



Identificación automatizada de imágenes, detección y recuento de piña usando vista superior mediante Machine Learning

JULIAN MAURICIO RIVEROS PARRADO

Universidad Antonio Nariño
Facultad de Ingeniería Mecánica, Electrónica y Biomédica
Villavicencio, Colombia
2022

Identificación automatizada de imágenes, detección y recuento de piña usando vista superior mediante Machine Learning

JULIAN MAURICIO RIVEROS PARRADO

Proyecto de grado presentado como requisito parcial para optar al título de:
Ingeniero Electromecánico

Director :
Ingeniero Alexander Cucaita Gómez

Universidad Antonio Nariño
Facultad de Ingeniería Mecánica, Electrónica y Biomédica
Villavicencio, Colombia
2022

Dedicatoria

Dedico este proyecto de tesis a Dios y a mis padres. A Dios porque ha estado conmigo en cada paso que doy, cuidándome y dándome fortaleza para continuar, a mis padres, quienes a lo largo de mi vida han velado por mi bienestar y educación siendo mi apoyo en todo momento. Depositando su entera confianza en cada reto que se me presentaba sin dudar ni un solo momento en mi inteligencia y capacidad. Es por ellos que soy lo que soy ahora, también se lo dedico a mi esposa por que a lo largo de estos 6 años de relación ha sido un apoyo incondicional para mí.

Y especialmente le dedicó esto a mi hija, por qué gracias a ella mi vida cambió y me convirtió en mejor persona, por ella son todos mi logros y esfuerzos que ya se verán reflejados.

Muchas gracias.

Agradecimientos

Quiero iniciar agradeciendo a cada uno de los docentes que me acompañaron durante este proceso educativo, además, a mis padres por brindarme su confianza, por los valores y principios que me han inculcado desde que era pequeño hasta hoy en día como mi ejemplo y por último, pero no menos importante quiero agradecerle a mi esposa y a mi hija por todo el apoyo moral que diariamente me brindan.

Infinitas gracias por qué gracias a ustedes soy lo que soy hoy en día.

Resumen

El uso de nuevas tecnologías para el reconocimiento de frutas como la piña a partir del análisis de imágenes, es una solución actual al proceso de conteo de frutos que puede haber al alcance de estas nuevas formas, para ello se logró realizar este proceso usando la red neuronal artificial (ANN), máquina de vectores de soporte(SVM), bosque aleatorio (RF), Naive Bayes (NB), árboles de decisión (DT) y k vecino más cercanos (KNN).

Palabras clave: Piña. RPA, programación, conteo, recolección.

Abstract

The use of new technologies for the recognition of fruits such as pineapple from image analysis is a current solution to the process of counting fruits that may be within reach of these new forms, for this it was possible to carry out this process using the network artificial neural (ANN), support vector machine (SVM), random forest (RF), Naive Bayes (NB), decision trees (DT) and k nearest neighbor (KNN).

Keywords: Pineapple. RPA, programming, counting, collecting.

Contenido

	Pág.
Tabla de contenido	
1. Materiales y métodos	18
1.1. Recopilación de datos de UAV y configuración de instrumentos.....	18
1.2. Canal de metodología y flujo de trabajo de análisis de imágenes	18
1.2.1. Preprocesamiento de imágenes para identificación de coronas de frutos	19
1.2.2. Extracción de características	20
1.2.3. Selección de características usando ANOVA unidireccional	22
1.2.4. Clasificación de objetos con aprendizaje automático	22
1.2.5. Recuento de rendimiento	27
1.2.6. Evaluación del desempeño	27
2. Resultados y discusión	29
3. Conclusiones y recomendaciones	40
3.1. Conclusiones.....	40
3.2. Recomendaciones.....	41
Bibliografía	42

Lista de figuras

	Pág.
Figura 1 Plantación de piñas y montaje experimental con cuadricóptero DJI Mavic 2 Zoom.	18
Figura 2 Diagrama de flujo de la metodología propuesta de detección y conteo de rendimiento de frutos de piña.	19
Figura 3 Estructura ANN-MLP.	24
Figura 4 Imagen recortada de (a) imagen original, (b) mejora de contraste (técnica CLAHE), (c) eliminación de fondo (espacio de color HSV), (d) imagen binaria , (e) proceso de dilatación, (f) proceso de relleno, (g) proceso abierto, (h) proceso cerrado y (i) t	29
Figura 5 Coronas de piña extraídas y ruido de las imágenes del cuadro delimitador	30
Figura 6 Ilustración de pruebas de comparación múltiple para demostrar (a) la diferencia significativa entre la característica del área (representada por la línea azul) y un número similar de características, a saber, energía, suavidad y asimetría (representada por la línea roja; valor de $p < 0,05$) para la corona de la piña (b) la diferencia significativa entre las características del área con el mismo número de características, a saber, energía, suavidad y sesgo (representado por la línea roja; valor $p < 0,05$) para el ruido de fondo (c) la comparación del número de características entre con y sin selección de características utilizando unidireccional ANOVA.....	31
Figura 7 Métricas de confusión para demostrar la capacidad de clasificación utilizando el clasificador de aprendizaje automático más preciso (a) clasificador ANN-GDX; notación de 1 = piña, 2 = ruido y (b) clasificador SVM cuadrático; notación de 1 = piña, 2 = r.....	37
Figura 8 Rendimiento de comparación entre clasificadores con varias funciones de entrenamiento (a) ANN-LM (b) ANN-SCG (c) ANN-GDX y (d) algoritmos de prueba ANN-RP.....	37
Figura 9 La comparación del conteo de rendimiento de la corona de piña entre el conteo manual y el conteo automático utilizando el aprendizaje automático.....	38

Lista de tablas

Pág.

Tabla 1 Comparación de métricas de rendimiento para la clasificación entre diferentes funciones de entrenamiento y selección de características con y sin ANOVA unidireccional en datos de prueba.	33
---	----

Lista de Símbolos y abreviaturas

Abreviaturas

Abreviatura	Término
<i>ANN</i>	Red neuronal artificial
<i>ANOVA</i>	Análisis de varianza unidireccional
<i>CLAHE</i>	Técnica de mejora adaptativa imitada por el contraste
<i>DT</i>	Decision Trees
<i>KNN</i>	k- vecinos más cercanos
<i>NB</i>	Naive Bayes
<i>RF</i>	Random Forest
<i>ROI</i>	Región de Interés
<i>SVM</i>	Máquina de vectore de soporte
<i>TP</i>	True positive
<i>UAV</i>	Aeronave no tripulada

Introducción

Recientemente, la agricultura de precisión ha recibido atención mediante la implementación de un análisis computacional que utiliza el procesamiento de imágenes para ayudar al equipo de gestión agrícola a monitorear, medir y responder a la variabilidad de los cultivos para mejorar la gestión a nivel de granja. El procesamiento de imágenes en agricultura de precisión o aplicaciones agrícolas para diferentes cultivos mediante detección automática y conteo de rendimiento de frutos durante la temporada de cosecha podría ser de gran beneficio para los agricultores. Existen muchas tecnologías con un inmenso potencial en la agricultura, específicamente para satélites (Miranda et al., 2020; Schwalbert et al., 2020), vehículos terrestres (Diago et al., 2019; Wendel et al., 2018) y vehículos aéreos no tripulados (UAV) (Dobbels & Lorenz, 2019; Marques Ramos et al., 2020). Sin embargo, la aplicación de estas tecnologías depende de los tipos de cultivo, el tamaño del área de plantación, la calidad de imagen deseada y la resolución.

El procesamiento de imágenes capturadas por UAV a cierta altura requiere un preprocesamiento, segmentación y clasificación para mejorar la representación de imágenes o la detección de objetos. Los estudios han investigado la aplicabilidad del procesamiento de imágenes para los cultivos para atender la maximización del rendimiento y la gestión de la productividad, incluido el procesamiento de imágenes basado en la detección automática de enfermedades (Feng et al., 2020), el control del estrés del cultivo (Zhou et al., 2018), la predicción del rendimiento (Kicherer et al., 2017) y el conteo a través de la máquina (Gutiérrez et al., 2019). La razón de la pertinencia en varias ramas del sector agrícola es el rápido desarrollo de las tecnologías de procesamiento informático que brindan beneficios en términos de implementación rápida, bajo costo y resultados de procesamiento precisos para grandes áreas de campo.

El surgimiento de la tecnología UAV como parte de los sistemas aéreos no tripulados para la detección de piñas se puede implementar a alturas de vuelo bajas para resoluciones espaciales extremadamente altas. Estas tecnologías son esenciales para mejorar el proceso o el rendimiento del cultivo. En el sector agrícola, la identificación

automática mediante técnicas de procesamiento de imágenes en el área de la plantación dificulta la obtención de resultados de detección precisos debido a los factores ambientales que contribuyen a la iluminación variable durante el día que varía constantemente de vez en cuando y a las imágenes con formas geométricas y procesamiento de objetos texturizados. Estos inconvenientes han planteado desafíos importantes cuando las imágenes se recuperan a distancia además de los niveles de iluminación; por lo tanto, la detección de cultivo del área de cultivo objetivo puede identificarse erróneamente con precisión. Otros problemas incluyen entornos desestructurados y desordenados y la falta de características distintivas en la superficie de la fruta. Los resultados son pobres cuando se utilizaron diferentes modelos y condiciones para estimar el número de frutos en árboles de diferentes formas de copa. La obtención de imágenes por la noche con iluminación artificial o la selección del entorno oportuno con iluminación nublada ha recomendado comúnmente el mantenimiento de niveles de iluminación constantes.

Para abordar estos problemas, se han evaluado comparativamente varios estudios para investigar el uso del análisis de imágenes en alta resolución espacial de imágenes RGB de UAV. Los estudios actuales para introducir la resolución espacial del análisis de imágenes RGB se han implementado para varios cultivos, incluidos el brócoli (Blok et al., 2016), el maíz (Lang et al., 2019), los cítricos (Maldonado & Barbosa, 2016), el plátano (Calou et al., 2020), la patata (Li et al., 2019) y la bola de algodón (Sun et al., 2019). Sin embargo, según el conocimiento de los autores, este es el primer estudio que analiza específicamente la información de la imagen de la piña utilizando el análisis de imágenes basado en UAV. Dado que existe una investigación limitada para reconocer y clasificar automáticamente la corona de la fruta, este análisis proporciona avances en la comprensión del análisis de imágenes para tales cultivos porque su morfología representa una forma geométrica irregular (es decir, no circular). Con base en los problemas actuales, el algoritmo debería haber considerado la capacidad de superar la iluminación irregular, la discriminación entre la morfología del cultivo y el fondo complejo, la superposición, las oclusiones y las similitudes de color entre los frutos y las hojas.

Todos los estudios anteriores se han incorporado como punto de referencia para demostrar una buena capacidad de rendimiento para cultivos específicos en el

reconocimiento de la región de interés deseada; sin embargo, los enfoques de algoritmos similares no se pueden aplicar fácilmente a otros debido a sus características morfológicas. Al comprender la información del cultivo relacionada con sus características y características, se puede considerar un enfoque adecuado necesario para el análisis de imágenes para detectar las imágenes de la corona de la piña. Por ejemplo, (Blok et al., 2016; Maldonado & Barbosa, 2016) han empleado análisis de imágenes específicas de reconocimiento de objetos esféricos en un entorno de campo iluminado para cabezas de brócoli y cítricos. Se ha propuesto un problema de segmentación debido al efecto de la inconsistencia de la iluminación para analizar la segmentación basada en el color y la textura, el filtro de paso bajo, la característica de energía de la textura y el filtro mediano, y clasificar aún más el cultivo utilizando el sistema experto. Para obtener una detección baja de falsos positivos debido a las similitudes de color entre la región de interés (ROI) y el fondo, estos métodos utilizan conversión de color, umbralización, ecualización de histograma, filtrado espacial con máscaras de Laplace y Sobel y borrosidad gaussiana para combinar con SVM clasificación son útiles para mejorar la detección de frutos verdes que se confunden fácilmente con las hojas del árbol. Sun et al. (Sun et al., 2019) afirmaron que el efecto de sombra ha contribuido a reducir el rendimiento de detección de la bola de algodón y, por lo tanto, implementó el análisis de imagen, es decir, el umbral de color con RGB y HSV, la transformación circular Hough y la operación de fusión y división.

Sun investigó el vector de características, incluidas las características de color y textura, para entrenar un clasificador de bosque aleatorio para la segmentación de cápsulas, logrando una precisión promedio del 99,4 %. El área y la relación de elongación entre los ejes mayor y menor se usaron para separar las cápsulas en racimos superpuestos. Por lo tanto, los algoritmos de detección de objetos deben separar objetos individuales en grupos y conectar regiones inconexas como un solo objeto. Otro estudio mostró que la clasificación adecuada con BPNN (Lang et al., 2019), SVM y ANN (Calou et al., 2020) y RF (Li et al., 2019) han mejorado el estudio mediante sensores remotos, aprendizaje automático e imágenes RGB de alta resolución espacial y, por lo tanto, podrían generar imágenes precisas. reconocimiento y detección.

El método de aprendizaje automático tiene un potencial significativo para el rendimiento oportuno y preciso que se evaluará con las características apropiadas mediante el análisis de varianza (ANOVA) para aumentar la eficiencia del algoritmo diseñado. Se requieren imágenes de calidad con fondos bien iluminados y un enfoque de segmentación adecuado para mejorar el proceso de detección. Esto confirmó que es posible el potencial para procesar imágenes RGB de los cultivos en el campo utilizando UAV y análisis para resaltar sus características.

1. Materiales y métodos

1.1. Recopilación de datos de UAV y configuración de instrumentos

La vista superior de las imágenes de piña de la variante N36 se capturó con el UAV (DJI Mavic 2 Zoom) en la plantación de piña que se encuentra en la parte oriental del municipio de San Martín, Meta en Colombia Fig. 1 . Las imágenes se adquirieron durante la temporada de cosecha en marzo de 2022 utilizando la cámara del dron Mavic 2 Zoom. Los vuelos se fijaron automáticamente a una velocidad de 16 m/s, y vuelan sobre la hilera designada de piñas. Diez imágenes de muestra fueron seleccionadas aleatoriamente y anotadas manualmente para evaluar la capacidad del algoritmo para extraer las imágenes de la piña, lo que comprende el preprocesamiento, la extracción de características y la clasificación de objetos a describir. De las 20 imágenes de muestra, se detectaron 360 coronas de piña, que constaban de 180 piñas y 180 ruidos de fondo de hojas, pastos y el suelo. Los datos se dividieron en datos de entrenamiento y prueba que constaban de 90 piñas y 90 ruidos de fondo.



Figura 1 Plantación de piñas y montaje experimental con cuadricóptero DJI Mavic 2 Zoom.

1.2. Canal de metodología y flujo de trabajo de análisis de imágenes

La canalización de la metodología general para automatizar la detección y el conteo de coronas de piña a partir de imágenes RGB, como se muestra en la Fig. 2 . Comienza con la recopilación de datos en la plantación, el preprocesamiento de la imagen, la extracción

de características, la clasificación ANN, la selección de características mediante el algoritmo ANOVA y el recuento de rendimiento. El análisis de las imágenes del UAV se realizó utilizando una computadora personal con una CPU AMD Series 5 4000 3,2 GHz, 16 GB de RAM, NVIDIA GeForce GTX 1650 M y MATLAB R2019a (MathWorks, 2022). El análisis computacional para la ejecución general del algoritmo a partir del procesamiento de imágenes se utiliza para detectar, clasificar y estimar el rendimiento de la piña en función de la corona de fruta detectada. Las imágenes de datos del UAV se obtuvieron mediante procesamiento de imágenes para mejorar el brillo de cada imagen. Se seleccionaron veinte imágenes al azar para desarrollar un sistema de detección que constaba de 6 a 10 piñas para cada imagen de muestra en la que se recortó la capacidad del algoritmo de mostrar el cuadro delimitador para detectar objetos para extraer las características.

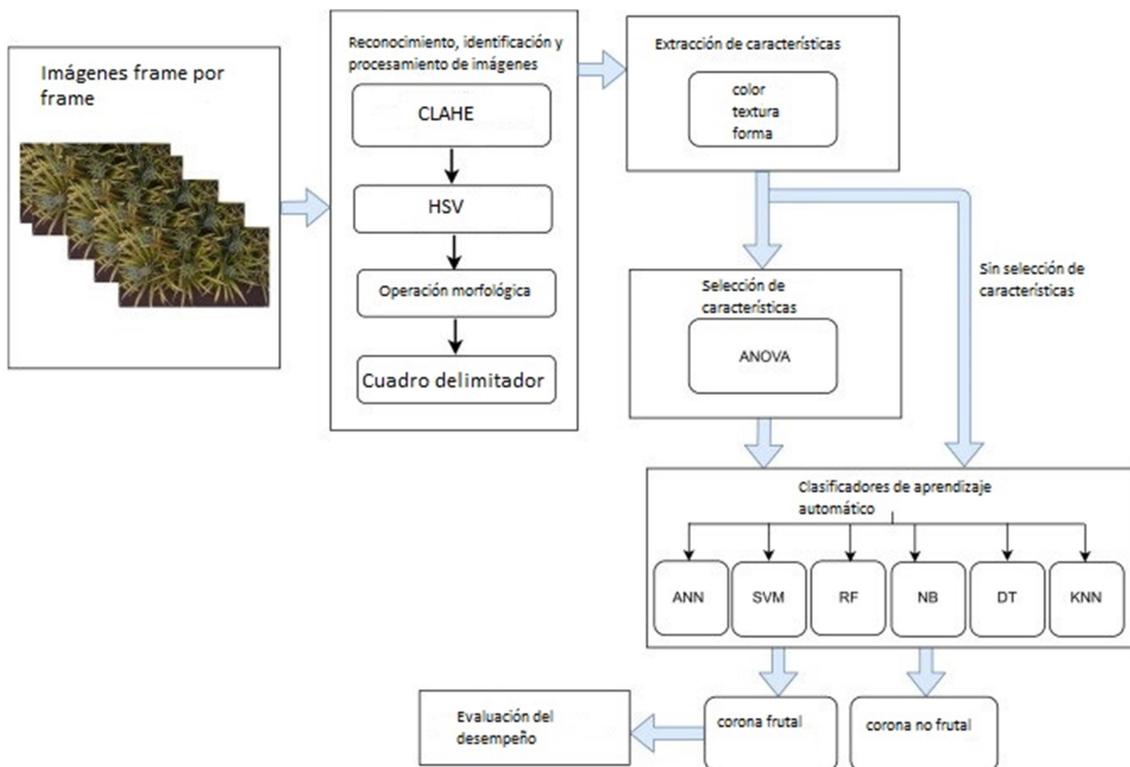


Figura 2 Diagrama de flujo de la metodología propuesta de detección y conteo de rendimiento de frutos de piña.

1.2.1. Preprocesamiento de imágenes para identificación de coronas de frutos

El preprocesamiento elimina las imágenes de fondo no deseadas, como el suelo, las hojas y la hierba de las imágenes RGB capturadas por UAV. Matemáticamente, las

imágenes de cuadro capturadas se pueden representar mediante la Ecuación (1) mientras que $F(X,y)$ representa la función que recupera los píxeles en las coordenadas x e y , respectivamente para los componentes R, G y B; N representa la fila de dimensión máxima y n representa la columna de dimensión máxima (Basso & Pignaton de Freitas, 2020).

$$f(x,y) = \begin{bmatrix} R \\ G \\ B \end{bmatrix} = \begin{bmatrix} f_{0,0} & f_{1,0} & \dots & f_{N-1,0} \\ f_{0,1} & f_{1,1} & \dots & f_{N-1,1} \\ f_{0,n-1} & f_{1,n-1} & \dots & f_{N-1,n-1} \end{bmatrix} \quad (1)$$

La extracción de las coronas de piña del ruido de fondo se realizó convirtiendo los canales R, G y B para mejorar el contraste de color en las imágenes. La mejora de la imagen se incluyó para mejorar la representación de la imagen con la técnica de mejora adaptativa limitada por el contraste (CLAHE) (Rahimi et al., 2020; Schirrmann et al., 2016), que se utilizó para mejorar el contraste y el ruido de fondo. La extracción de la detección de la corona objetivo con el umbral de color se realizó en los espacios de color HSV para construir la máscara más efectiva para eliminar el ruido de fondo. La separación de cada corona de fruta fue más difícil debido al complejo ruido de fondo y, por lo tanto, se requiere un componente V para aumentar la información de brillo. Luego se asignó el umbral para el componente H y S para aislar aún más el elemento que no es de corona. El ruido punteado restante se eliminó con la operación morfológica de dilatación, relleno, apertura y cierre. Se realizó la técnica del cuadro delimitador para detectar el ROI, que puede incluir corona de piña o corona sin piña. Sin embargo, el preprocesamiento es insuficiente debido al ruido de fondo detectado como resultado de mala clasificación. En este caso, la clasificación de aprendizaje automático distinguirá entre las coronas de piña y el ruido de fondo.

1.2.2. Extracción de características

En esta sección, las características extraídas se seleccionan posteriormente al proceso de segmentación. Esta investigación utiliza características de color para representar la apariencia de las imágenes de la corona de piña y características geométricas para extraer características de forma y textura. Luego se realiza un análisis de estas características para diferenciar la corona de la fruta y el ruido de fondo. Con base en las imágenes de muestra de este marco, se determinaron e identificaron tres vectores de características principales como

- Características del color

La extracción de las características de forma de la corona de la piña del proceso de segmentación usó un histograma de color en la corona de la piña que se calculó para las tres matrices de R, G y B. Las tres características principales que se evaluarán son R media, B media y B media. G. El ruido de fondo puede demostrar similitudes de color entre las coronas de piña y, por lo tanto, existían ligeras diferencias.

- Características de la forma

Las características de forma se utilizan para cuantificar el tamaño y la forma de cada corona de piña y el ruido de fondo. Los componentes de la característica de forma a evaluar son el área, el centroide x , el centroide y , la longitud del eje mayor, la longitud del eje menor, la orientación, la solidez, la excentricidad y el perímetro.

- Características de la textura

La extracción de texturas investiga el uso de las características LBP y GLCM para comprender LBP medio, desviación estándar LBP, contraste, correlación, energía, GLCM medio, desviación estándar GLCM, entropía, varianza, curtosis, suavidad, homogeneidad, raíz cuadrática media y asimetría. Función LBP como en las ecuaciones. (2), (3) operan los descriptores de textura en función de la diferencia entre los píxeles centrales y los píxeles adyacentes o vecinos en la corona de la piña y el ruido de fondo. El operador LBP (Sree Vidya & Chandra, 2019) se denota por t_i es el valor vecino, t_C es el valor de gris del píxel central, n es el número total de vecinos involucrados y R es el radio de la vecindad. En un píxel central t_C , cada píxel adyacente t_i obtiene una etiqueta binaria que puede ser 0 o 1, dependiendo de si el píxel central tiene un valor de intensidad mayor que el píxel adyacente.

$$LBP_{N,R} = \sum_{p=0}^{N-1} S(t_i - t_C) 2^p \quad (2)$$

Donde

$$S(t) = \begin{cases} 1, & t \geq 0; \text{ el píxel vecino es mayor que el píxel central} \\ 0, & t < 0; \text{ Otros} \end{cases} \quad (3)$$

Las características de GLCM se utilizan para generar una matriz que describe la aparición de dos píxeles uno al lado del otro desde la derecha en una imagen en escala de grises. Las características de GLCM calculan en cuatro orientaciones, a saber, 0° , 45° , 90° y 135° . Los GLCM se almacenan en una matriz $i \times j \times n$, donde n es el

número de GLCM normalmente determinado debido a las diferentes orientaciones y desplazamientos del algoritmo. Después de extraer la matriz GLCM, se calcularon algunas características (Vallabhaneni & Rajesh, 2018), a saber, contraste, correlación, entropía, energía, homogeneidad, varianza, asimetría y suavidad.

1.2.3. Selección de características usando ANOVA unidireccional

ANOVA unidireccional demostró la capacidad de analizar subconjuntos de características redundantes al reducir la dimensionalidad de los datos. Varias funciones pueden degradar el rendimiento de la clasificación incluso cuando todas las funciones son irrelevantes y contienen información sobre la variable de respuesta. Si se aplican demasiadas funciones en el sistema, puede degradar el rendimiento de la predicción incluso cuando todas las funciones son relevantes y contienen información sobre la variable de respuesta. Este estudio utilizó una prueba de análisis de comparación múltiple en ANOVA unidireccional para la selección de características con valores de p inferiores a 0,05 y la separación de medias se calculó mediante la prueba de diferencia significativamente significativa de Tukey, que demostró que una o más características son significativamente diferentes (Panda, 2020). La selección de características reduce la dimensionalidad de los datos al seleccionar solo un subconjunto de características medidas para crear el modelo clasificador de aprendizaje automático para optimizar el rendimiento de la clasificación.

1.2.4. Clasificación de objetos con aprendizaje automático

En general, la clasificación impone un modelo computacional inspirado en el sistema nervioso central en informática y campos afines para resolver problemas no lineales correspondientes a datos ruidosos o complejos (Babikir et al., 2019), incluido el análisis de imágenes. Los clasificadores de aprendizaje automático estiman el número de coronas de piña dentro del cuadro delimitador mediante el aprendizaje de las características morfológicas al contar el número de coronas de frutas en varios cuadros de imágenes (Roy et al., 2019) que se muestran en la Ecuación (4). Suponga que el cuadro delimitador de la i -ésima imagen se denota por bb_i y N es el número máximo del cuadro delimitador, por lo tanto, el número total de ROI detectado es:

$$Total \text{ número ROI} = \sum_{n=i}^N (bb_i, bb_{i+1}, bb_{i+2}, \dots, bb_N) \quad (4)$$

El algoritmo de clasificación Se necesita el uso de aprendizaje automático para eliminar la detección positiva verdadera de la corona de piña para identificarla como una corona que no es de fruta. El procesamiento previo basado en el algoritmo de imagen no puede detectar todos los cuadros delimitadores. Por lo tanto, al usar el algoritmo de clasificación, esto mejora indirectamente el rendimiento del algoritmo para discriminar correctamente la corona y, por lo tanto, lo hace útil durante el proceso de conteo de frutas. Este estudio involucra 26 neuronas que representan los números de características morfológicas como nodo de entrada, 2 neuronas en el nodo de salida que representan la corona deseada. La arquitectura específica de las capas ocultas depende de la arquitectura de clasificadores propuesta. Para que los resultados sean más confiables en los datos automáticos de conteo, entrenamiento y prueba para cada entrenamiento experimental, Los conjuntos de prueba y validación se generan aleatoriamente estableciendo el 70 % del conjunto de datos como conjunto de entrenamiento, el 15 % como conjunto de prueba y el 15 % como conjunto de validación. Las imágenes procesadas en 360° con secciones recortadas del cuadro delimitador contienen específicamente ambas coronas de piña, y el ruido de fondo se entrena usando las imágenes de entrenamiento y se prueba con imágenes invisibles para ver la precisión de la clasificación y el conteo.

1.2.4.1. **Red neuronal artificial**

La figura 3 muestra la estructura de MLP NN, que comprende neuronas de capa de entrada, neuronas de capa oculta, de las cuales cada neurona de entrada en ANN se multiplica por un peso de conexión y neuronas de capa de salida. Para generar el resultado final de corona de piña con conteo automático, el producto y los sesgos se suman y transforman a través de una función de transferencia que consta de ecuaciones algebraicas (Anitha & Chakravarthy, 2018), y el resultado correcto se usa para calcular los rendimientos de piña. En la clasificación ANN, esta investigación funciona mediante los procesos de entrenamiento, prueba y validación. Durante el proceso de entrenamiento de la red ANN, con el fin de clasificar la piña y algunos ruidos de fondo detectados durante el procesamiento de imágenes, se realizó un feed forward back propagation se utilizará el procedimiento. El algoritmo de retro propagación es una técnica de aprendizaje ANN comúnmente utilizada. Usando el descenso de gradiente, permite que una red encuentre un estado que minimice la cantidad de error modificando

los pesos que conectan las neuronas. Para una ANN, un número de neuronas predefinidas forman cada capa del MLP (Ebtehaj et al., 2018) que consta de 26 neuronas de entrada, 10 neuronas ocultas y 2 neuronas de salida. Las neuronas, j , en la capa oculta reciben la información de la capa de entrada y suman las señales de entrada, X_i , luego de ponderarlos con las fortalezas de las respectivas conexiones, en yode la capa de entrada. Luego, su salida se envía a la capa de salida, y_i , como una función f de la suma como se muestra en la ecuación. (5)

$$y_i = f\left(\sum w_{ij}x_i\right) \quad (5)$$

Donde f es la función de activación necesaria para transformar la cantidad ponderada de todas las señales que afectan a las neuronas. La salida se clasifica en piña y ruido de fondo. Las ecuaciones muestran la fórmula para contar el rendimiento total de los frutos de piña y el ruido de fondo. De la matriz de confusión, la cantidad de piñas y el ruido de fondo se clasifican correctamente. El algoritmo es competente para adaptarse a varios tipos de datos y es efectivo para aprender patrones. El resultado de la clasificación se comparó con cuatro tipos de algoritmos de entrenamiento, a saber, Levenberg-Marquardt (LM), gradiente conjugado escalado (SCG), retro propagación de tasa de aprendizaje variable (GDX) y retro propagación resistente (RP) para seleccionar el mejor rendimiento para la detección y clasificación de corona de piña y ruido de fondo.

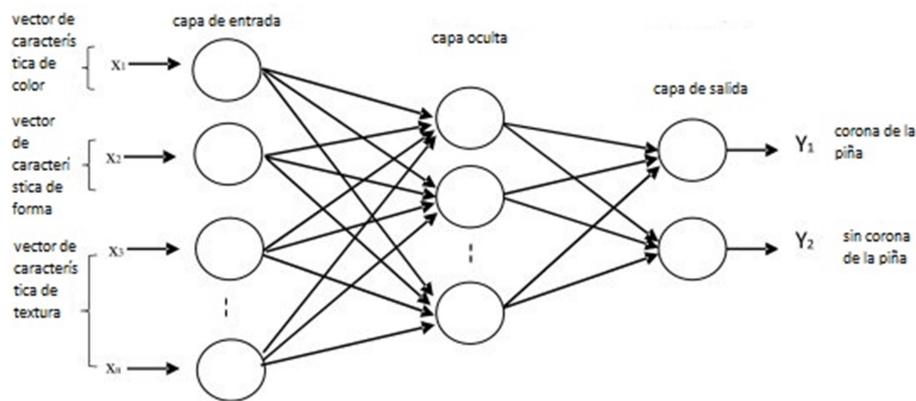


Figura 3 Estructura ANN-MLP.

1.2.4.2. Máquinas de vectores soporte

SVM es un método de clasificación de datos simple que genera un modelo que predice el valor objetivo de los datos en el conjunto de prueba. El modelo se construye utilizando

datos de entrenamiento y prueba, que consisten en una serie de instancias de datos, cada una de las cuales incluye un valor objetivo y muchos atributos. Las etiquetas reconocidas ayudan a especificar la corrección de la salida del sistema proporcionando un indicador del resultado deseado y validando la precisión del sistema, o ayudando al sistema a aprender a operar correctamente (Alzu'bi et al., 2018). El objetivo de una máquina de vectores de soporte es encontrar el mejor hiperplano de separación que maximice el margen por optimización (Al-Zebari & Sengur, 2019); mostrado en las ecuaciones (6) , (7) , (8)

$$\min_{w,b,\xi} J(\vec{w}, \vec{\xi}) = 1/2w^T w + C \sum_{n=1}^N \xi_n \quad (6)$$

$$y_n [w^T \varphi(x_n) + b] \geq 1 - \xi_n \quad (7)$$

$$\xi_n \geq 0, n = 1, \dots, N \quad (8)$$

Donde w , b y ξ son el vector de peso, la variable de sesgo y la variable de holgura, mientras que φ es la función kernel no lineal y $C > 0$ es una constante. Los tipos de SVM incluyen lineal, cuadrático, cúbico, gaussiano fino, gaussiano medio y gaussiano grueso.

1.2.4.3. Bosque aleatorio

El RF es uno de los mejores métodos de clasificación y regresión que tiene la capacidad de clasificar un gran conjunto de datos. Este algoritmo genera un conjunto de árboles de decisión. La idea fundamental de las técnicas de conjunto es agrupar a los alumnos débiles para crear un alumno fuerte. La entrada se ingresa en la parte superior y a medida que desciende al árbol; los datos originales se muestrean al azar, pero con sustitución, en conjuntos cada vez más pequeños. La clase de muestra se calcula utilizando un número arbitrario de árboles forestales aleatorios. Para la clasificación, las predicciones de los RF se toman como los votos mayoritarios de las predicciones de todos los árboles, y para la regresión, las predicciones de todos los árboles se toman como el promedio de las predicciones de todos los árboles, como se ve en la Ec. (9) (Elhariri et al., 2014) , donde S es la predicción de bosques aleatorios mientras k^{th} es una respuesta de un árbol y K es el índice que se ejecuta sobre los árboles individuales en el bosque.

$$S = 1/K \sum_{K=1}^K K^{th} \quad (9)$$

1.2.4.4. **Bayesiana**

El teorema de Bayes es importante para las estadísticas inferenciales y varios modelos sofisticados de aprendizaje automático. El razonamiento bayesiano es un método sistemático para ajustar la probabilidad de los supuestos a la luz de la evidencia reciente y, por lo tanto, juega un papel importante en la investigación (Berrar, 2018). El clasificador ingenuo de Bayes se basa en el teorema de Bayes, que sustenta un algoritmo de aprendizaje automático simple pero eficiente. Los clasificadores ingenuos de Bayes asumen que la consecuencia del valor de una variable en una clase dada es independiente de los valores de otras variables. Esto se conoce como independencia condicional de clase.. Los enfoques de clasificación más complejos a menudo pueden ser superados por el ingenuo Bayes. Es particularmente útil cuando las entradas tienen una gran dimensionalidad. Los modelos con capacidades predictivas se crean utilizando Naive Bayes (Miriti, 2016). Los tipos disponibles de Naïve Bayes son Gaussian Naïve Bayes y Kernel Naïve Bayes.

1.2.4.5. **Árboles de decisión**

Los árboles de decisión (DT) son una técnica simple de aprendizaje automático supervisado no paramétrico muy conocida que ha visto un uso generalizado en tareas de clasificación de datos . El objetivo principal de DT es aprender algunas reglas del conjunto de datos de prueba para construir un modelo que prediga la etiqueta de clase de una muestra de prueba. Un arreglo DT tiene dos tipos de nodos: nodos hoja y nodos internos . A una hoja se le asigna una etiqueta de clase basada en el voto mayoritario de los ejemplos de entrenamiento que llegan a la hoja. Además, cada nodo interno es una consulta de función y se ramifica en función de las respuestas (Al-Zebari & Sengur, 2019). Los tipos de DT incluyen DT fina, media y de curso.

1.2.4.6. **K-vecinos más cercanos**

El clasificador de k-vecinos más cercanos (KNN), que es un método no paramétrico, es un enfoque bien conocido en la comunidad de aprendizaje automático. Para asignar las etiquetas de clase de las muestras de prueba, el clasificador KNN tiene en cuenta las muestras de entrenamiento, un parámetro de distancia y el número de vecinos más cercanos (k). La distancia euclidiana es una solución general para calcular la distancia. El voto de la mayoría de las etiquetas de k-vecinos más cercanos predeterminados determina las etiquetas de clase de las muestras de prueba (Al-Zebari & Sengur,

2019). El KNN tiene varios tipos, a saber, fino, medio, grueso, coseno, cúbico y ponderado.

1.2.5. Recuento de rendimiento

El proceso convencional de conteo de rendimiento se basa en el juicio de un experto en piña que decide la fruta adecuada para cosechar. La piña se cosechará cuando se reciba la demanda del cliente. Mediante un proceso manual, la fruta se contará por parcela individual y luego se multiplicará por la cantidad de parcelas para lograr el objetivo de fruta que se va a cosechar. A diferencia del conteo automático, el algoritmo aprendió el ROI contado en el cuadro delimitador como corona de fruta o corona sin fruta. Según el número total de fotogramas de la imagen, la extracción del cuadro delimitador se acumulará para sumar el número de coronas de piña que se contarán en el rendimiento de la piña. En este estudio,

1.2.6. Evaluación del desempeño

Los rendimientos de las coronas de piña se compararon con el conteo de clasificador manual y de máquina. La evaluación con respecto a la precisión, la sensibilidad, la especificidad y la precisión de la clasificación se evaluó como en las Ecs. (10)–(13). Los términos se definen como (Arowolo et al., 2016; Dhalia Sweetlin et al., 2018) Verdadero positivo (TP) son casos positivos clasificados correctamente de detección de corona de fruta verdadera, Negativo verdadero (TN) son casos negativos clasificados correctamente de detección de corona de fruta incorrecta, Positivo falso (FP) son casos negativos clasificados incorrectamente y Negativo falso (FN) es incorrectamente clasificaron las coronas de piña como los casos positivos. La sensibilidad se define como la probabilidad de que la verdadera clasificación de la copa de la fruta, la especificidad es la probabilidad de clasificación como un ruido detectado desde el fondo. La exactitud y la precisión describen cuántas piñas clasificadas son relevantes y la probabilidad de que la clasificación se realice correctamente.

$$\text{Sensibilidad} = \frac{TP}{(TP + FN)} \% \quad (10)$$

$$\textit{Especificidad} = \frac{TN}{(TN + FN)}\% \quad (11)$$

$$\textit{Presición} = \frac{TP}{(TP + FP)}\% \quad (12)$$

$$\textit{Exactitud} = \frac{(TP + TN)}{(TP + TN + FP + FN)}\% \quad (13)$$

2. Resultados y discusión

El análisis de imágenes para la detección de coronas de piña en un entorno de campo abierto requiere etapas de procesamiento sistemáticas debido a las oclusiones del ruido de fondo, además de las similitudes de color entre las hojas y las coronas que contribuyen a la precisión de la detección. Las comparaciones entre los clasificadores demostraron que los errores de FN y FP siguen siendo altos para clasificar la piña y el ruido, lo que puede deberse a las características de la piña y el ruido que parecen similares, especialmente por el color y la forma de las hojas de la piña en estas situaciones. El potencial de la identificación de la ROI deseada es alto porque el algoritmo de procesamiento de imágenes puede eliminar la iluminación y distinguir las oclusiones que son obligatorias para el análisis de imágenes en esta etapa que se muestra en la Fig. 4. La detección precisa de la corona de la piña es vital para el conteo de frutos, lo cual es útil para estimar el rendimiento en cada parcela de la plantación de piña. En la Fig. 5 se muestra la extracción del cuadro delimitador para recuperar la corona de la piña .

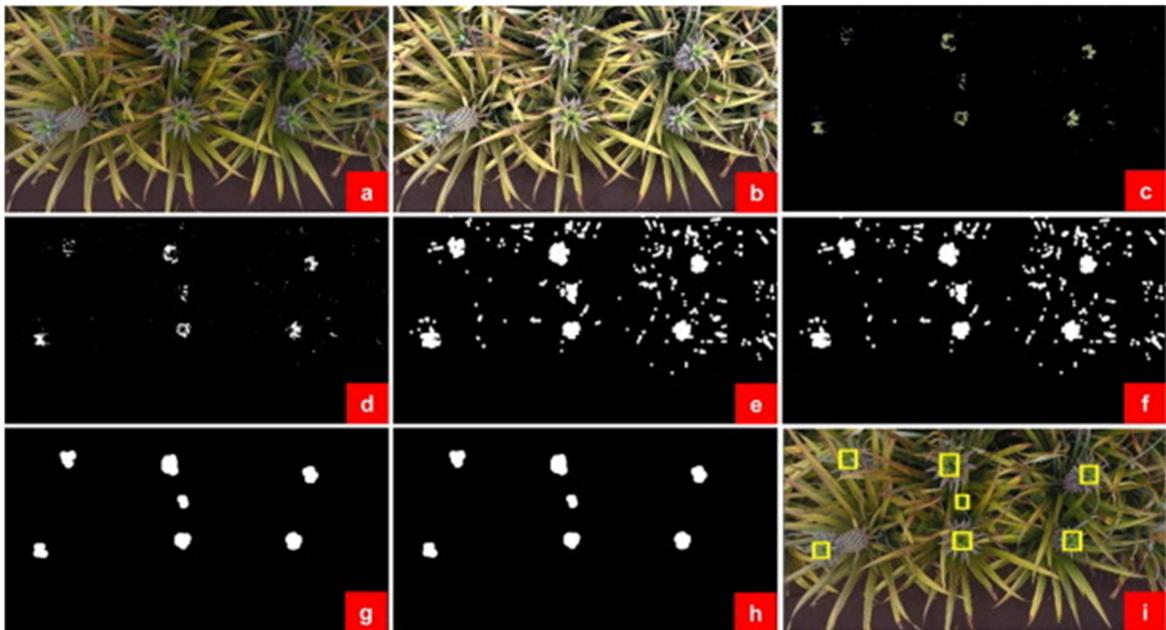


Figura 4 Imagen recortada de (a) imagen original, (b) mejora de contraste (técnica CLAHE), (c) eliminación de fondo (espacio de color HSV), (d) imagen binaria , (e) proceso de dilatación, (f) proceso de relleno, (g) proceso abierto, (h) proceso cerrado y (i) t



Figura 5 Coronas de piña extraídas y ruido de las imágenes del cuadro delimitador.

La selección de características entre color, textura y forma ha demostrado una mejor precisión de clasificación y produce mejores resultados usando ANOVA. Se puede observar que no todas las características extraídas fueron significativas para proceder con la clasificación como se ve claramente en la Fig. 6 . De las 26 características, hay 22 características seleccionadas al hacer coincidir las diferencias significativas de la corona de piña y se podría reducir el ruido de fondo. Las características de forma, color y textura se redujeron a cuatro características significativas que demostraron que la característica no difiere significativamente tanto para la piña como para el ruido, a saber, excentricidad, homogeneidad, raíz cuadrática media y media. Figura 6 ilustra las pruebas de comparación múltiple para examinar el número de características que se pueden eliminar.

número de características

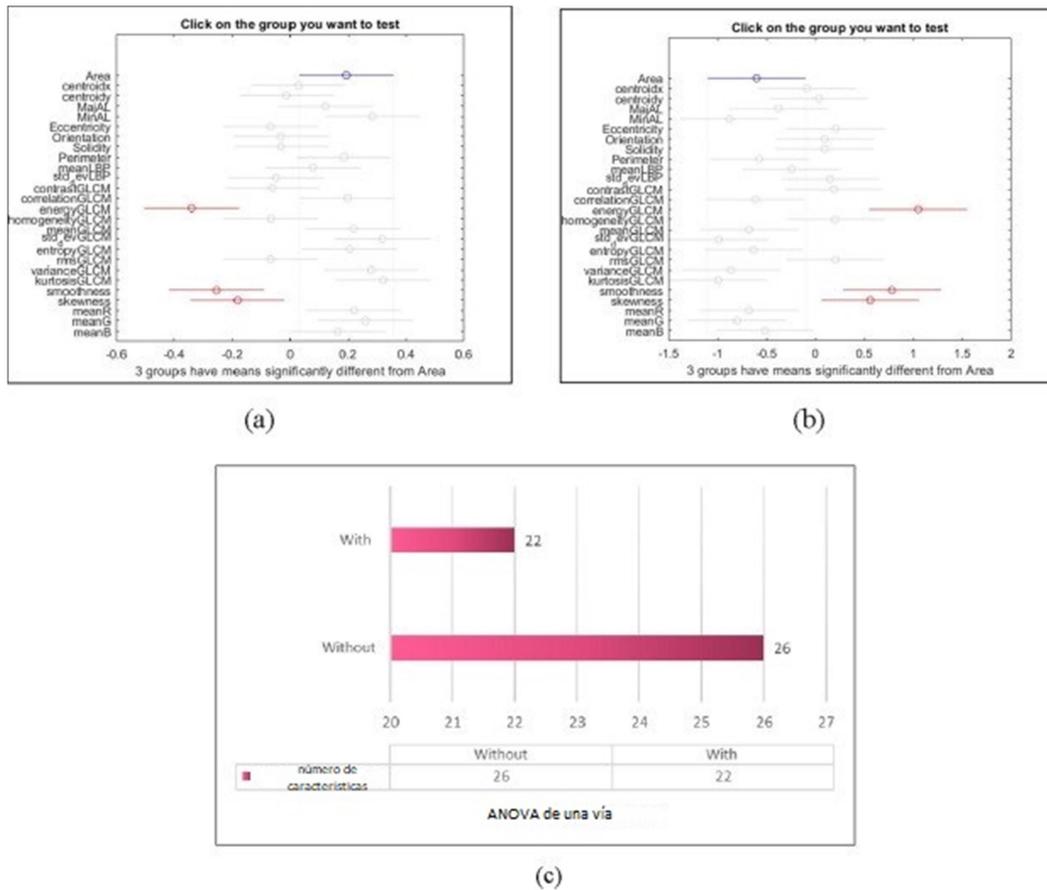


Figura 6 Ilustración de pruebas de comparación múltiple para demostrar (a) la diferencia significativa entre la característica del área (representada por la línea azul) y un número similar de características, a saber, energía, suavidad y asimetría (representada por la línea roja; valor de $p < 0,05$) para la corona de la piña (b) la diferencia significativa entre las características del área con el mismo número de características, a saber, energía, suavidad y sesgo (representado por la línea roja; valor $p < 0,05$) para el ruido de fondo (c) la comparación del número de características entre con y sin selección de características utilizando unidireccional ANOVA

La tabla 1 muestra el rendimiento de precisión del clasificador tabulado del entrenamiento y la prueba entre la función de entrenamiento para seis algoritmos de clasificadores con y sin selección de características usando las imágenes probadas no vistas. Este análisis se centra en descubrir la detección de factibilidad de la corona de piña en la que la detección de precisión es la más adecuada para representar el resultado. Los resultados antes de incorporar la selección de características mostraron que el rendimiento de precisión puede mejorarse o reducirse ligeramente cuando se usa ANOVA unidireccional para ejecutar la selección de características según el tipo de clasificador. La clasificación

general fue capaz de clasificar con precisión hasta el 90 % de la corona identificada. El KNN grueso ha informado que la precisión mínima se reduce en un 36,02% desde la precisión máxima alcanzada. Además, la precisión, La especificidad y la sensibilidad para ANN-GDX también mostraron que los rendimientos superaron el 90%, lo que demostró que el clasificador pudo demostrar una alta sensibilidad para detectar la clasificación de la corona de piña, alta precisión para recordar la corona como una corona de piña correctamente identificada y alta especificidad para confirmar que la imagen de ruido de fondo se identifique correctamente como ruido de fondo. Además, el rendimiento de la clasificación se optimizó con la selección de características de ANOVA y dio como resultado un incremento del 2,94 % en el rendimiento de la clasificación.

Por lo tanto, el proceso de selección de características para eliminar características no informativas y seleccionar características importantes podría mejorar la precisión de la clasificación. Sin embargo, otros clasificadores siguen una tendencia de mayor rendimiento en alta precisión para recuperar la corona como una corona de piña correctamente identificada y alta especificidad para confirmar que la imagen de ruido de fondo se identifica correctamente como ruido de fondo. Además, el rendimiento de la clasificación se optimizó con la selección de características de ANOVA y dio como resultado un incremento del 2,94 % en el rendimiento de la clasificación. Por lo tanto, el proceso de selección de características para eliminar características no informativas y seleccionar características importantes podría mejorar la precisión de la clasificación. Sin embargo, otros clasificadores siguen una tendencia de mayor rendimiento en alta precisión para recuperar la corona como una corona de piña correctamente identificada y alta especificidad para confirmar que la imagen de ruido de fondo se identifica correctamente como ruido de fondo.

Además, el rendimiento de la clasificación se optimizó con la selección de características de ANOVA y dio como resultado un incremento del 2,94 % en el rendimiento de la clasificación. Por lo tanto, el proceso de selección de características para eliminar características no informativas y seleccionar características importantes podría mejorar la precisión de la clasificación. Sin embargo, otros clasificadores siguen una tendencia de mayor rendimiento en el rendimiento de la clasificación se optimizó con la selección de características de ANOVA y dio como resultado un incremento del 2,94 % en el rendimiento de la clasificación. Por lo tanto, el proceso de selección de características

para eliminar características no informativas y seleccionar características importantes podría mejorar la precisión de la clasificación. Sin embargo, otros clasificadores siguen una tendencia de mayor rendimiento en el rendimiento de la clasificación se optimizó con la selección de características de ANOVA y dio como resultado un incremento del 2,94 % en el rendimiento de la clasificación.

Por lo anterior, el proceso de selección de características para eliminar características no informativas y seleccionar características importantes podría mejorar la precisión de la clasificación. Sin embargo, otros clasificadores siguen una tendencia de mayor rendimiento en el clasificador KNN se optimizará con ANOVA, excepto para DT, NB, SVM y RF, lo que puede deberse a la arquitectura de la red, la función de entrenamiento y su tasa de aprendizaje, que pudo segregarse entre la corona de piña y el ruido de fondo. Esto se puede observar en el clasificador SVM cuadrático que pudo demostrar un rendimiento comparable al de ANN-GDX sin realizar la selección de características con ANOVA.

Tabla 1 Comparación de métricas de rendimiento para la clasificación entre diferentes funciones de entrenamiento y selección de características con y sin ANOVA unidireccional en datos de prueba.

Tipo de clasificador	Función de entrenamiento	Sin ANOVA unidireccional				Con ANOVA unidireccional			
		anterior (%)	ESP (%)	Sen (%)	Cuenta (%)	anterior (%)	ESP (%)	Sen (%)	Cuenta (%)
ANA	LM	90.8	88.2	87.8	89.44	88.89	88.89	88.89	88,9
	SCG	88.4	92,9	93.3	90.56	91.2	92.1	92.2	91.7
	GDX	90.3	93.1	93.3	91.70	92.6	96.5	96.7	94.4
	PR	86.6	92.77	93.3	89.14	95.4	92.47	92.2	93,9
DT	Buen árbol	90,0	92.2	92.0	91.1	91.1	84.4	85.42	87.8
	Árbol mediano	90,0	92.2	92.0	91.1	91.1	84.4	85.42	87.8

Tipo de clasificador	Función de entrenamiento	Sin ANOVA unidireccional				Con ANOVA unidireccional			
		anterior (%)	ESP (%)	Sen (%)	Cuenta (%)	anterior (%)	ESP (%)	Sen (%)	Cuenta (%)
	Árbol grueso	90,0	93.3	93.1	91.7	91.1	76.7	79.62	83,9
bayesian a ingenua	Bayesian o ingenuo gaussiano	90,0	91.1	91.0	90,6	91.1	87.8	88.17	89.4
	Núcleo bayesian o ingenuo	91.1	92.2	92.1	91.7	93.3	87.8	88.42	90,6
MVS	MVS lineal	91.1	93.3	93.2	92.2	98.9	85.6	87.25	92.2
	SVM cuadrática	90,0	96.7	96.4	93.3	95.6	85.6	86,9	90,6
	SVM cúbico	88,9	95.6	95.2	92.2	95.6	87.8	88.7	91.7
	SVM gaussiano fina	72.2	100.0	100.0	86.1	70.0	100.0	100.0	85.0
	SVM gaussiano media	90,0	95.6	95.3	92.8	93.3	88,9	89.4	91.1
	SVM gaussiano gruesa	93.3	91.1	91.3	92.2	97.8	84.4	86.3	91.1

Tipo de clasificador	Función de entrenamiento	Sin ANOVA unidireccional				Con ANOVA unidireccional			
		anterior (%)	ESP (%)	Sen (%)	Cuenta (%)	anterior (%)	ESP (%)	Sen (%)	Cuenta (%)
KNN	Bien KNN	92.2	92.2	92.2	92.2	94.4	90	90.4	92.2
	KNN medio	96.7	86.7	87,9	91.7	96.7	82.2	84.5	89.4
	KNN grueso	100.0	45.6	64.7	72.8	100.0	38,9	62.1	69.4
	Coseno KNN	91.1	91.1	91.1	91.1	94.4	88,9	89.5	91.7
	KNN cúbico	96.7	83.3	85.3	90,0	97.8	76.7	80.7	87.2
	KNN ponderado	94.4	92.2	92.4	93.3	95.6	84.4	86,0	90,0
RF	árboles embolsados	94.4	93.3	93.4	91.7	84.4	91.0	90.5	87.8

Pre = Precisión; Spe = Especificidad; Sen = Sensibilidad; Acc = Precisión.

La comparación detallada entre parámetros métricos en algoritmos de aprendizaje ANN se extrajo de la matriz de confusión como una medida del rendimiento de la clasificación utilizando ANOVA de una vía para piña y ruido de fondo. Como se discutió anteriormente, el número TP representa las imágenes que se clasifican correctamente como corona de piña, TN representa el número de imágenes clasificadas incorrectamente como corona de piña, o en otras palabras, que se detectan como ruido de fondo, FP se clasifica incorrectamente como corona de piña y FN es incorrectamente clasificado como ruido de fondo. Los parámetros métricos se registraron en números de imágenes. Durante la fase de entrenamiento, ANN-LM sin y con selección de características es TP = 90, TN = 84, FP = 0, FN = 6 y TP = 90, TN = 87, FP = 3, FN = 0.

ANN-SCG para ambos sin y con selección de funciones es TP = 89, TN = 89, FP = 1, FN = 1 y TP = 85, TN = 81, FP = 5, FN = 9. ANN-RP tanto para sin como con selección de funciones es TP = 90, TN = 89, FP = 0, FN = 1 y TP = 84,

Durante la fase de prueba, se realizaron las métricas de rendimiento para la clasificación entre diferentes funciones de entrenamiento y con/sin ANOVA unidireccional de corona de piña y el conjunto de datos de ruido. El valor de toda la matriz de confusión para ANN-LM con y sin selección de características es TP = 79, TN = 82, FP = 8, FN = 11 y TP = 80, TN = 80, FP = 10, FN = 10. ANN -SCG con y sin selección de funciones es TP = 84, TN = 79, FP = 11, FN = 6 y TP = 83, TN = 82, FP = 8, FN = 7. ANN-RP tanto para sin como con la selección de funciones es TP = 84, TN = 77, FP = 13, FN = 6 y TP = 83, TN = 86, FP = 4, FN = 7. ANN-GDX tanto con como sin selección de funciones es TP = 84, TN = 81, FP = 9, FN = 6 y TP = 87, TN = 83, FP = 7, FN = 3. (figura 7). El enfoque desarrollado utilizando perceptrón multicapa sin/con selección de características (ver Fig. 8) indica que la precisión de ANN-GDX alcanzó el porcentaje máximo de rendimiento general, lo que indica que el clasificador es más sensible y preciso en comparación con los algoritmos ANN-LM, ANN-SCG y ANN-RP. Comparables con otros algoritmos, los valores ANN-GDX son sensibles y precisos, de modo que se ha logrado un 94,4 % de precisión, un 92,6 % de precisión, un 96,5 % de especificidad y un 96,7 % de sensibilidad. Mientras tanto, el rendimiento de la precisión revela que el algoritmo ANN-RP logra un alto valor en los parámetros de precisión del conjunto de datos en comparación con todos los algoritmos. Diferentes algoritmos de entrenamiento demostraron que las métricas de rendimiento varían, sin embargo, la selección de mayor precisión es la más preferible para indicar la capacidad del clasificador de clasificar con precisión entre la corona de piña y el ruido de fondo.

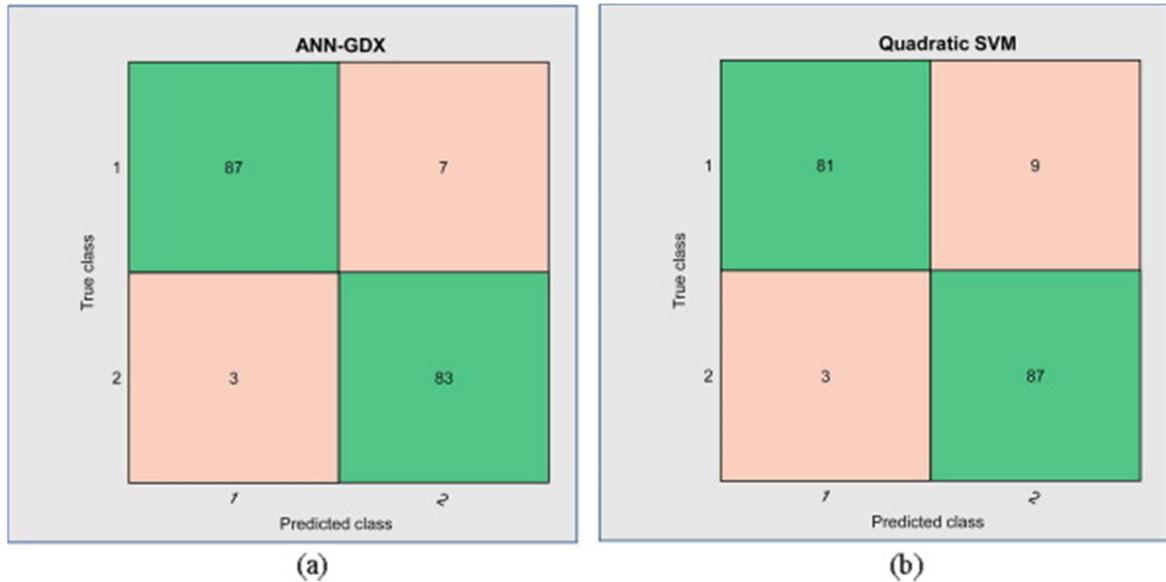


Figura 7 Métricas de confusión para demostrar la capacidad de clasificación utilizando el clasificador de aprendizaje automático más preciso (a) clasificador ANN-GDX; notación de 1 = piña, 2 = ruido y (b) clasificador SVM cuadrático; notación de 1 = piña, 2 = r

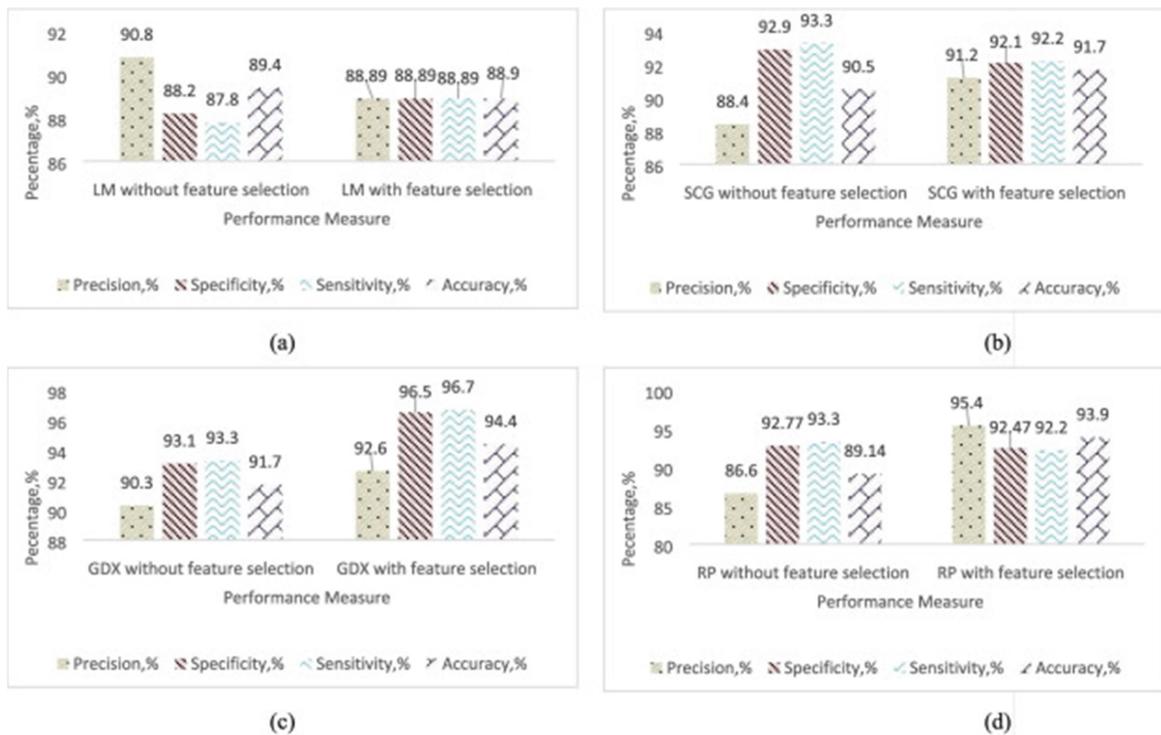


Figura 8 Rendimiento de comparación entre clasificadores con varias funciones de entrenamiento (a) ANN-LM (b) ANN-SCG (c) ANN-GDX y (d) algoritmos de prueba ANN-RP.

Para el recuento de rendimiento, se compara con el total exacto de piñas detectadas en el procesamiento de imágenes desde el cuadro delimitador. Se comparó la comparación entre el conteo manual y el conteo automatizado por clasificador para probar la capacidad de aprendizaje de los algoritmos propuestos. La Fig. 9 muestra los resultados de la medida de rendimiento del conteo de frutas para algoritmos de función de entrenamiento general y muestra los resultados detallados del experimento con y sin implementación de la selección de características de ANOVA. Durante el experimento se registró el número total exacto de coronas de piña y el ruido de fondo. El conteo automático de frutas se tuvo en cuenta en el caso de que la detección del número total de corona de piña utilizando el aprendizaje automático haya clasificado con éxito la corona de piña. Se comparó la comparación entre el conteo automático y el conteo manual en el que la selección de la función de entrenamiento del clasificador se selecciona de tal manera que la imagen real del terreno calculada durante el conteo automático es la más cercana al conteo manual.

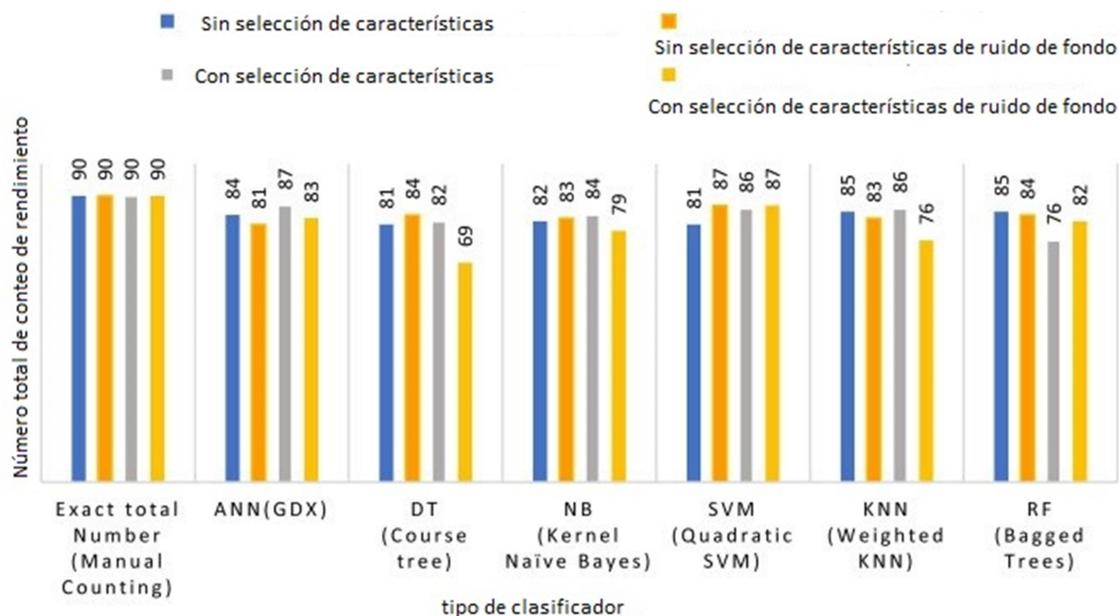


Figura 9 La comparación del conteo de rendimiento de la corona de piña entre el conteo manual y el conteo automático utilizando el aprendizaje automático.

El enfoque de conteo automático desarrollado usando ANN-GDX con selección de funciones ANOVA indica que el mayor número de imágenes de detección, 87/90, se puede contar como corona de piña. Similar a Quadratic SVM, el número comparable de

corona de piña y ruido de fondo podría contarse en 86/90 y 87/90 respectivamente. Sin embargo, el peor algoritmo de conteo demostró que los algoritmos de aprendizaje de RF y DT no eran adecuados para el algoritmo de conteo debido a la baja capacidad para producir un conteo preciso (exactamente 76/90 y 69/90 respectivamente para piña y ruido de fondo). Como resultado, las imágenes RGB se pueden procesar y computar como conteo automático de frutas basado en imágenes aéreas con UAV y se muestra como método efectivo con 87/90 de detección correcta de corona de piña. El procesamiento de imágenes digitales al resaltar la funcionalidad y la capacidad de detección precisa puede verse como un método alternativo para automatizar el proceso de conteo de la fruta antes de la cosecha.

3. Conclusiones y recomendaciones

3.1. Conclusiones

Se utilizó un sistema con dron DJI Mavic 2 Zoom y software MATLAB para el reconocimiento, detección y conteo automático de cultivos en tiempo real de piñas utilizando enfoques de aprendizaje automático. El conteo de densidad de la piña en el área seleccionada se determina en tiempo real. Este estudio propone un método de procesamiento de imágenes y aprendizaje automático para detectar y contar con precisión la corona de la piña. El método propuesto consta de varios pasos.

En primer lugar, mejore la imagen de datos para mejorar la calidad y detectar la corona de piña mediante operaciones morfológicas. En segundo lugar, extraiga las características de color, forma y textura como entrada en el clasificador de aprendizaje automático para clasificar entre la corona de piña y el ruido de fondo, como hojas, hierba y suelo. La optimización con ANOVA tiene como objetivo mejorar aún más el rendimiento de la clasificación y, por último, las frutas de piña en función de su corona detectada a través del algoritmo de conteo automático deben contarse para mostrar el rendimiento de la piña en el que se confirma la viabilidad del método con pruebas de imágenes no vistas y la capacidad de superar El problema de la iluminación y la oclusión variadas debido al ruido de fondo.

El algoritmo de aprendizaje automático ANN-GDX da como resultado una precisión de hasta el 94,4 % como la mejor clasificación en comparación con otros algoritmos clasificadores. La extensión futura se centraría en mejorar la detección robusta para eliminar el ruido y aumentar el conteo con precisión al aumentar más características para evaluar y proporcionar una decisión de clasificación más precisa.

3.2. Recomendaciones

Es importante revisar la forma en la que se realiza el procedimiento de filtrado de piña capturado a partir de imágenes aéreas, ya que a la hora de capturar diversas imágenes en horarios distintos genera desde la concepción de las mismas imágenes diferencias e incremento de dificultades a la hora de realizar el procesamiento, por lo tanto, se requiere más trabajo para mejorar la precisión de detección en altitudes más altas con una mayor robustez para compensar las diferentes condiciones climáticas.

Bibliografía

- Al-Zebari, A., & Sengur, A. (2019). Performance comparison of machine learning techniques on diabetes disease detection. *2019 1st International Informatics and Software Engineering Conference (UBMYK)*, 1–4.
- Alzu'bi, R., Anushya, A., Hamed, E., Al Sha'ar, E. A., & Vincy, B. S. A. (2018). Dates fruits classification using SVM. *AIP Conference Proceedings*, 1952(1), 20078.
- Anitha, P., & Chakravarthy, T. (2018). Agricultural Crop Yield Prediction using Artificial Neural Network with Feed Forward Algorithm. *International Journal of Computer Sciences and Engineering*, 6(11), 178–181.
<https://doi.org/10.26438/ijcse/v6i11.178181>
- Arowolo, M. O., Abdulsalam, S. O., Saheed, Y. K., & Salawu, M. D. (2016). A feature selection based on one-way-ANOVA for microarray data classification. *Al-Hikmah J Pure Appl Sci*, 3, 30–35.
- Babikir, H. A., Elaziz, M. A., Elsheikh, A. H., Showaib, E. A., Elhadary, M., Wu, D., & Liu, Y. (2019). Noise prediction of axial piston pump based on different valve materials using a modified artificial neural network model. *Alexandria Engineering Journal*, 58(3), 1077–1087. <https://doi.org/10.1016/j.aej.2019.09.010>
- Basso, M., & Pignaton de Freitas, E. (2020). A UAV Guidance System Using Crop Row Detection and Line Follower Algorithms. *Journal of Intelligent & Robotic Systems*, 97(3), 605–621. <https://doi.org/10.1007/s10846-019-01006-0>
- Berrar, D. (2018). Bayes' theorem and naive Bayes classifier. *Encyclopedia of Bioinformatics and Computational Biology: ABC of Bioinformatics*, 403.
- Blok, P. M., Barth, R., & van den Berg, W. (2016). Machine vision for a selective broccoli harvesting robot. *IFAC-PapersOnLine*, 49(16), 66–71.
<https://doi.org/https://doi.org/10.1016/j.ifacol.2016.10.013>
- Calou, V. B. C., Teixeira, A. dos S., Moreira, L. C. J., Lima, C. S., de Oliveira, J. B., & de Oliveira, M. R. R. (2020). The use of UAVs in monitoring yellow sigatoka in banana. *Biosystems Engineering*, 193, 115–125.
<https://doi.org/https://doi.org/10.1016/j.biosystemseng.2020.02.016>
- Dhalia Sweetlin, J., Nehemiah, H. K., & Kannan, A. (2018). Computer aided diagnosis of pulmonary hamartoma from CT scan images using ant colony optimization based

- feature selection. *Alexandria Engineering Journal*, 57(3), 1557–1567.
<https://doi.org/https://doi.org/10.1016/j.aej.2017.04.014>
- Diago, M. P., Aquino, A., Millán, B., Palacios, F., & Tardaguila, J. (2019). *On-the-go assessment of vineyard canopy porosity, bunch and leaf exposure by image analysis*.
- Dobbels, A. A., & Lorenz, A. J. (2019). Soybean iron deficiency chlorosis high-throughput phenotyping using an unmanned aircraft system. *Plant Methods*, 15(1), 97.
<https://doi.org/10.1186/s13007-019-0478-9>
- Ebtehaj, I., Bonakdari, H., & Zaji, A. H. (2018). A new hybrid decision tree method based on two artificial neural networks for predicting sediment transport in clean pipes. *Alexandria Engineering Journal*, 57(3), 1783–1795.
<https://doi.org/10.1016/j.aej.2017.05.021>
- Elhariri, E., El-Bendary, N., Hassanien, A. E., Badr, A., Hussein, A. M. M., & Snášel, V. (2014). Random forests based classification for crops ripeness stages. *Proceedings of the Fifth International Conference on Innovations in Bio-Inspired Computing and Applications IBICA 2014*, 205–215.
- Feng, D., Xu, W., He, Z., Zhao, W., & Yang, M. (2020). Advances in plant nutrition diagnosis based on remote sensing and computer application. *Neural Computing and Applications*, 32(22), 16833–16842. <https://doi.org/10.1007/s00521-018-3932-0>
- Gutiérrez, S., Tardaguila, J., Fernández-Novales, J., & Diago, M. P. (2019). On-the-go hyperspectral imaging for the in-field estimation of grape berry soluble solids and anthocyanin concentration. *Australian Journal of Grape and Wine Research*, 25(1), 127–133. <https://doi.org/https://doi.org/10.1111/ajgw.12376>
- Kicherer, A., Klodt, M., Sharifzadeh, S., Cremers, D., Töpfer, R., & Herzog, K. (2017). Automatic image-based determination of pruning mass as a determinant for yield potential in grapevine management and breeding. *Australian Journal of Grape and Wine Research*, 23(1), 120–124. <https://doi.org/https://doi.org/10.1111/ajgw.12243>
- Lang, Q., Zhiyong, Z., Longsheng, C., Hong, S., Minzan, L., Li, L., & Junyong, M. (2019). Detection of Chlorophyll Content in Maize Canopy from UAV Imagery. *IFAC-PapersOnLine*, 52(30), 330–335.
<https://doi.org/https://doi.org/10.1016/j.ifacol.2019.12.561>
- Li, B., Xu, X., Han, J., Zhang, L., Bian, C., Jin, L., & Liu, J. (2019). The estimation of crop emergence in potatoes by UAV RGB imagery. *Plant Methods*, 15(1), 1–13.
<https://doi.org/10.1186/s13007-019-0399-7>

- Maldonado, W., & Barbosa, J. C. (2016). Automatic green fruit counting in orange trees using digital images. *Computers and Electronics in Agriculture*, *127*, 572–581. <https://doi.org/https://doi.org/10.1016/j.compag.2016.07.023>
- Marques Ramos, A. P., Prado Osco, L., Elis Garcia Furuya, D., Nunes Gonçalves, W., Cordeiro Santana, D., Pereira Ribeiro Teodoro, L., Antonio da Silva Junior, C., Fernando Capristo-Silva, G., Li, J., Henrique Rojo Baio, F., Marcato Junior, J., Eduardo Teodoro, P., & Pistori, H. (2020). A random forest ranking approach to predict yield in maize with uav-based vegetation spectral indices. *Computers and Electronics in Agriculture*, *178*, 105791. <https://doi.org/https://doi.org/10.1016/j.compag.2020.105791>
- MathWorks. (2022). *MATLAB - El lenguaje del cálculo técnico - MATLAB & Simulink*. <https://la.mathworks.com/products/matlab.html>
- Miranda, J. da R., Alves, M. de C., Pozza, E. A., & Santos Neto, H. (2020). Detection of coffee berry necrosis by digital image processing of landsat 8 oli satellite imagery. *International Journal of Applied Earth Observation and Geoinformation*, *85*, 101983. <https://doi.org/https://doi.org/10.1016/j.jag.2019.101983>
- Miriti, E. (2016). *Classification of selected apple fruit varieties using Naive Bayes*. University of Nairobi.
- Panda, M. (2020). Elephant search optimization combined with deep neural network for microarray data analysis. *Journal of King Saud University-Computer and Information Sciences*, *32*(8), 940–948.
- Rahimi, W. N. S., Asraf H, M., & Ali, M. S. A. M. (2020). Ananas comosus crown image thresholding and crop counting using a colour space transformation scheme. *Telkomnika (Telecommunication Computing Electronics and Control)*, *18*(5), 2472–2479. <https://doi.org/10.12928/TELKOMNIKA.v18i5.13895>
- Roy, P., Kislav, A., Plonski, P. A., Luby, J., & Isler, V. (2019). Vision-based preharvest yield mapping for apple orchards. *Computers and Electronics in Agriculture*, *164*, 104897. <https://doi.org/https://doi.org/10.1016/j.compag.2019.104897>
- Schirrmann, M., Giebel, A., Gleiniger, F., Pflanz, M., Lentschke, J., & Dammer, K. H. (2016). Monitoring agronomic parameters of winter wheat crops with low-cost UAV imagery. *Remote Sensing*, *8*(9). <https://doi.org/10.3390/rs8090706>
- Schwalbert, R. A., Amado, T., Corassa, G., Pott, L. P., Prasad, P. V. V., & Ciampitti, I. A.

- (2020). Satellite-based soybean yield forecast: Integrating machine learning and weather data for improving crop yield prediction in southern Brazil. *Agricultural and Forest Meteorology*, 284, 107886.
<https://doi.org/https://doi.org/10.1016/j.agrformet.2019.107886>
- Sree Vidya, B., & Chandra, E. (2019). Entropy based Local Binary Pattern (ELBP) feature extraction technique of multimodal biometrics as defence mechanism for cloud storage. *Alexandria Engineering Journal*, 58(1), 103–114.
<https://doi.org/https://doi.org/10.1016/j.aej.2018.12.008>
- Sun, S., Li, C., Paterson, A. H., Chee, P. W., & Robertson, J. S. (2019). Image processing algorithms for infield single cotton boll counting and yield prediction. *Computers and Electronics in Agriculture*, 166, 104976.
<https://doi.org/https://doi.org/10.1016/j.compag.2019.104976>
- Vallabhaneni, R. B., & Rajesh, V. (2018). Brain tumour detection using mean shift clustering and GLCM features with edge adaptive total variation denoising technique. *Alexandria Engineering Journal*, 57(4), 2387–2392.
<https://doi.org/10.1016/j.aej.2017.09.011>
- Wendel, A., Underwood, J., & Walsh, K. (2018). Maturity estimation of mangoes using hyperspectral imaging from a ground based mobile platform. *Computers and Electronics in Agriculture*, 155, 298–313.
<https://doi.org/https://doi.org/10.1016/j.compag.2018.10.021>
- Zhou, J., Khot, L. R., Boydston, R. A., Miklas, P. N., & Porter, L. (2018). Low altitude remote sensing technologies for crop stress monitoring: a case study on spatial and temporal monitoring of irrigated pinto bean. *Precision Agriculture*, 19(3), 555–569.
<https://doi.org/10.1007/s11119-017-9539-0>