de los productos agrícolas y sus fenómenos internos dirigen a la cadena de valor a adoptar técnicas no destructivas, como el análisis de imágenes. Mediante técnicas de análisis de imagen se ha logrado concretar tareas como clasificación, monitoreo, detección de defectos, de estado de madurez (*ver Tabla 3*), etc. Implementando técnicas de visión por computador la textura, los macro componentes o de la forma de puede clasificar frutos de manera rápida y con una tasa de precisión elevada además del uso de varios criterios (Tripathi & Maktedar, 2020).

Tabla 4

Aplicación de análisis de imagen en frutos frescos

Proceso/ensayo	Fruto	AI Tecnología	Referencia
Control en el secado	Rodajas de manzana Cubos de banana	Sistema de visión por computador (SVC)	(Jieling Chen et al., 2020)
	Kiwi		
	Arvejas	SVC en tiempo real	
Detección de moretones	Manzana	Procesamiento de imagen térmica	
Estado de madurez	Mango	Análisis de imagen	(Mohd Ali et al., 2020)
Decaimiento	Uvas	Análisis de varianza	
Detección de enfermedad	trigo	Histograma RGB	

Nota. Los atributos evaluados en las frutas demandan diferentes metodologías y tecnologías de análisis de imagen.

3.3. Espacio de color RGB

El método de análisis de los canales RGB de una imagen es utilizado ampliamente en procesos de clasificación no destructiva de dificultad baja al igual que el nivel de procesamiento demandado (Zhang & Gao, 2020). En años atrás se analizaban únicamente

la imágenes bidimensionales obtenidas por las cámaras de profundidad D-RGB y se realizan de manera eficiente la segmentación de frutos cuyo fondo tiene colores diferentes, presentando mayor efectividad para frutos rojos (Nguyen et al., 2016). El algoritmo SVM fue empleado en esta técnica para dar evaluar frutos que presenten colores de interés diferentes al rojo, debido a que el algoritmo combina el plano de la imagen con el espacio tridimensional para extraer mayor información de la corteza de un fruto (Barnea et al., 2016). El método es aplicado con mayor frecuencia en el pericarpio de los frutos, por lo que entorno externo puede provocar perturbaciones en la medición del color de forma directa, sin embargo, en condiciones controladas muchos autores correlacionan el color con características fisicoquímicas.

3.3.1. Instrumentación

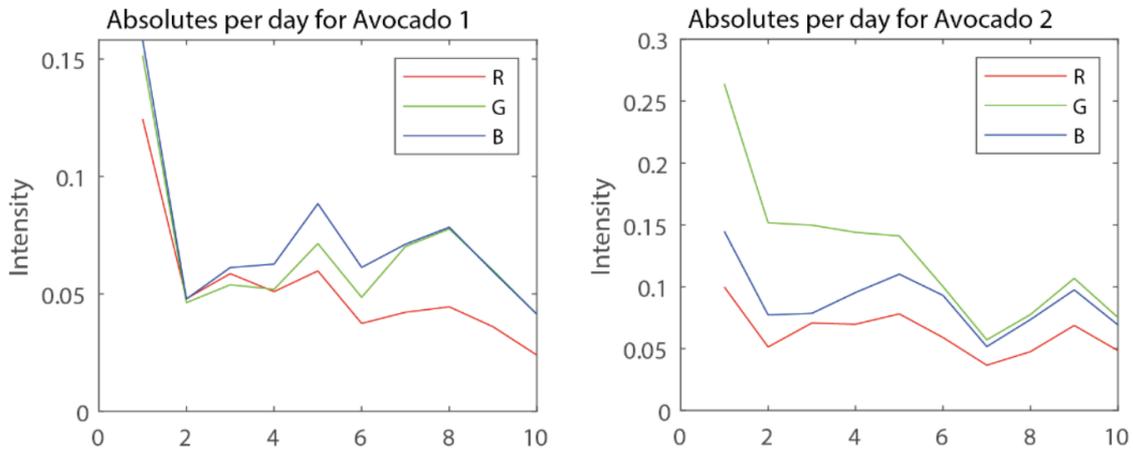
Las cámaras de color ubicuas son de bajo costo y se utilizan con frecuencia para filtrar los canales rojos, verdes y azules, los datos son utilizados en el procesamiento de manera directa. El dispositivo con carga acoplada (CCD) es un sensor que permite capturar imágenes de calidad en condiciones de poca luz mientras que otro sensor muy utilizado es CMOS, este último es un dispositivo que ideal para tomar imágenes a gran velocidad y con bajo consumo de energía (Walsh et al., 2020). Los dispositivos mencionados son utilizados con mayor frecuencia para evaluar atributos de frutos frescos.

3.3.2. Trabajos relacionados

(Pinto et al., 2019) diseñaron un montaje óptico para analizar aguacates mediante el espacio RGB, se buscaba la clasificación de aguacates de variedad *Mill* en términos de madurez. Posterior al procesamiento de las imágenes, los datos se presentan en intensidad de cada canal vs los días de maduración. En todos los canales la intensidad se reduce, sin embargo, el canal G sufre la mayor atenuación como se observa en la Figura 1.

Figura 1

La intensidad de los canales RGB frente a los días de maduración en muestras de



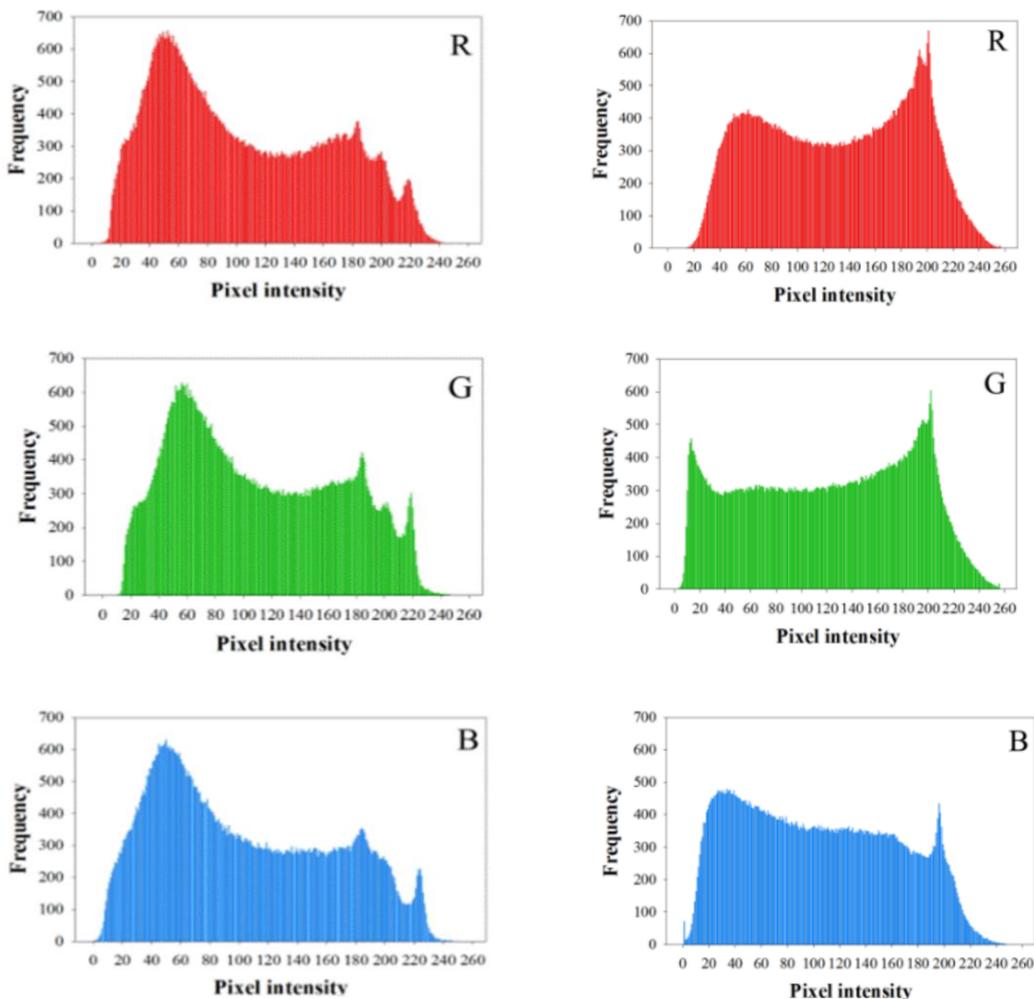
aguacate.

Nota. A lo largo de la etapa de maduración la intensidad de los canales disminuye, el canal Green presenta un descenso significativamente mayor.

Otros estudios realizados son experimentos basados en visión por computador para clasificar el estado de madurez en tomates y cítricos. Se han alcanzado tasas de reconocimiento fue del 97.44%, cabe mencionar que el cambio de color de los frutos analizados es significativo (Jiqing Chen et al., 2021). Los compuestos en el exocarpio cambian la coloración de la corteza en ciertos frutos, la generación de fitoesteroles reducen el brillo y la intensidad, mientras que la acumulación antocianinas, al ser compuestos de color púrpura, reducen la intensidad de los canales (Ramos-Aguilar et al., 2021). Para la clasificación de aguacates en frutos maduros e inmaduros se obtuvo histogramas RGB a partir de imágenes bidimensionales. Los resultados alcanzados demuestran mayor frecuencia en los tres canales en frutos inmaduros, que se interpreta como una pigmentación menos luminosa. La acumulación de antocianinas y su pigmentación provocada son detectadas en los canales rojos, por lo que este último canal presentó una diferencia significativa en disminución de frecuencia ($p < 0,05$), observar Figura 2. Para los canales verdes se identificó una diferencia significativa en disminución de frecuencia ($p < 0,05$) entre los frutos verdes y maduros, probablemente debido a la degradación de la clorofila en el tejido por fenómenos de la maduración; mientras que en los canales azules no se identificaron diferencias significativas ($p > 0,05$). (Espinosa-Velázquez et al., 2016).

Figura 2

Histogramas de los canales RGB para los frutos de aguacate inmaduros y maduros.



Nota. En la columna de la izquierda se representan los canales RGB de los frutos inmaduros y a la izquierda los canales de los frutos maduros de acuerdo a cómo se han distribuido los colores en las dos etapas.

3.4. Espacio de color CieLab

El espacio de color CieLab se deriva de los valores originales de una imagen RGB, reduciendo la importancia de la calidad de una cámara, debido a que los parámetros son combinados (Rodríguez-Pulido et al., 2021). De la conversión de la imagen RGB, los parámetros CieLab son representados en planos cartesianos o polares. En el eje Y se representa el valor de luminosidad, en el eje X se sitúan los valores de variación Rojo-Verde, en el eje Z se posicionan los valores de variación Amarillo-Azul. Además, en

coordenadas polares se emplea el valor de tono como argumento y saturación como módulo, en la Figura 3 se puede observar una adaptación de los parámetros en un sistema cartesiano. Los parámetros de este sistema pueden ser utilizados con el fin de implementar correlaciones de la imagen procedente de un objeto (López & Di Sarli, 2016).

Los procesadores de imágenes CieLab miden el cambio de color para establecer comparaciones, cuando se trata de cambios con facilidad de percepción, la fórmula utilizada corresponde a la Norma europea EN 12878 para cuantificar el cambio de color, mientras que cuando los cambios son mínimamente perceptibles, la técnica demanda el uso de la fórmula CIELBA2000, que realiza correcciones en el ángulo, en el tono y en el croma (López & Di Sarli, 2016).

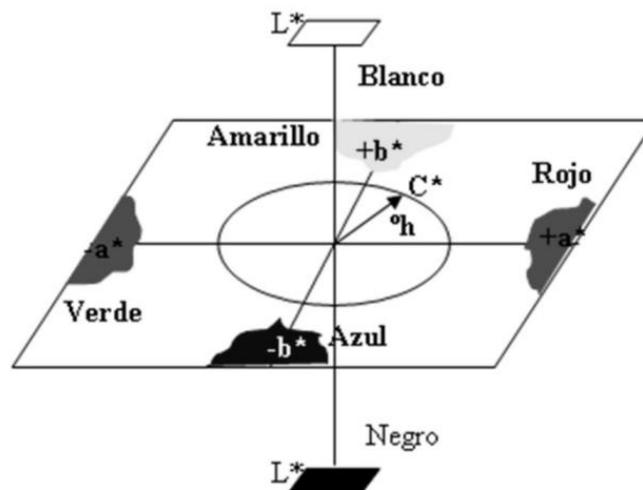
Fórmula 12878:
$$\Delta E^* = [(\Delta L^*)^2 + (\Delta a^*)^2 + (\Delta b^*)^2]^{\frac{1}{2}}$$

Fórmula CIELAB200:
$$\Delta E_{\omega} = \left[\left(\frac{\Delta L'}{K_L S_L} \right)^2 + \left(\frac{\Delta L'}{K_L S_L} \right)^2 + RT \left(\frac{\Delta C'}{K_C S_C} \right) \left(\frac{\Delta H'}{K_H S_H} \right) \right]^2$$

Los valores de S_L corresponden a diferencia de luminosidad, S_C diferencia de croma, S_H diferencia de tono. Los valores de K son constantes lamas paramétricas.

Figura 3

Modelo o espacio de color CIELAB representado en un sistema cartesiano en coordenadas polares y cartesianas.



3.4.1. Instrumentación

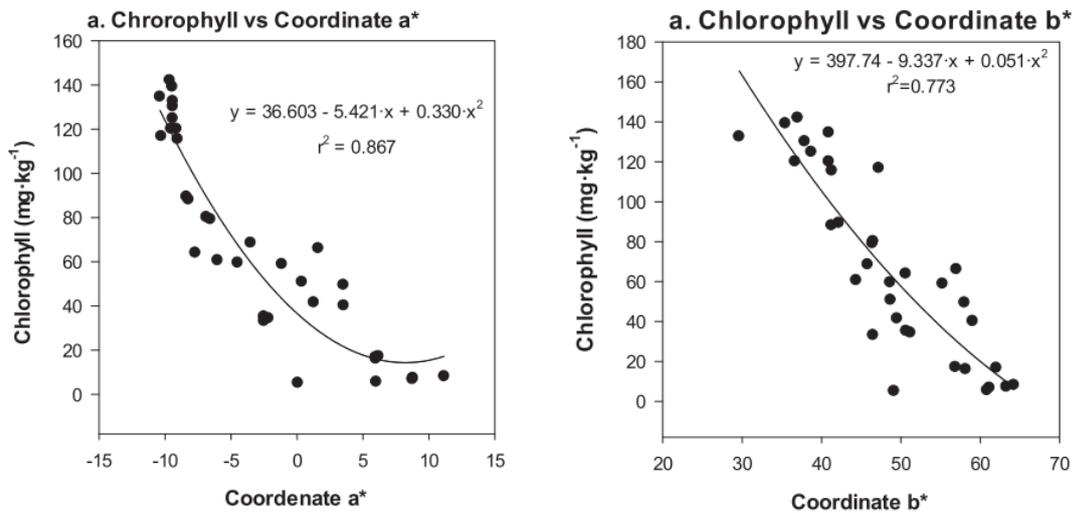
Para el evaluar imágenes mediante el método CieLab, generalmente las muestras se colocan en una cabina de o domo de iluminación controlada. Las cámaras utilizadas corresponden a las directrices CIE y las marcas más utilizadas son Nikon D80 (Rodríguez-Pulido et al., 2021), Canon PowerShot S90 (Ting & Tang, 2019). El software para procesar las imágenes y cuantificar los parámetros es Imagen o herramientas de Matlab (López & Di Sarli, 2016).

3.4.2. Trabajos relacionados

(Conesa et al., 2019) Realizaron una investigación para correlacionar la degradación de la clorofila, la generación de carotenoides, el cambio de color y el estado de madurez en cítricos. Si bien la degradación de la clorofila ocurre un la maduración de la mayor parte de frutos, los compuestos generados no son iguales, por lo que los frutos maduros presenta colores amarillos, rojos, púrpuras o en algunos casos el color se mantiene (Agócs et al., 2007). El sensor utilizado fue la cámara portátil Konica Mibolta e iluminación estándar D65, mientras que la cuantificación experimental de clorofila se realizó mediante espectrofotometría con agua-acetona 1:9 como solvente y con 645nm de longitud de onda. Las coordenadas a^* y b^* presentaron coeficientes de regresión r^2 0,816 y 0,773 respectivamente vs el contenido total de clorofila como se observa en la Figura 4. Si bien en el fruto de aguacate el cambio de color es mínimo debido a que los compuestos generados para el limón son en mayor porcentaje criptoxantina de color amarillo, mientras que para el aguacate predomina la generación de luteína de color verde oscuro, las tasas de reducción de clorofila son similares (Ashton et al., 2006) por lo que el experimento se puede extrapolar para aguacate *Hass*.

Figura 4

El contenido de clorofila en relación a las coordenadas a* y b*.



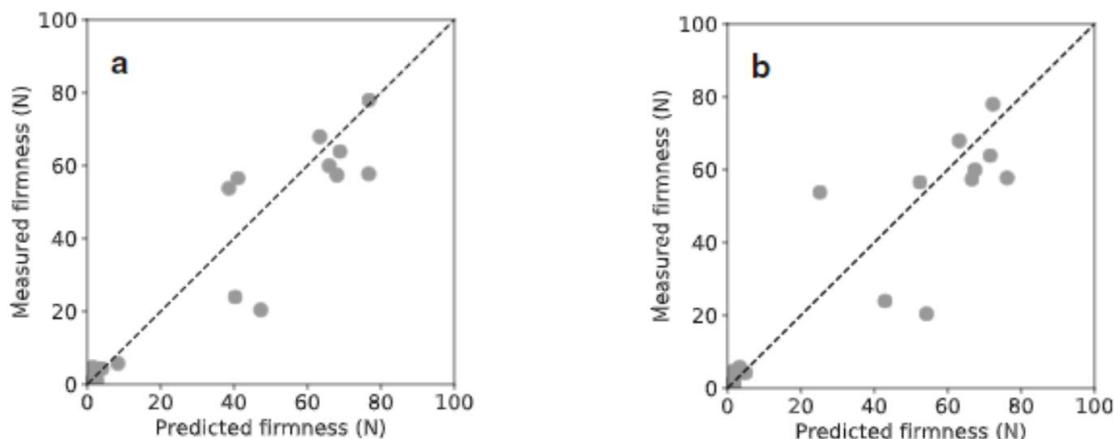
Nota. El contenido total de clorofila en diferentes estados de madurez se reduce debido a la degradación en un cítrico. La degradación produce variaciones en las coordenadas a* y b*.

Cho et al., (2020) utilizaron el un teléfono inteligente para determinar madurez en aguacate *Hass* basándose en la firmeza. Se utilizó el espacio de color L * a * b para analizar las imágenes y el modelo de regresión de Máquina vector soporte fue el más efectivo, una vez más, para la predicción de firmeza. El algoritmo de clasificación corresponde a CNN, que es un tipo de red neuronal artificial especializado para clasificar imágenes, con entrenamiento previo de muestras patrón (Voulodimos et al., 2018). Los aguacates se colocaron dentro de una carpa con iluminación constante para homogenizar el entorno, las imágenes se capturaron con un iPhone 5S con configuración estándar en su cámara.

Se realizó la regresión mediante tres modelos: regresión por vector de soporte y k de vecinos más cercanos.

Figura 5

Firmeza medida por un punzómetro frente a la firmeza predicha por análisis de los parámetros Lab.



Nota. El modelo de regresión SVM presentó mejores correlaciones de la predicción de firmeza que el método de k vecinos más cercanos. Los valores para firmeza están expresados en Newtons.

Durante el almacenamiento del aguacate, los parámetros L^* y b^* disminuyeron mientras que el parámetro a^* aumentó gradualmente, estos cambios se debieron a que el aguacate cambió de manera global su color de verde a violáceo negro. El parámetro a^* fue el mejor estimador de la firmeza con una correlación individual del 0,88. El cambio sugiere que mientras más rojo es el color de piel, el valor de la firmeza es menor (Cho et al., 2020).

3.5. Imágenes multiespectrales

Las regiones del visible y del infrarrojo cercano (NIR) abarcan los rangos de 400-740nm y 750-2500 respectivamente. En estos rangos del espectro es posible evaluar compuestos orgánicos de interés presentes en alimentos, principalmente lípidos y pigmentos. Los experimentos se basan en la atenuación de la radiación Vis y NIR por parte de los frutos (corteza o pulpa) para una serie de aplicaciones cuantitativas. Los ensayos han demostrado mejores resultados cuando han sido aplicados en las pulpas de las frutas (Walsh et al., 2020).

3.5.1. Imagen de resonancia magnética (RMI)

El método evalúa las características estructurales mediante la cuantificación de las interacciones entre el núcleo y los electrones de un átomo. Las interacciones más

estudiadas corresponden al átomo de hidrógeno. RMI permite crear imágenes en 2D o 3D de alta definición, presentando mediante escaneo el desplazamiento químico de protones (H^+) vinculados a la presencia de agua, azúcares o aceite (Cakmak, 2019). El contenido de aceite es un parámetro potencial para esta técnica ya que se ha utilizado en técnicas convencionales para determinar madurez en aguacate. La técnica inicialmente se diseñó para determinar defectos internos (Mazhar et al., 2015), posteriormente los estudios de la variación en los protones debido a la pérdida de agua en los frutos facilitaron la evaluación del estado de madurez del aguacate en términos de firmeza de la pulpa.

3.5.2. Infrarrojo cercano

El empleo de espectroscopia para realizar controles post cosecha es tema maduro, pese a no tener los mejores valores de confiabilidad, ha sido adoptada en las prácticas comerciales para evaluar propiedades químicas. Enlaces de O-H y C-H absorben la luz en la región infrarroja (<2500nm), por lo que los picos en las bandas de lectura permiten cuantificar macro constituyentes dominantes de una fruta de manera no invasiva (Walsh et al., 2020).

Instrumentación

La fuente de luz generalmente son fotodiodos y la longitud de onda más común es 10nm. El sensor se coloca en la parte ecuatorial de la fruta y los datos se presentan en los rangos del espectro de 350-2520nm. El algoritmo SVM ajusta de mejor manera los datos analizados con las muestras patrón (Kasampalis et al., 2021).

Tabla 5*Sistemas NIR desarrollados.*

Instrumento	Formato	Geometría óptica	Aplicación
Da metro	Portable	Remitancia	Clorofila
Kiwi metro	Portable	Remitancia	Pigmentos rojos
Cereza metro	Portable	Remitancia	Pigmentos rojos
Multiplex330	Portable	Reflectancia difusa	Pigmentos
Softripe	Portable	Reflectancia difusa	Clorofila
FIORMA	Portable	Remitancia	Clorofila, pigmentos
IDD4	En línea	Transmitancia	Defectos internos

Nota. La aplicación cuantifica un atributo físico o químico de la fruta y su relación con el estado de madurez o calidad. Adaptado de (Walsh et al., 2020); (Vilanova, 2012).

Existen estudios aplicados para evaluar pigmentos en frutos y vegetales, al igual que su interacción con el etileno, los resultados cuentan con relevancia para determinar etapa óptima de cosecha y estimación de la vida útil (Dar et al., 2019). Trabajos más recientes demuestran que a través de la intensidad espectral se puede indagar en la clorofila de una fruta para una detección proximal y fenotipado (B. Li et al., 2018). El contenido de materia seca y el contenido de sólidos solubles totales permiten determinar el índice de madurez de muchas frutas. Se ha obtenido bajos niveles de fiabilidad en frutos con alto contenido de almidón, como el caso del maíz. La espectroscopia NIR ha cuantificado de manera eficiente frutos frescos y mantiene los niveles de precisión y exactitud de ensayos convencionales en laboratorio (Subedi & Walsh, 2011). La firmeza varía en cada estado de madurez de una fruta debido al cambio en la composición química, como por ejemplo: la degradación de pectinas. Esta variación provoca cambios en la dispersión de la luz por parte de la pared celular que puede ser detectable por un sensor monocromático y presentado en el espectro, los datos finales se pueden correlacionar con el estado de madurez (Subedi & Walsh, 2009).

Trabajos relacionados

Melado-Herreros et al (2021), clasificaron frutos de aguacate *Hass Mill* correlacionando la firmeza con el contenido de materia seca, siendo este último el parámetro de clasificación. 120 muestras se clasificaron en tres grupos de acuerdo a su índice de madurez mediante ensayos destructivos: inmaduro, maduro y sobremaduro. La función para calcular el índice de madurez fue:

$$\text{índice de madurez} = \ln\left(\frac{\text{firmeza de la pulpa}}{\text{contenido de materia seca}}\right)$$

Para la obtención de HSI de las muestras se utilizó el equipo Savitzy Golay en un rango de 380-2000nm. En la clasificación se obtuvo un valor de precisión de 50% para inmaduro, 80% para maduro y 87% para sobremaduro. La regresión de las imágenes con los datos fue realizada por PLS Toolbox.

3.5.3. Análisis de imágenes térmicas

El empleo de imágenes térmicas es un método amigable con el medioambiente que procesa la radiación térmica de un objeto. Como método de análisis, esta técnica suprime los factores que externos relacionados con el color. La temperatura está asociada a diferentes fenómenos que ocurren en el interior de un organismo u objeto, mediante el procesamiento de este parámetro se pueden obtener un gran número de datos de manera no invasiva. Para construir las imágenes termográficas, detecta la radiación en el rango de 3 μm y 13 μm (Lu & Lu, 2017). Las mediciones que se obtienen a partir de imágenes térmicas pueden ser adquiridas en el día o por la noche, ya que la radiación infrarroja es emitida y no reflejada como en el caso de los colores o la luminosidad. El sensor detecta la radiación del fruto y la transforma en señales eléctricas, a partir de las cuales se construye un termograma con la ayuda de un procesador (Chandel et al., 2018). Una de las aplicaciones agrícolas que se ha popularizado es la detección y cuantificación de la tasa respiratoria en frutos, factor fuertemente relacionado con el estado de madurez y la senescencia de un fruto fresco (S. Li et al., 2019).

Para determinar el estado de madurez en la que se encuentra el fruto, la lectura de imágenes térmicas posibilita la cuantificación la radiación infrarroja emitida por el fruto analizado. Estudios previos muestran de antemano que la tasa de respiración varía durante el ripening. La respiración en los frutos se mide a partir de la generación de CO_2 en unidades de $\text{mL}_{\text{CO}_2} * \text{kg}^{-1} * \text{h}^{-1}$, cada fruto tiene una tasa y variación específica que se

deriva del tiempo de vida útil, la respiración es mayor para los frutos climatéricos. Para el caso del aguacate se ha determinado un promedio de tasa de respiración entre 50-55 $mL_{CO_2} * kg^{-1} * h^1$ para el estado óptimo de madurez (Hough et al., 2003). Para la clasificación en términos de madurez, el procesador de imágenes busca correlacionar el calor emanado con la tasa de respiración (Yaqoob et al., 2021).

Instrumentación

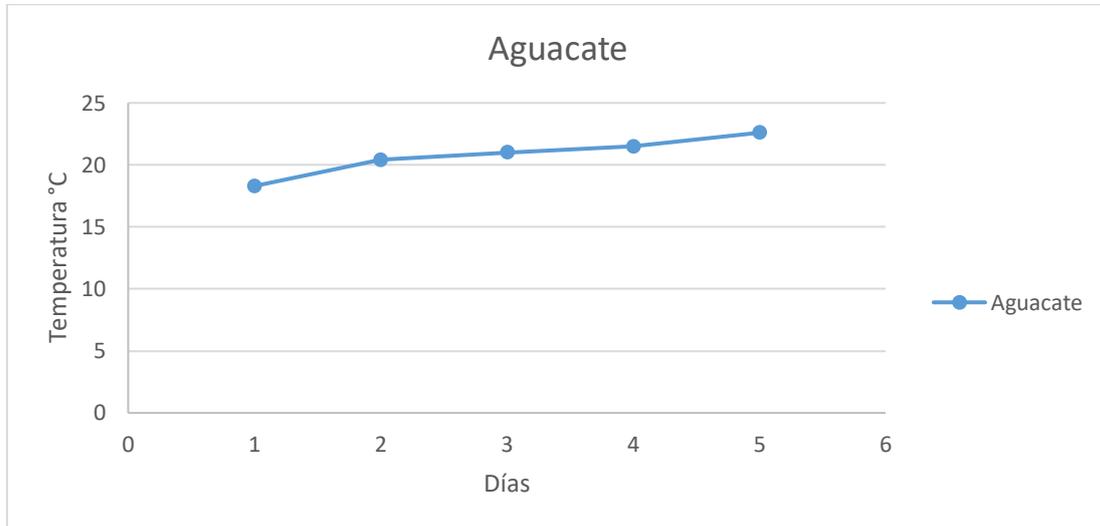
Las cámaras infrarrojas tienen la capacidad de capturar aproximadamente 30 imágenes por segundo. La velocidad es una característica muy importante debido al cambio en las condiciones externas y el movimiento (Tripathi & Maktedar, 2020). Las cámaras más utilizadas para el análisis de calidad en frutos son T440, FLIR Lepton 2.5 y Fiuke Ti55 (Mohd Ali et al., 2020) debido a que trabajan con gran eficiencia entre 0 y 40 °C. Los datos son procesados y procesados.

Trabajos relacionados

Gurupatham et al (2018), empleó la termografía, como método no destructivo, para determinar la variación de temperatura durante la maduración en aguacate Hall. Se mantuvieron constantes factores como la temperatura externa, lugar de captura de imagen y cámara infrarroja (E5 IR CAMERA W / MSX 120X90 RES). Se basó en el hecho de que una fruta cambia su capacidad calorífica a diferentes temperaturas.

Figura 6

Variación de la temperatura obtenida por procesamiento de imágenes térmicas durante la maduración de aguacate *Hall*;



Nota. La temperatura incrementa durante el proceso de maduración. (Gurupatham et al., 2018)

Ali et al., (2021) realizaron un estudio para determinar el estado de madurez en durines, una fruta de color gris verdoso que al igual que el aguacate, el color del pericarpio varía mínimamente en las etapas de maduración. La cámara infrarroja empleada fue la FLIR E60, los parámetros analizados fueron intensidad media y min_ROI. Se utilizaron tres algoritmos para la clasificación de madurez donde el más efectivo fue máquina de vectores de soporte (SVM), con una precisión del 99%. Además, el método permite caracterizar la forma y textura en las muestras con un error mínimo. El método de clasificación de datos SVM es una técnica de machine learning que permite clasificar los datos en el plano o espacio utilizando un hiperplano compuesto por funciones lineales (Danades et al., 2016). Es importante mencionar que mediante el uso de cámaras infrarrojas se puede monitorear temperatura en la planta y temperatura ambiental, que son factores importantes en un cultivo (Stutsel et al., 2021).

Tabla 6

Efectividad de los algoritmos en la clasificación de madurez para aguacate.

Nivel de madurez	Clasificación correcta (%)		
	LDA	kNN	SVM
Inmaduro	96	95	97
Maduro	95	93	96
Sobremaduro	96	96	99
Todos	96	95	97

Nota. Algoritmos multivariados utilizados: LDA = análisis discriminante lineal; kNN = k- vecino más cercano; SVM = máquina de vectores de soporte. (Ali et al., 2021)

3.5.4. Análisis de imagen hiperespectral (HSI)

La técnica de imágenes hiperespectrales son consideradas un ensayo híbrido entre conceptos de espectroscopia y técnicas integrales de imagen obteniendo datos en las regiones visibles y de infrarrojo cercano. La transformación de imágenes bidimensionales a hipercubos tridimensionales permite correlacionar eficientemente atributos internos con la textura de los frutos (Munera et al., 2017).

Instrumentación

Las cámaras utilizadas para HSI se componen principalmente de una fuente de luz, un dispositivo de dispersión de la longitud de onda o lámparas monocromáticas y un sensor. El conjunto es asistido por iluminación controlada que homogenizan la iluminación y no generan calentamiento (Antequera et al., 2021). Los montajes ópticos cuentan con la disponibilidad de ser aplicados en líneas de producción.

Trabajos relacionados

(Pinto et al., 2019) crearon un sistema para determinar clasificar en términos de madurez en aguacates *Mill*. El estudio se basó en la reflectancia por parte de la clorofila a los haces de luz de 300-900nm. El sensor empleado fue una cámara Stingray F-080B y se empleó el algoritmo de clasificación PCA. El montaje óptico permitió clasificar de manera eficiente las muestras de aguacate de manera eficiente en tres clases: maduro, casi maduro e inmaduro.

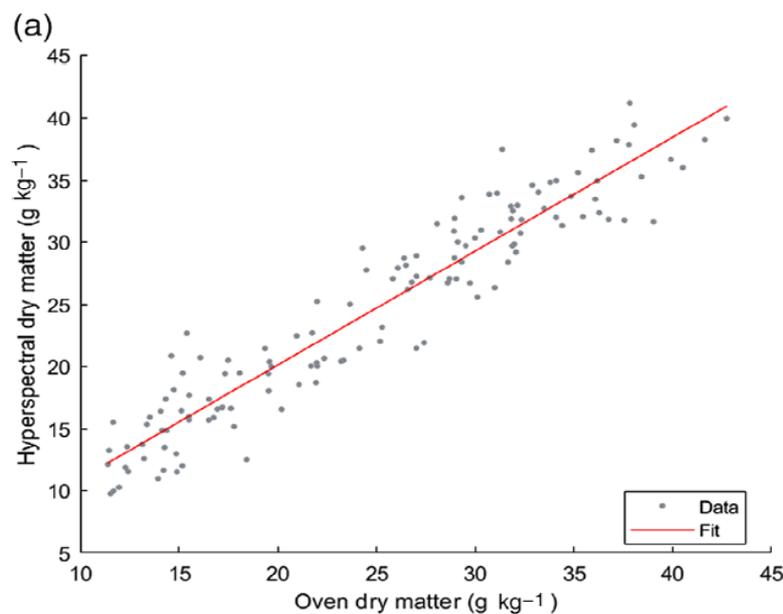
Vega Díaz et al., (2021) diseñaron un estudio para comprobar la relación entre el espacio de color CieLab de una imagen hiperespectral y la madurez en frutos de aguacate *Mill* determinado en porcentaje de materia seca. El factor analizado fue el ROI (región de interés) con tres niveles: área del pedúnculo, área central y área total de la fruta.

Las imágenes fueron obtenidas por una cámara hiperespectral Pika XC2, sobre un rango 400-1000nm. Las imágenes se procesaron con la biblioteca de OpenCV de Python, la regresión de los datos se realizó mediante Matlab r20.

El ROI que presentó una mejor correlación fue el área total del fruto como se observa en la Figura 2, obteniendo un R^2 de 0,95; el modelo de cálculo que mejor se ajustó fue SVM.

Figura 7

Regresión entre resultados de materia seca por el método tradicional vs el empleo de imágenes hiperespectrales.



Regresión lineal entre el contenido de materia seca obtenido mediante máquinas de vectores de soporte (SVM) desde una región de interés (ROI) vs contenido de materia seca obtenido mediante el secado en horno, en aguacate *Hass* (Vega Díaz et al., 2021).

CAPÍTULO IV

CONCLUSIONES Y RECOMENDACIONES

4.1. Conclusiones

Para determinar el estado de madurez de un fruto mediante análisis de imagen, los métodos aplicados cuantifican características de los frutos cuya correlación con el estado de madurez es estudiado previamente. Las características fisicoquímicas, principalmente del pericarpio, son detectados por sensores periféricos y calibrados por algoritmos de *machine learning* a partir de datos experimentales obtenidos durante la fase de entrenamiento.

Durante el proceso de maduración del aguacate ocurren fenómenos de degradación de la clorofila en la corteza y variación del contenido de aceite en la pulpa. La acción de enzimas transforma levemente el color verde de la clorofila en colores más oscuros por la generación de antocianinas. El contenido de aceite está correlacionado con el contenido de materia seca y aumenta por la pérdida de peso del fruto a causa de la respiración y pérdida de agua.

Los atributos del fruto de aguacate detectados por un sistema de visión por computador varían dependiendo del método. Como variables críticas para determinar el estado de madurez se establecieron los cambios de color para el sistema de color RGB y CieLab; calor emitido para procesamiento de imágenes infrarrojos, reflexión y atenuación de luz monocromática para imágenes hiperespectrales o estructuras resonantes para imágenes de resonancia magnética. La homogeneidad de factores externos durante la fase de entrenamiento y el análisis de las muestras influye de manera directa para obtener resultados fiables.

Mediante las técnicas de espectroscopía se pueden obtener datos de la composición interna con los que se interpreta de manera efectiva el índice de madurez. El algoritmo de clasificación SVM ha arrojado los mejores valores de eficiencia para en los ensayos de clasificación de estados de madurez en los frutos de aguacate. Las variedades de aguacate que presentan más variaciones en el color como en el caso de *Persea americana Hass*, pueden ser evaluadas mediante análisis colorimétrico de imagen (RGB o CieLab), mientras que para las subespecies que varían en menor proporción como el caso de *Mill*, se requieren métodos multiespectrales o hiperespectrales.

4.2. Recomendaciones

Se sugiere enfocar experimentos en la obtención de datos de productos de la región analizados con montajes ópticos disponibles. De esta manera se puede contribuir a las bases de datos públicas.

Realizar pruebas en tiempo real analizando productos en líneas de producción o empaque, ya que en nuestro país la agroindustria es pilar fundamental de la economía.

REFERENCIAS BIBLIOGRÁFICAS

- Abasi, S., Minaei, S., Jamshidi, B., & Fathi, D. (2018). Dedicated non-destructive devices for food quality measurement: A review. *Trends in Food Science & Technology*, 78, 197–205. <https://doi.org/10.1016/j.tifs.2018.05.009>
- Adegbenjo, A. O., Liu, L., & Ngadi, M. O. (2020). Non-destructive assessment of chicken egg fertility. *Sensors (Switzerland)*, 20(19), 1–23. <https://doi.org/10.3390/s20195546>
- Agócs, A., Nagy, V., Szabó, Z., Márk, L., Ohmacht, R., & Deli, J. (2007). Comparative study on the carotenoid composition of the peel and the pulp of different citrus species. *Innovative Food Science & Emerging Technologies*, 8(3), 390–394. <https://doi.org/10.1016/j.ifset.2007.03.012>
- Alegre, E., Pajares, G., & De la Escalera, A. (2016). Conceptos y métodos en visión por computador. In *España: Grupo de Visión del Comité Español de Automática (CEA)*. <https://intranet.ceautomatica.es/sites/default/files/upload/8/files/ConceptosyMetodosenVxC.pdf>
- Ali, M. M., Hashim, N., & Shahamshah, M. I. (2021). Durian (*Durio zibethinus*) ripeness detection using thermal imaging with multivariate analysis. *Postharvest Biology and Technology*, 176, 111517.
- Alkhalaf, M. I., Alansari, W. S., Ibrahim, E. A., & ELhalwagy, M. E. A. (2019). Anti-oxidant, anti-inflammatory and anti-cancer activities of avocado (*Persea americana*) fruit and seed extract. *Journal of King Saud University - Science*, 31(4), 1358–1362. <https://doi.org/10.1016/j.jksus.2018.10.010>
- Amodio, M. L., Ceglie, F., Chaudhry, M. M. A., Piazzolla, F., & Colelli, G. (2017). Potential of NIR spectroscopy for predicting internal quality and discriminating among strawberry fruits from different production systems. *Postharvest Biology and Technology*, 125, 112–121. <https://doi.org/https://doi.org/10.1016/j.postharvbio.2016.11.013>
- Anaya-Esparza, L. M., Pérez-Larios, A., Ruvalcaba-Gómez, J. M., Sánchez-Burgos, J. A., Romero-Toledo, R., & Montalvo-González, E. (2020). Funcionalización de los recubrimientos a base de quitosano para la conservación postcosecha de frutas y

- hortalizas. *TIP. Revista Especializada En Ciencias Químico-Biológicas*, 23.
<https://doi.org/https://doi.org/10.22201/fesz.23958723e.2020.0.241>.
- Antequera, T., Caballero, D., Grassi, S., Uttaro, B., & Perez-Palacios, T. (2021). Evaluation of fresh meat quality by Hyperspectral Imaging (HSI), Nuclear Magnetic Resonance (NMR) and Magnetic Resonance Imaging (MRI): A review. *Meat Science*, 172, 108340.
<https://doi.org/https://doi.org/10.1016/j.meatsci.2020.108340>
- Ashton, O. B. O., Wong, M., McGhie, T. K., Vather, R., Wang, Y., Requejo-Jackman, C., Ramankutty, P., & Woolf, A. B. (2006). Pigments in Avocado Tissue and Oil. *Journal of Agricultural and Food Chemistry*, 54(26), 10151–10158.
<https://doi.org/10.1021/jf061809j>
- Astudillo-Ordoñez, C. E., & Rodríguez, P. (2018). Physicochemical parameters of avocado *Persea americana* Mill. cv. Hass (Lauraceae) grown in Antioquia (Colombia) for export. *Corpoica Cienc Tecnol Agropecuaria*, 19.
https://doi.org/https://doi.org/10.21930/rcta.vol19_num2_art:694
- Baldeón, E. O., Alcañiz, M., Masot, R., Fuentes, E. M., Barat, J. M., & Grau, R. (2015). Voltammetry pulse array developed to determine the antioxidant activity of camu-camu (*Myrciaria dubia* (H.B.K.) McVaug) and tumbo (*Passiflora mollissima* (Kunth) L.H. Bailey) juices employing voltammetric electronic tongues. *Food Control*, 54, 181–187. <https://doi.org/10.1016/j.foodcont.2015.01.044>
- Barnea, E., Mairon, R., & Ben-Shahar, O. (2016). Colour-agnostic shape-based 3D fruit detection for crop harvesting robots. *Biosystems Engineering*, 146, 57–70.
<https://doi.org/https://doi.org/10.1016/j.biosystemseng.2016.01.013>
- Barrera López, R. E., & Arrubla Vélez, J. P. (2017). Análisis de fitoesteroles en la semilla de *Persea americana* miller (Var. Lorena) por cromatografía de gases y cromatografía líquida de alta eficiencia. *Revista Facultad de Ciencias Básicas*, 13(1). <https://doi.org/https://doi.org/10.18359/rfcb.2013>
- Bernabé, E. S. (2017). *Procesado de imágenes hiperespectrales* [Escuela Técnica Superior de Ingeniería y Sistemas de Telecomunicación].
https://oa.upm.es/44860/3/TFG_ESTHER_SANCHEZ_BERNABE.pdf
- Best, S., & Vargas, P. (2020). Aplicación de la agricultura tecnológica 4.0. In

Informativo INIA Quilamapu.

<https://biblioteca.inia.cl/bitstream/handle/123456789/4011/NR42318.pdf?sequence=1>

- Bhargava, A., & Bansal, A. (2018). Fruits and vegetables quality evaluation using computer vision: A review. *Journal of King Saud University-Computer and Information Sciences*, 33.
<https://doi.org/https://doi.org/10.1016/j.jksuci.2018.06.002>
- Bonah, E., Huang, X., Aheto, J. H., & Osaé, R. (2020). Application of electronic nose as a non-invasive technique for odor fingerprinting and detection of bacterial foodborne pathogens: a review. *Journal of Food Science and Technology*, 57(6), 1977–1990. <https://doi.org/10.1007/s13197-019-04143-4>
- Bratu, A.-M., Popa, C., Bojan, M., Logofatu, P. C., & Petrus, M. (2021). Non-destructive methods for fruit quality evaluation. *Scientific Reports*, 11(1).
<https://doi.org/10.1038/s41598-021-87530-2>
- Brenes, J. A., Martínez, A., Quesada-López, C., & Jenkins, M. (2020). Sistemas de apoyo a la toma de decisiones que usan inteligencia artificial en la agricultura de precisión: un mapeo sistemático de literatura. *Revista Ibérica de Sistemas e Tecnologías de Información*, E28, 217–229.
[http://www.kerwa.ucr.ac.cr/bitstream/handle/10669/81549/Brenes%2CMartinez%2CQuesada y Jenkins - RISTI_E28.pdf?sequence=1&isAllowed=y](http://www.kerwa.ucr.ac.cr/bitstream/handle/10669/81549/Brenes%2CMartinez%2CQuesada%20y%20Jenkins%20-%20RISTI_E28.pdf?sequence=1&isAllowed=y)
- Cakmak, H. (2019). 10 - Assessment of fresh fruit and vegetable quality with non-destructive methods. In C. M. Galanakis (Ed.), *Food Quality and Shelf Life* (pp. 303–331). Academic Press. <https://doi.org/https://doi.org/10.1016/B978-0-12-817190-5.00010-0>
- Campos, D., Teran-Hilares, F., Chirinos, R., Aguilar-Galvez, A., García-Ríos, D., Pacheco-Avalos, A., & Pedreschi, R. (2020). Bioactive compounds and antioxidant activity from harvest to edible ripeness of avocado cv. Hass (*Persea americana*) throughout the harvest seasons. *International Journal of Food Science & Technology*, 55(5), 2208–2218. <https://doi.org/https://doi.org/10.1111/ijfs.14474>
- Cañete, M. L., De Los Cobos, R. P., & Hueso, J. J. (2018). Influence of harvest date on sensory quality attributes of avocado ‘Hass.’ *Acta Horticulturae*, 1194, 1127–1131.

<https://doi.org/10.17660/ActaHortic.2018.1194.161>

- Chandel, A. K., Khot, L. R., Osroosh, Y., & Peters, T. R. (2018). Thermal-RGB imager derived in-field apple surface temperature estimates for sunburn management. *Agricultural and Forest Meteorology*, 253–254, 132–140. <https://doi.org/https://doi.org/10.1016/j.agrformet.2018.02.013>
- Chandy, A. (2019). RGBD analysis for finding the different stages of maturity of fruits in farming. *Journal of Innovative Image Processing (JIIP)*, 1(02), 111–121. <https://doi.org/https://doi.org/10.36548/jiip.2019.2.006>
- Chen, Jieling, Zhang, M., Xu, B., Sun, J., & Mujumdar, A. S. (2020). Artificial intelligence assisted technologies for controlling the drying of fruits and vegetables using physical fields: A review. *Trends in Food Science & Technology*, 105, 251–260. <https://doi.org/https://doi.org/10.1016/j.tifs.2020.08.015>
- Chen, Jiqing, Wu, J., Wang, Z., Qiang, H., Cai, G., Tan, C., & Zhao, C. (2021). Detecting ripe fruits under natural occlusion and illumination conditions. *Computers and Electronics in Agriculture*, 190, 106450. <https://doi.org/https://doi.org/10.1016/j.compag.2021.106450>
- Chen, Y., Grimplet, J., David, K., Castellarin, S. D., Terol, J., Wong, D. C. J., Luo, Z., Schaffer, R., Celton, J.-M., Talon, M., Gambetta, G. A., & Chervin, C. (2018). Ethylene receptors and related proteins in climacteric and non-climacteric fruits. *Plant Science*, 276, 63–72. <https://doi.org/https://doi.org/10.1016/j.plantsci.2018.07.012>
- Cho, B.-H., Koyama, K., Olivares Díaz, E., & Koseki, S. (2020). Determination of “Hass” Avocado Ripeness During Storage Based on Smartphone Image and Machine Learning Model. *Food and Bioprocess Technology*, 13(9), 1579–1587. <https://doi.org/10.1007/s11947-020-02494-x>
- Cömert, E. D., Mogol, B. A., & Gökmen, V. (2020). Relationship between color and antioxidant capacity of fruits and vegetables. *Current Research in Food Science*, 2, 1–10. <https://doi.org/10.1016/j.crfs.2019.11.001>
- Conesa, A., Manera, F. C., Brotons, J. M., Fernandez-Zapata, J. C., Simón, I., Simón-Grao, S., Alfosea-Simón, M., Martínez Nicolás, J. J., Valverde, J. M., & García-Sánchez, F. (2019). Changes in the content of chlorophylls and carotenoids in the

- rind of Fino 49 lemons during maturation and their relationship with parameters from the CIELAB color space. *Scientia Horticulturae*, 243, 252–260.
<https://doi.org/https://doi.org/10.1016/j.scienta.2018.08.030>
- Danades, A., Pratama, D., Anggraini, D., & Anggriani, D. (2016). Comparison of accuracy level K-Nearest Neighbor algorithm and Support Vector Machine algorithm in classification water quality status. *2016 6th International Conference on System Engineering and Technology (ICSET)*, 137–141.
<https://doi.org/10.1109/ICSEngT.2016.7849638>
- Dar, J. A., Wani, A. A., Ahmed, M., Nazir, R., Zargar, S. M., & Javaid, K. (2019). Peel colour in apple (*Malus × domestica* Borkh.): An economic quality parameter in fruit market. *Scientia Horticulturae*, 244, 50–60.
<https://doi.org/https://doi.org/10.1016/j.scienta.2018.09.029>
- El-Bendary, N., El Hariri, E., Hassanien, A. E., & Badr, A. (2015). Using machine learning techniques for evaluating tomato ripeness. *Expert Systems with Applications*, 42(4), 1892–1905.
<https://doi.org/https://doi.org/10.1016/j.eswa.2014.09.057>
- El-Mesery, H., Mao, H., & Abomohra, E.-F. (2019). Applications of Non-destructive Technologies for Agricultural and Food Products Quality Inspection. *Sensors*, 19, 2–3. <https://doi.org/10.3390/s19040846>
- Escobar-Peláez, M. Á., & Castaño-García, J. O. (2018). *Determinación del estado de madurez del aguacate mediante procesamiento de imágenes con la Raspberry PI*. <https://core.ac.uk/download/pdf/161642542.pdf>
- Escobar, J. V, Rodriguez, P., Cortes, M., & Correa, G. (2019). Influencia de la materia seca como Índice de madurez de cosecha y tiempo de almacenamiento en frío sobre la calidad del aguacate cv. Hass producido en la región del trópico alto. *Información Tecnológica*, 30(3), 199–210.
<https://doi.org/http://dx.doi.org/10.4067/S0718-07642019000300199>
- Espinosa-Velázquez, Dorantes-Alvarez, L., Gutiérrez-López, G. F., García-Armenta, E., Sánchez-Segura, L., Perea-Flores, M. J., Ceballos-Reyes, G. M., & Ortíz Moreno, A. (2016). Morpho-structural description of unripe and ripe avocado pericarp (*Persea americana* Mill var. *drymifolia*) [Descripción morfo-estructural del

pericarpio del aguacate ((*Persea americana* Mill var. *drymifolia*) inmaduro y maduro]. *Revista Mexicana de Ingeniera Quimica*, 15(2), 469–480.

<https://www.scopus.com/inward/record.uri?eid=2-s2.0->

[84978695261&partnerID=40&md5=0106b5d3cb559447f22e32d66debd0b8](https://www.scopus.com/inward/record.uri?eid=2-s2.0-84978695261&partnerID=40&md5=0106b5d3cb559447f22e32d66debd0b8)

Fabbri, G., Giancesella, M., Gallo, L., Morgante, M., Contiero, B., Muraro, M., Boso, M., & Fiore, E. (2021). Application of ultrasound images texture analysis for the estimation of intramuscular fat content in the longissimus thoracis muscle of beef cattle after slaughter: A methodological study. *Animals*, 11(4).

<https://doi.org/10.3390/ani11041117>

Fernandes, A. F. A., Dórea, J. R. R., & Rosa, G. J. de M. (2020). Image Analysis and Computer Vision Applications in Animal Sciences: An Overview. *Frontiers in Veterinary Science*, 7, 551269. <https://doi.org/10.3389/fvets.2020.551269>

Fernández Donoso, M. (2020). *Estudio y desarrollo de modelo de eficiencia hídrica de riego basado en agricultura 4.0* [Universidad Andrés Bello].

<http://repositorio.unab.cl/xmlui/handle/ria/15527>

Fu, L., Gao, F., Wu, J., Li, R., Karkee, M., & Zhang, Q. (2020). Application of consumer RGB-D cameras for fruit detection and localization in field: A critical review. *Computers and Electronics in Agriculture*, 177, 105687.

<https://doi.org/https://doi.org/10.1016/j.compag.2020.105687>

Galletti, P. A., Carvalho, M. E. A., Hirai, W. Y., Brancaglioni, V. A., Arthur, V., & da Silva, C. (2020). Integrating Optical Imaging Tools for Rapid and Non-invasive Characterization of Seed Quality: Tomato (*Solanum lycopersicum* L.) and Carrot (*Daucus carota* L.) as Study Cases. *Frontiers in Plant Science*, 11.

<https://doi.org/10.3389/fpls.2020.577851>

Gurupatham, S. K., Ilksoy, E., Jacob, N., Van Der Horn, K., & Fahad, F. (2018). *Fruit Ripeness Estimation for Avocado Using Thermal Imaging. Volume 8B:*

<https://doi.org/10.1115/IMECE2018-86290>

Hafeez, S. H. B., Rizvi, H. H., Sarfaraz, R., Umer, M., & Siddiqui, M. A. (2019). Electronic Nose (E-Nose). *2019 International Conference on Information Science and Communication Technology, ICISCT 2019*.

<https://doi.org/10.1109/CISCT.2019.8777425>

- Haque, S., Lobaton, E., Nelson, N., Yencho, G. C., Pecota, K. V., Mierop, R., Kudenov, M. W., Boyette, M., & Williams, C. M. (2021). Computer vision approach to characterize size and shape phenotypes of horticultural crops using high-throughput imagery. *Computers and Electronics in Agriculture*, 182. <https://doi.org/10.1016/j.compag.2021.106011>
- Herrera-González, J. A., Salazar-García, S., Martínez-Flores, H. E., & Ruiz-García, J. E. (2017). Indicadores preliminares de madurez fisiológica y comportamiento postcosecha del fruto de aguacate Méndez. *Revista Fitotécnica Mexicana*, 40, 40–60. <https://doi.org/https://doi.org/10.35196/rfm.2017.1.55-63>
- Hough, G., Langohr, K., Gómez, G., & Curia, A. (2003). Survival Analysis Applied to Sensory Shelf Life of Foods. *Journal of Food Science*, 68(1), 359–362. <https://doi.org/https://doi.org/10.1111/j.1365-2621.2003.tb14165.x>
- Hussain, A., Pu, H., & Sun, D.-W. (2018). Innovative nondestructive imaging techniques for ripening and maturity of fruits – A review of recent applications. *Trends in Food Science & Technology*, 72, 144–152. <https://doi.org/https://doi.org/10.1016/j.tifs.2017.12.010>
- Hwang, Y.-H., Ismail, I., & Joo, S.-T. (2020). Identification of Umami Taste in Sous-vide Beef by Chemical Analyses, Equivalent Umami Concentration, and Electronic Tongue System. *Foods*, 9(3). <https://doi.org/10.3390/foods9030251>
- Kalinowska, K., Wojnowski, W., & Tobiszewski, M. (2021). Smartphones as tools for equitable food quality assessment. *Trends in Food Science and Technology*, 111, 271–279. <https://doi.org/10.1016/j.tifs.2021.02.068>
- Kasampalis, D. S., Tsouvaltzis, P., Ntouros, K., Gertsis, A., Gitas, I., & Siomos, A. S. (2021). The use of digital imaging, chlorophyll fluorescence and Vis/NIR spectroscopy in assessing the ripening stage and freshness status of bell pepper fruit. *Computers and Electronics in Agriculture*, 187, 106265. <https://doi.org/https://doi.org/10.1016/j.compag.2021.106265>
- Khudyakova, E. V., Gorbachev, M. S., & Nifontova, E. A. (2019). Improving the efficiency of agro-industrial complex management based on digitalization and system approach. *IOP Conference Series: Earth and Environmental Science*, 274(1). <https://doi.org/10.1088/1755-1315/274/1/012079>

- Kujawa, S., & Niedbała, G. (2021). Artificial neural networks in agriculture. *Agriculture (Switzerland)*, *11*(6). <https://doi.org/10.3390/agriculture11060497>
- Lazaro, A., Boada, M., Villarino, R., & Girbau, D. (2019). Color Measurement and Analysis of Fruit with a Battery-Less NFC Sensor. *Sensors*, *19*(7). <https://doi.org/10.3390/s19071741>
- Li, B., Lecourt, J., & Bishop, G. (2018). Advances in Non-Destructive Early Assessment of Fruit Ripeness towards Defining Optimal Time of Harvest and Yield Prediction—A Review. *Plants*, *7*(1). <https://doi.org/10.3390/plants7010003>
- Li, S., Luo, H., Hu, M., Zhang, M., Feng, J., Liu, Y., Dong, Q., & Liu, B. (2019). Optical non-destructive techniques for small berry fruits: A review. *Artificial Intelligence in Agriculture*, *2*, 85–98. <https://doi.org/https://doi.org/10.1016/j.aiaa.2019.07.002>
- Lima, G. C., Figueiredo, F. L., Barbieri, A. E., & Seki, J. (2020). Agro 4.0: Enabling agriculture digital transformation through IoT [Agro 4.0: Habilitando a transformação digital da agricultura por meio da IoT]. *Revista Ciencia Agronomica*, *51*(5). <https://doi.org/10.5935/1806-6690.20200100>
- Lopez-Vega, L. A., Gil-Cortez, J. M., Sierra-Sarmiento, M. A., & Hoyos-Leyva, J. D. (2021). Hass avocado oil extraction: In the way of malaxation process optimization. *LWT*, *152*, 112312. <https://doi.org/https://doi.org/10.1016/j.lwt.2021.112312>
- López, A., & Di Sarli, A. R. (2016). El modelo CIELAB, las fórmulas de diferencia de color y el uso de la norma europea en 12878 en morteros y hormigones coloreados. *Ciencia y Tecnología de Los Materiales*. https://digital.cic.gba.gob.ar/bitstream/handle/11746/5804/11746_5804.pdf-PDFA.pdf?sequence=1&isAllowed=y
- Lu, Y., & Lu, R. (2017). Non-Destructive Defect Detection of Apples by Spectroscopic and Imaging Technologies: A Review. *Transactions of the ASABE*, *60*(5), 1765–1790. <https://doi.org/https://doi.org/10.13031/trans.12431>
- Lu, Y., & Young, S. (2020). A survey of public datasets for computer vision tasks in precision agriculture. *Computers and Electronics in Agriculture*, *178*, 105760. <https://doi.org/https://doi.org/10.1016/j.compag.2020.105760>

- Luque, A., Peralta, M. E., de las Heras, A., & Córdoba, A. (2017). State of the Industry 4.0 in the Andalusian food sector. *Procedia Manufacturing*, *13*, 1199–1205. <https://doi.org/https://doi.org/10.1016/j.promfg.2017.09.195>
- Magwaza, L. S., & Tesfay, S. Z. (2015). A Review of Destructive and Non-destructive Methods for Determining Avocado Fruit Maturity. *Food and Bioprocess Technology*, *8*(10), 1995–2011. <https://doi.org/10.1007/s11947-015-1568-y>
- Mangus, D. L., Sharda, A., & Zhang, N. (2016). Development and evaluation of thermal infrared imaging system for high spatial and temporal resolution crop water stress monitoring of corn within a greenhouse. *Computers and Electronics in Agriculture*, *121*, 149–159.
- Martínez-González, M. E., Balois-Morales, R., Alia-Tejacal, I., Cortes-Cruz, M. A., Palomino-Hermosillo, Y. A., & López-Gúzman, G. G. (2017). *Tratamientos poscosecha para el control de los daños por frío en frutos climatéricos y no climatéricos*. <https://doi.org/https://doi.org/10.29312/remexca.v0i19.674>
- Mavridou, E., Vrochidou, E., Papakostas, G. A., Pachidis, T., & Kaburlasos, V. G. (2019). Machine Vision Systems in Precision Agriculture for Crop Farming. *Journal of Imaging*, *5*(12). <https://doi.org/10.3390/jimaging5120089>
- Mazhar, M., Joyce, D., Cowin, G., Brereton, I., Hofman, P., Collins, R., & Gupta, M. (2015). Non-destructive 1H-MRI assessment of flesh bruising in avocado (*Persea americana* M.) cv. Hass. *Postharvest Biology and Technology*, *100*, 33–40. <https://doi.org/https://doi.org/10.1016/j.postharvbio.2014.09.006>
- Medina-Torres, R., Jaime-Ruiz, Y., Ibarra-Estrada, M., & Salazar-García, S. (2017). Contenido de aceite en frutos de selecciones de aguacate (*Persea americana*) criollo de clima tropical y subtropical de Nayarit, México. *Revista Venezolana de Ciencia y Tecnología de Alimentos*, *8*(1), 1–13. https://www.researchgate.net/profile/Samuel-Salazar-Garcia/publication/319873905_Oil_content_in_fruit_of_criollo_avocado_Persea_americana_selections_of_tropical_and_subtropical_climate_of_Nayarit_Mexico_Contentido_de_aceite_en_frutos_de_selecciones_de_agua
- Melado-Herreros, A., Nieto-Ortega, S., Olabarrieta, I., Gutiérrez, M., Villar, A., Zufía, J., Gorretta, N., & Roger, J.-M. (2021). Postharvest ripeness assessment of ‘Hass’

- avocado based on development of a new ripening index and Vis-NIR spectroscopy. *Postharvest Biology and Technology*, *181*, 111683.
<https://doi.org/https://doi.org/10.1016/j.postharvbio.2021.111683>
- Méndez-Perez, R., Auat-Cheein, F., & Rosell-Polo, J. R. (2017). Flexible system of multiple RGB-D sensors for measuring and classifying fruits in agri-food Industry. *Computers and Electronics in Agriculture*, *139*, 231–242.
<https://doi.org/10.1016/j.compag.2017.05.014>
- Mendoza, F., Lu, R., Ariana, D., Cen, H., & Bailey, B. (2011). Integrated spectral and image analysis of hyperspectral scattering data for prediction of apple fruit firmness and soluble solids content. *Postharvest Biology and Technology*, *62*(2), 149–160. <https://doi.org/https://doi.org/10.1016/j.postharvbio.2011.05.009>
- Mhlanga, D. (2021). Artificial intelligence in the industry 4.0, and its impact on poverty, innovation, infrastructure development, and the sustainable development goals: Lessons from emerging economies? *Sustainability (Switzerland)*, *13*(11).
<https://doi.org/10.3390/su13115788>
- Misimi, E., Øye, E. R., Eilertsen, A., Mathiassen, J. R., Åsebø, O. B., Gjerstad, T., Buljo, J., & Skotheim, Ø. (2016). GRIBBOT – Robotic 3D vision-guided harvesting of chicken fillets. *Computers and Electronics in Agriculture*, *121*, 84–100. <https://doi.org/https://doi.org/10.1016/j.compag.2015.11.021>
- Mohd Ali, M., Hashim, N., Aziz, S. A., & Lasekan, O. (2020). Emerging non-destructive thermal imaging technique coupled with chemometrics on quality and safety inspection in food and agriculture. *Trends in Food Science & Technology*, *105*, 176–185. <https://doi.org/https://doi.org/10.1016/j.tifs.2020.09.003>
- Momin, M. A., Rahman, M. T., Sultana, M. S., Igathinathane, C., Ziauddin, A. T. M., & Grift, T. E. (2017). Geometry-based mass grading of mango fruits using image processing. *Information Processing in Agriculture*, *4*(2), 150–160.
<https://doi.org/https://doi.org/10.1016/j.inpa.2017.03.003>
- Moscetti, R., Raponi, F., Cecchini, M., Monarca, D., & Massantini, R. (2021). Feasibility of computer vision as Process Analytical Technology tool for the drying of organic apple slices. *Acta Horticulturae*, *1311*, 433–438.
<https://doi.org/10.17660/ActaHortic.2021.1311.55>

- Munera, S., Amigo, J. M., Blasco, J., Cubero, S., Talens, P., & Aleixos, N. (2017). Ripeness monitoring of two cultivars of nectarine using VIS-NIR hyperspectral reflectance imaging. *Journal of Food Engineering*, *214*, 29–39. <https://doi.org/https://doi.org/10.1016/j.jfoodeng.2017.06.031>
- Nguyen, T. T., Vandevoorde, K., Wouters, N., Kayacan, E., De Baerdemaeker, J. G., & Saeys, W. (2016). Detection of red and bicoloured apples on tree with an RGB-D camera. *Biosystems Engineering*, *146*, 33–44. <https://doi.org/https://doi.org/10.1016/j.biosystemseng.2016.01.007>
- Oboh, G., Odubanjo, V. O., Bello, F., Ademosun, A. O., Oyeleye, S. I., Nwanna, E. E., & Ademiluyi, A. O. (2016). Aqueous extracts of avocado pear (*Persea americana* Mill.) leaves and seeds exhibit anti-cholinesterases and antioxidant activities in vitro. *Journal of Basic and Clinical Physiology and Pharmacology*, *27*(2), 131–140. <https://doi.org/doi:10.1515/jbcpp-2015-0049>
- Ordoñez-Araque, R., Rodríguez-Villacres, J., & Urresto-Villegas, J. (2020). Electronic nose, tongue and eye: Their usefulness for the food industry [Nariz, lengua y ojo electrónico: Su utilidad para la industria alimentaria]. *Vitae*, *27*(3), 1–13. <https://doi.org/10.17533/udea.vitae.v27n3a01>
- Özdoğan, G., Lin, X., & Sun, D.-W. (2021). Rapid and noninvasive sensory analyses of food products by hyperspectral imaging: Recent application developments. *Trends in Food Science & Technology*, *111*. <https://doi.org/https://doi.org/10.1016/j.tifs.2021.02.044>
- Padrón-Pereira, C. A., Padrón-León, G. M., Montes-Hernández, A. I., & Oropeza-González, R. A. (2016). *Procesamiento digital de imágenes: Determinación del color en muestras de alimentos y durante la maduración de frutos* (1st ed.). https://www.researchgate.net/publication/312605106_Procesamiento_digital_de_imagenes_Determinacion_del_color_en_muestras_de_alimentos_y_durante_la_maduracion_de_frutos
- Pathmanaban, P., Gnanavel, B. K., & Anandan, S. S. (2019). Recent application of imaging techniques for fruit quality assessment. *Trends in Food Science & Technology*, *94*, 32–42. <https://doi.org/https://doi.org/10.1016/j.tifs.2019.10.004>
- Pena-Pereira, F., Wojnowski, W., & Tobiszewski, M. (2020). AGREE—Analytical

GREENness Metric Approach and Software. *Analytical Chemistry*, 92(14), 10076–10082. <https://doi.org/10.1021/acs.analchem.0c01887>

Pérez-Díaz, F., de Lourdes Arévalo-Galarza, M., Pérez-Flores, L. J., Lobato-Ortiz, R., & Ramírez-Guzmán, M. E. (2020). Fruits growth and postharvest characteristics of native tomato genotypes (*Solanum lycopersicum* L.) [Crecimiento y características postcosecha de frutos de genotipos nativos de tomate (*Solanum lycopersicum* L.)]. *Revista Fitotecnia Mexicana*, 43(1), 89–99. <https://doi.org/10.35196/RFM.2020.1.89>

Pérez-Llorca, M., Muñoz, P., Müller, M., & Munné-Bosch, S. (2019). Biosynthesis, Metabolism and Function of Auxin, Salicylic Acid and Melatonin in Climacteric and Non-climacteric Fruits. *Frontiers in Plant Science*, 10, 136. <https://doi.org/10.3389/fpls.2019.00136>

Pinto, J., Rueda-Chacón, H., & Arguello, H. (2019). Classification of Hass avocado (*persea americana* mill) in terms of its ripening via hyperspectral images. *TecnoLÃ\textthreesuperiorgicas*, 22, 111–130. <https://doi.org/https://doi.org/10.22430/22565337.1232>

Putri, V. J., Warsiki, E., Syamsu, K., & Iskandar, A. (2019). Application Nano Zeolite-Molybdate For Avocado Ripeness Indicator. *{IOP} Conference Series: Earth and Environmental Science*, 347, 12063. <https://doi.org/10.1088/1755-1315/347/1/012063>

Ramírez-Gil, J. G., Martínez, G. O. G., & Morales Osorio, J. G. (2018). Design of electronic devices for monitoring climatic variables and development of an early warning system for the avocado wilt complex disease. *Computers and Electronics in Agriculture*, 153, 134–143. <https://doi.org/10.1016/j.compag.2018.08.002>

Ramos-Aguilar, A. L., Ornelas-Paz, J., Tapia-Vargas, L. M., Gardea-Béjar, A. A., Yahia, E. M., Ornelas-Paz, J. D. J., Ruiz-Cruz, S., Rios-Velasco, C., & Ibarra-Junquera, V. (2021). Comparative study on the phytochemical and nutrient composition of ripe fruit of Hass and Hass type avocado cultivars. *Journal of Food Composition and Analysis*, 97. <https://doi.org/10.1016/j.jfca.2020.103796>

Ratani, G., Dario, P., & Cavallo, F. (2017). Smartphone-based food diagnostic technologies: A review. *Sensors*, 17(6), 1453. <https://doi.org/10.3390/s17061453>

- Rodríguez-Pulido, F. J., Gordillo, B., Heredia, F. J., & González-Miret, M. L. (2021). CIELAB – Spectral image MATCHING: An app for merging colorimetric and spectral images for grapes and derivatives. *Food Control*, *125*, 108038. <https://doi.org/https://doi.org/10.1016/j.foodcont.2021.108038>
- Rodriguez, P., Henao, J. C., Correa, G., & Aristizabal, A. (2018). Identification of harvest maturity indicators for ‘hass’ avocado adaptable to field conditions. *HortTechnology*, *28*(6), 815–821. <https://doi.org/10.21273/HORTTECH04025-18>
- Roslin, N. A., Che’ya, N. N., Rosle, R., & Ismail, M. R. (2021). Smartphone application development for rice field management through aerial imagery and normalised difference vegetation index (Ndvi) analysis. *Pertanika Journal of Science and Technology*, *29*(2), 809–836. <https://doi.org/10.47836/pjst.29.2.07>
- Saha, D., & Manickavasagan, A. (2021). Machine learning techniques for analysis of hyperspectral images to determine quality of food products: A review. *Current Research in Food Science*, *4*, 28–44. <https://doi.org/10.1016/j.crfs.2021.01.002>
- Salazar-López, N. J., Domínguez-Avila, J. A., Yahia, E. M., Belmonte-Herrera, B. H., Wall-Medrano, A., Montalvo-González, E., & González-Aguilar, G. A. (2020). Avocado fruit and by-products as potential sources of bioactive compounds. *Food Research International*, *138*, 109774. <https://doi.org/https://doi.org/10.1016/j.foodres.2020.109774>
- Sanaeifar, A., Bakhshipour, A., & de la Guardia, M. (2016). Prediction of banana quality indices from color features using support vector regression. *Talanta*, *148*, 54–61. <https://doi.org/https://doi.org/10.1016/j.talanta.2015.10.073>
- Santos Pereira, L. F., Barbon, S., Valous, N. A., & Barbin, D. F. (2018). Predicting the ripening of papaya fruit with digital imaging and random forests. *Computers and Electronics in Agriculture*, *145*, 76–82. <https://doi.org/https://doi.org/10.1016/j.compag.2017.12.029>
- Sarfraz, M. (2020). Introductory Chapter: On Digital Image Processing. In *Digital Imaging* (3rd Ed). IntechOpen. <https://doi.org/http://dx.doi.org/10.5772/intechopen.83239>
- Sevenich, R. (2022). Instrumentation and Process Control. In P. L. H. McSweeney & J. P. McNamara (Eds.), *Encyclopedia of Dairy Sciences (Third Edition)* (Third Edit,

pp. 336–355). Academic Press. <https://doi.org/https://doi.org/10.1016/B978-0-12-818766-1.00330-5>

Stutsel, B., Johansen, K., Malbêteau, Y. M., & McCabe, M. F. (2021). Detecting Plant Stress Using Thermal and Optical Imagery From an Unoccupied Aerial Vehicle. *Frontiers in Plant Science*, *12*. <https://doi.org/10.3389/fpls.2021.734944>

Subedi, P. P., & Walsh, K. B. (2009). Non-invasive techniques for measurement of fresh fruit firmness. *Postharvest Biology and Technology*, *51*(3), 297–304. <https://doi.org/https://doi.org/10.1016/j.postharvbio.2008.03.004>

Subedi, P. P., & Walsh, K. B. (2011). Assessment of sugar and starch in intact banana and mango fruit by SWNIR spectroscopy. *Postharvest Biology and Technology*, *62*(3), 238–245. <https://doi.org/https://doi.org/10.1016/j.postharvbio.2011.06.014>

Sun, D.-W. (2016). *Computer vision technology for food quality evaluation* (2nd Ed). Academic Press. <https://books.google.com.ec/books?hl=es&lr=&id=cM8cCwAAQBAJ&oi=fnd&pg=PP1&dq=food+computer+vision+hardware&ots=doT8Yz8Eqm&sig=ZL-zgpupJmUSWf8xJK3QA2DG4m0#v=onepage&q=food computer vision hardware&f=false>

Teerachaichayut, S., & Ho, H. T. (2017). Non-destructive prediction of total soluble solids, titratable acidity and maturity index of limes by near infrared hyperspectral imaging. *Postharvest Biology and Technology*, *133*, 20–25. <https://doi.org/https://doi.org/10.1016/j.postharvbio.2017.07.005>

Ting, H. Y., & Tang, K. W. W. (2019). Determination of Sarawak's brinjal maturity using colour image processing technique. *Borneo Journal of Sciences and Technology*, *1*(2). <https://doi.org/https://doi.org/10.35370/bjost.2019.1.2-05>

Tremocoldi, M. A., Rosalen, P. L., Franchin, M., Massarioli, A. P., Denny, C., Daiuto, É. R., Paschoal, J. A. R., Melo, P. S., & Alencar, S. M. de. (2018). Exploration of avocado by-products as natural sources of bioactive compounds. *PLOS ONE*, *13*(2), e0192577. <https://doi.org/https://doi.org/10.1371/journal.pone.0192577>

Tripathi, M. K., & Maktedar, D. D. (2020). A role of computer vision in fruits and vegetables among various horticulture products of agriculture fields: A survey. *Information Processing in Agriculture*, *7*(2), 183–203.

<https://doi.org/https://doi.org/10.1016/j.inpa.2019.07.003>

- Tu, Y.-H., Phinn, S., Johansen, K., Robson, A., & Wu, D. (2020). Optimising drone flight planning for measuring horticultural tree crop structure. *ISPRS Journal of Photogrammetry and Remote Sensing*, *160*, 83–96.
<https://doi.org/10.1016/j.isprsjprs.2019.12.006>
- Uyeh, D. D., Kim, J., Lohumi, S., Park, T., Cho, B.-K., Woo, S., Lee, W. S., & Ha, Y. (2021). Rapid and non-destructive monitoring of moisture content in livestock feed using a global hyperspectral model. *Animals*, *11*(5).
<https://doi.org/10.3390/ani11051299>
- Vega Díaz, J. J., Sandoval Aldana, A. P., & Reina Zuluaga, D. V. (2021). Prediction of dry matter content of recently harvested ‘Hass’ avocado fruits using hyperspectral imaging. *Journal of the Science of Food and Agriculture*, *101*(3), 897–906.
<https://doi.org/10.1002/jsfa.10697>
- Vilanova, J. C. (2012). Revisión bibliográfica del tema de estudio de un proyecto de investigación. *Radiología*, *54*(2), 108–114.
<https://doi.org/https://doi.org/10.1016/j.rx.2011.05.015>
- Villa-Rodríguez, J. A., Molina-Corral, F. J., Ayala-Zavala, J. F., Olivas, G. I., & González-Aguilar, G. A. (2011). Effect of maturity stage on the content of fatty acids and antioxidant activity of ‘Hass’ avocado. *Food Research International*, *44*(5), 1231–1237. <https://doi.org/https://doi.org/10.1016/j.foodres.2010.11.012>
- Voulodimos, A., Doulamis, N., Doulamis, A., & Protopapadakis, E. (2018). Deep Learning for Computer Vision: A Brief Review. *Computational Intelligence and Neuroscience*, *2018*, 7068349. <https://doi.org/10.1155/2018/7068349>
- Walsh, K. B., Blasco, J., Zude-Sasse, M., & Sun, X. (2020). Visible-NIR ‘point’ spectroscopy in postharvest fruit and vegetable assessment: The science behind three decades of commercial use. *Postharvest Biology and Technology*, *168*, 111246. <https://doi.org/https://doi.org/10.1016/j.postharvbio.2020.111246>
- Yaqoob, M., Sharma, S., & Aggarwal, P. (2021). Imaging techniques in Agro-industry and their applications, a review. *Journal of Food Measurement and Characterization*, *15*(3), 2329–2343. <https://doi.org/10.1007/s11694-021-00809-w>

- Zhang, Q., & Gao, G. (2020). Prioritizing robotic grasping of stacked fruit clusters based on stalk location in RGB-D images. *Computers and Electronics in Agriculture*, *172*, 105359.
<https://doi.org/https://doi.org/10.1016/j.compag.2020.105359>
- Zhou, L., Zhang, C., Qiu, Z., & He, Y. (2020). Information fusion of emerging non-destructive analytical techniques for food quality authentication: A survey. *TrAC Trends in Analytical Chemistry*, *127*, 115901.
<https://doi.org/https://doi.org/10.1016/j.trac.2020.115901>
- Zhu, L., Spachos, P., Pensini, E., & Plataniotis, K. N. (2021). Deep learning and machine vision for food processing: A survey. *Current Research in Food Science*, *4*, 233–249. <https://doi.org/10.1016/j.crfs.2021.03.009>