

Sistema inteligente para el manejo de malezas en el cultivo de piña con conceptos de agricultura de precisión

ISSN 0122-8420
eISSN 2539-0899

Fecha de recepción: 05 de marzo de 2020

Fecha de aceptación: 04 de junio de 2020

Andrés F. Jiménez López • 1
Diana Andrea Camargo Pico • 2
Dayra Yisel García Ramírez • 3DOI: <https://doi.org/10.19053/01228420.v17.n3.2020.10830>

Resumen

La agricultura de precisión busca la aplicación de insumos en cultivos agrícolas en el lugar, el momento y la cantidad adecuados. El manejo de malezas específico del sitio es una estrategia de agricultura de precisión que permite la reducción en la aplicación de herbicidas, minimizando costos de insumos, con efectos positivos para el medioambiente. El objetivo de este artículo es mostrar los avances en el desarrollo de un sistema inteligente para la detección de malezas y aplicación de herbicida en un cultivo de piña con conceptos de agricultura de precisión. El prototipo utiliza un sistema de visión artificial para la adquisición de la reflectancia en las plantas en el espectro del visible y un sistema embebido que permite el procesamiento de las imágenes en tiempo real como mecanismo de detección de maleza. El prototipo cuenta con un sistema de fumigación automático, el cual emula la aplicación del herbicida selectivo; lo que en conjunto es implementado sobre un vehículo terrestre que realiza su recorrido entre los surcos de un cultivo de piña. El algoritmo de detección de malezas para el cultivo de piña tuvo una eficiencia de más del 80 %, obteniendo así resultados satisfactorios y el cumplimiento de requerimiento para la detección y aplicación de insumo solo en los lugares en donde se necesita.

Palabras clave: agricultura de precisión, cultivo agrícola, malezas, sistema de detección, piña.

Intelligent System for Weeds Management in Pineapple Crop with Precision Agriculture Concepts

Abstract

The aim of precision agriculture is to apply agricultural inputs in the right place, time and amount. The site-specific weed management is a precision agriculture strategy that allows reducing the herbicide application, minimizing inputs costs, with positive effects for the environment. The objective of this paper is to show the advances in the development of weed detection and herbicide application system for a pineapple crop, using precision agriculture concepts. The prototype uses an artificial vision system for acquisition of reflectance in plants in the visible spectrum and an embedded system that allows the image processing in real-time as a weed detection mechanism. The prototype has an automatic fumigation system, that emulates the selective herbicide application, which together is implemented above a terrestrial vehicle that travels into the pineapple crop rows. The weed detection algorithm for pineapple had an efficiency major than 80%, obtaining satisfactory outcomes and the fulfilment of the requirements for the weed detection and input application only in the places where it is necessary.

Keywords: precision agriculture, agricultural crop, weed, detection system, pineapple.

- 1 MSc. Universidad de los Llanos. Facultad de Ciencias Básicas e Ingeniería. Departamento de Matemáticas y Física. Grupo de Investigación Macrypt. Villavicencio, Colombia. Universidad Nacional de Colombia. Ingeniería Mecánica-Mecatrónica. Bogotá Colombia. ajimenez@unillanos.edu.co <https://orcid.org/0000-0001-8308-7815>
- 2 I.E. Universidad Nacional Abierta y a Distancia, Leticia, Colombia, diana.camargo@unad.edu.co <https://orcid.org/0000-0003-0909-525X>
- 3 MSc. Universidad de los Llanos. Facultad de Ciencias Agropecuarias y Recursos Naturales. Grupo de Investigación A.P. Villavicencio, Colombia. dgarcia@unillanos.edu.co <https://orcid.org/0000-0002-2501-4842>

I. Introducción

La infestación de malezas ha sido estimada como un factor causante de la disminución en el rendimiento de los cultivos, que representa pérdidas económicas (Abouzahir et al., 2018). Estas afectaciones se producen al emerger las malezas dentro de la línea de siembra, compitiendo con la planta por los nutrientes, el agua y la luz del sol, durante su etapa de crecimiento. Las grandes dosis de herbicida y la resistencia de las malas hierbas constituyen un problema serio en la agricultura mundial, lo que provoca que el uso de agroquímicos sin control tenga efectos negativos, entre los que destacan el gasto innecesario de herbicida (pérdida económica), el daño medioambiental (contaminación del suelo y aguas subterráneas), y las trazas de agroquímicos en los alimentos (afectan la salud y seguridad alimentaria) (Jaramillo-Colorado et al., 2016; Bastidas et al., 2013).

La forma convencional de controlar las malezas es por exploración manual, siempre que sea posible, o el rocío de herbicidas uniformemente en todo el campo para mantenerlas bajo control. Esta última técnica es muy ineficiente, ya que solo el 20 % de la pulverización llega a la planta y menos del 1 % del químico contribuye realmente al control de malezas, obteniendo desperdicios, contaminación del medioambiente o sobredosificación que incrementa la probabilidad de encontrar trazas de agroquímicos en el fruto por encima de los límites permisibles y que pueden afectar la salud humana (Reyes et al., 2016). El manejo tecnificado de malezas en los cultivos de hileras se realiza aplicando herbicidas de forma mecánica o manual. Los sistemas mecánicos generalmente son eficaces en la eliminación de los malezas que crecen entre hileras de cultivo, pero no dentro de la línea de siembra (Utstumo et al., 2018). Como consecuencia se necesita usar mano de obra para la eliminación de hierbas muy cerca de las plantas, lo que puede llegar a ser más costoso que el procedimiento mecánico y no ser completamente eficaz.

Desde finales del siglo XX, la aplicación colectiva de nuevas tecnologías ha mejorado las prácticas de gestión de la agricultura y ha dado lugar al campo de la agricultura de precisión (PA) (Di Cicco et al., 2017). Estas tecnologías se fundamentan en el manejo de los recursos de manera más eficiente, teniendo en cuenta las condiciones ambientales y las necesidades reales de las plantas. La AP vincula estrategias de adquisición y análisis de información en campo y la aplicación de insumos de acuerdo con parámetros establecidos mediante sistemas inteligentes, en donde un aspecto principal es el manejo específico por sitio para una producción optimizada y eficiente de cultivos de campo. El manejo específico de malezas con conceptos de agricultura de precisión busca aplicar el herbicida en el lugar, la cantidad y el momento adecuados, para mejorar la productividad, reducir el desperdicio de insumos, sin afectar al medioambiente (Gee et al., 2008). Para lograr este propósito se implementan sistemas de control de malezas, en donde los sistemas robóticos juegan un papel fundamental (Lottes et al., 2016). Estos sistemas deben ser capaces de localizar malezas en el campo y usar pulverizadores de herbicidas que dirigen su aplicación directamente sobre ellas.

Las técnicas de tratamiento digital de imágenes se han usado para identificar especies vegetales y comportamiento fenológico de las plantas como una de las herramientas de la AP (Sandino & González, 2018). Los sistemas de determinación de la distribución espacial de las malezas han sido implementados usando cámaras multispectrales a bordo de aeronaves (Barrero et al., 2016) o a escala de campo (Rehman et al., 2019). La detección de malezas en las imágenes usando la caracterización de forma y ubicación de los surcos del cultivo permite determinar el tipo y el número de malezas por imagen (Agrawal et al., 2012). El crecimiento de malezas ocurre de forma no uniforme, pero estas se dan naturalmente agrupadas; es decir, pueden crecer en (o entre) las filas del cultivo. La detección de las malas hierbas puede ser rápida y precisa si se separa del suelo; este método puede resolver los problemas técnicos para la aplicación precisa de los pesticidas usando vehículos terrestres de navegación automatizada (Wang et al., 2019).

La clasificación de vegetación ha sido estudiada en diversas regiones del espectro del visible e infrarrojo (Siddiqi et al., 2009), junto con índices de color (Abouzahir et al., 2017), índices de vegetación (Pérez-Ortiz et al., 2016) y técnicas de imágenes hiperespectrales y multispectrales (Sa et al., 2017). La mayoría de los enfoques para el control automatizado de malezas utilizan cámaras digitales RGB (Red, Green, Blue por sus siglas en inglés) para detectar plantas (Zheng et al., 2017). En el caso del análisis multispectral por medio de la adquisición de imágenes del visible y el infrarrojo, se reporta en la literatura el uso de cámaras biespectrales, compuestas por dos cabezas de cámara monocromáticas, que permiten obtener dos imágenes congruentes de píxeles de cualquier escena en diferentes bandas espectrales. Existen otros enfoques que utilizan sensores de imágenes hiperespectrales (Farooq et al., 2018), lidars 3D (Light Detection and Ranging o Laser Imaging Detection and Ranging, por sus siglas en inglés), los sistemas de caracterización de la superficie 3D para la discriminación de cultivos-malezas y conceptos de fusión con sensores múltiples (Zhang & Wei, 2019).

En general, la detección y la clasificación de malas hierbas se basan en los principales pasos del tratamiento digital de imágenes: adquisición, segmentación, extracción de características y clasificación (Wang et al., 2019). Para este último procedimiento se recopilan imágenes, se clasifican y etiquetan como plantas o malas hierbas por un usuario, para luego usar estas características para formar clasificadores basados en estadística o aprendizaje de máquina. Típicamente, el tamaño del conjunto de entrenamiento debe estar en el rango de cientos o miles de muestras de referencia etiquetadas para obtener un clasificador significativo (Wagstaff & Liu, 2018). Las técnicas de procesamiento basadas en inteligencia artificial han sido empleadas para la detección de malezas y la clasificación entre suelo, cultivo y maleza. Como ejemplo de estas técnicas se encuentran las redes neuronales artificiales (RNA) (Potena et al., 2016) árboles de decisión (AD) (Lottes et al., 2018), la clasificación basada en *wavelets*, algoritmos genéticos, máquinas de soporte vectorial (MSV) (Bakhshipour & Jafari, 2018) y algoritmos basados en lógica difusa (Yang et al., 2003).

La piña, cultivada en hileras, es una de las frutas más sembradas en los Llanos Orientales colombianos, y el control de malezas, al igual que en otros cultivos, es parte esencial de su producción, pues además de estropear su crecimiento, algunas de estas malezas con semilla pueden contaminar la corona de la piña, lo que implica el aumento de utilización de tratamientos curativos, hecho que perjudica la economía del agricultor (Segura, 2015). Por otra parte, el uso de herbicidas para el control de malezas en piña, con excepción del quizalofop, como parte de un paquete tecnológico con varias décadas de uso en otros lugares, ha sido adoptado sin cuestionamiento en los agroecosistemas piñeros nacionales. Esto conlleva la necesidad de crear nuevas alternativas de control de malezas, en el marco de un manejo integrado, sostenible y amigable con el medioambiente.

El objetivo principal de esta investigación fue desarrollar un sistema prototipo capaz de detectar mediante visión artificial y procesamiento digital de imágenes, la presencia de malezas en las líneas de un cultivo de piña, y emular la aplicación de herbicida a cada planta que lo requiera, con el fin de evitar el uso excesivo de herbicidas; lo cual mitiga el impacto medioambiental, previene accidentes laborales por la aplicación de estos, y aumenta la productividad económica al ahorrar insumos. Este artículo se enfoca en el algoritmo de detección de malezas por medio de técnicas de procesamiento de imágenes.

II. Metodología

A. Descripción del campo de estudio y cultivo estudiado

Los datos usados en este estudio corresponden a un cultivo de piña de 50.000 plantas/ha, localizado en la vereda Barcelona, en el municipio de Villavicencio, Meta, Colombia (4.081950° N, 73.578567° W; elevación 467 msnm; 7 ha) durante el año 2017, como se aprecia en la Figura 1. La precipitación media anual es de 273 mm, el periodo de lluvias frecuentes ocurre durante los 31 días centrados en mayo, con una acumulación total de 137.16 mm. Las temperaturas mínimas y máximas son 20 °C y 32 °C, respectivamente (Weatherspark.com, 2019).




Figura 1. Área de estudio. Campo de cultivo de piña, vereda Barcelona

Fuente Villavicencio, Meta, Colombia

El cultivo fue sembrado a una densidad de 50.000 plantas/ha, en hileras dobles, con 40 cm entre ellas y 30 cm entre plantas, con distancia entre doble hilera de 90 cm, como se aprecia en la Figura 2. La variedad de la piña fue el clon MD2 o Gold.




Figura 2. Diagrama de siembra de piñas en hileras dobles para una densidad de 50.000 plantas/ha.

En el cultivo de piña nacen malezas de hoja ancha o angosta, dependiendo de la región y la maquinaria usada. El control de la maleza comienza en la preparación de la tierra, etapa en la que se destruyen totalmente residuos, se desmenuzan terrones y se busca que el suelo esté en condiciones adecuadas de humedad para aplicar una película de herbicida preemergente por un período de dos meses o más (Brenes-Prendas & Agüero-Alvarado, 2007). Los herbicidas deben ser usados cuando la maleza todavía no ha germinado o cuando tiene de dos a tres hojas. El crecimiento de la piña es lento inicialmente, con una reducida capacidad de producir sombra en los primeros meses de desarrollo, con un sistema radical poco profundo, que la hace susceptible a la competencia con las malezas. Por lo cual se resalta la importancia de eliminar las malezas durante los primeros siete a ocho meses después de la siembra; luego de ese periodo el cultivo cubre el suelo lo suficiente para crear sombra y así evitar el crecimiento de nuevas malezas (Segura, 2015).

B. Diseño e implementación del sistema

Un agente es una entidad capaz de recibir información del entorno en que se encuentra mediante mecanismos sensoriales, de procesar esta información y de actuar en este mismo entorno. Se dice que un agente es inteligente si las acciones ejecutadas en el ambiente en que se encuentra son adecuadas según la respuesta causada en el mismo (Russell & Norvig, 2016). En este artículo se describe el desarrollo de un agente inteligente para el manejo de malezas en el cultivo de piña. El agente permite adquirir información de la reflectancia de las plantas en el espectro electromagnético del visible. De acuerdo con condiciones y umbrales, se determina cuando aplicar el insumo para eliminar las malezas. En la Figura 3 se aprecia el esquema general del agente inteligente para el manejo de malezas en el cultivo de piña. El agente se desarrolló para que permita la adquisición de datos por medio de una cámara digital; además usa técnicas de visión de máquina para detectar la presencia de malezas. El agente inteligente fue realizado en un sistema embebido y controla la adquisición de información de los sensores, y de acuerdo con las condiciones medidas establece la aplicación del herbicida en tiempo real.

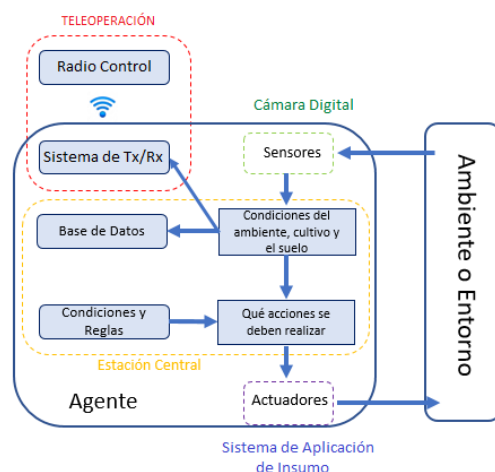


Figura 3. Diagrama esquemático del agente inteligente para el manejo de malezas en el cultivo de piña.

Para este proyecto, el sistema de detección y fumigación de malezas se implementó en un vehículo terrestre no tripulado con capacidad de recorrer el terreno entre los surcos del cultivo sin afectar las plantas cultivadas; pero que, a su vez, permitiera incorporar el sistema de medida que capture imágenes de las plantas dentro de las hileras del cultivo. Para este propósito se utilizó un vehículo a control remoto RC FORD 150 (New Bright Industrial Co., Ltd., Hong Kong, Republica de China), con dimensiones de 50x30x40cm, motor de 90 rpm, 2.5 canales (derecha/izquierda, delante/atrás), con batería de 6V, 1200mAh. Como requerimiento del sistema de detección de las malezas se especifica el uso de una cámara digital de bajo costo, con facilidad de adaptación al sistema, para lo cual se utilizó una cámara Unitec V06 5MXP-MIC (UNITEC U.S.A., Itagüí, Colombia) con zoom de 5x, interfaz USB y velocidad de transferencia de 480 Mbps. Para el control de la aplicación del insumo se utilizó un módulo relé de dos canales. Se utilizó una placa RaspberryPi 2 como sistema de procesamiento y análisis de información. En el sistema de aplicación se usó una bomba de agua dc40c-1240 de ½ con un rango de voltaje de trabajo de 5 a 12 VDC, una válvula check, además de los materiales necesarios para la construcción del tanque, conectores, conductos y otros accesorios para el sistema emulador de fumigación de insumo, lanza pulverizadora, boquilla pulverizadora metálica, conector espino a macho Bsp, ½, manguera de plástico reforzada y una manguera flexible trenzada de aluminio. El lenguaje de programación empleado en este proyecto fue Python. En la Figura 4 se aprecia el esquema general del sistema.




Figura 4. Esquema de interconexiones del sistema.

El sistema utiliza el concepto de visión artificial aplicado a la agricultura de precisión, como se aprecia en la Figura 5. La etapa de teledetección hace referencia a la adquisición de imágenes del entorno, que es realizada por la cámara digital. La etapa de procesamiento, segmentación, parametrización y clasificación se lleva a cabo por algoritmos implementados en la Raspberry Pi 2, usando el *software* en lenguaje Python y OpenCV (Bradski & Kaehler, 2008). Finalmente, en la etapa de interpretación se determina la presencia o ausencia de malas hierbas en el cultivo y el accionamiento eléctrico del sistema emulador de fumigación.

Para la protección de los componentes electrónicos de la humedad y el polvo se diseñó un encapsulado usando el *software* de modelamiento 3D, SketchUp (Trimble Inc., California, USA). La estructura fue elaborada en acrílico como material, a un grosor de 3 mm, color negro. Además, se desarrolló el encapsulado para la bomba, para que amortigüe las vibraciones causadas por el vehículo en funcionamiento. Todo el procesamiento es ejecutado por la Raspberry Pi 2. Este sistema embebido está conectado a un computador portátil mediante el protocolo wifi para la supervisión del sistema.

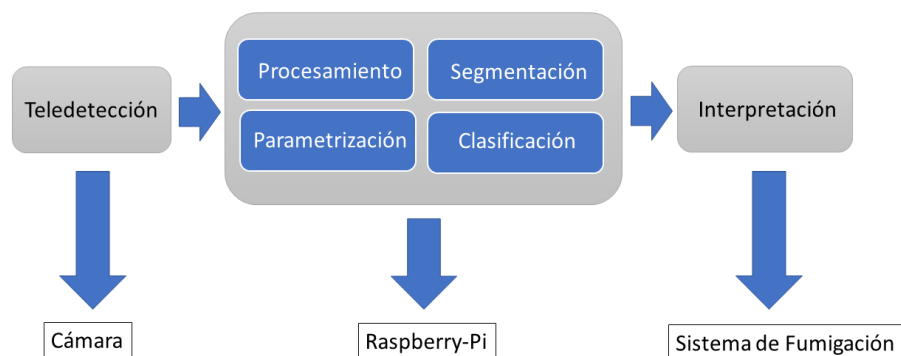


Figura 5. Diagrama descriptivo de procesos en el agente inteligente

C. Algoritmo de tratamiento de imágenes

Se capturaron 500 imágenes usando la cámara digital en el campo del cultivo de piña durante los meses de abril a julio de 2017 para diferentes horas del día, teniendo en cuenta diferentes distancias respecto a las líneas del cultivo, con diferentes condiciones ambientales, de iluminación, estado de crecimiento de las plantas, con y sin malezas. Las imágenes digitales fueron almacenadas como imágenes de 24-bits de profundidad, con una resolución de 640x480 píxeles en el modelo de color RGB (Red Green Blue) y en formato jpg. Para cada imagen se hizo la transformación del espacio de color RGB a HSV (Hue: Tono, Saturation: Saturación y Value: Valor) usando python-OpenCV, cuyos rangos corresponden a valores entre (H: 0 - 180, S: 0 – 255 y V: 0-255).

Posteriormente se llevó a cabo la segmentación y binarización de la imagen para detectar la presencia de las malezas, representada por nivel 1 (blanco), y nivel 0 (negro) para el suelo, la planta de piña y otras superficies. Finalmente se calculan los valores de los momentos de la imagen: área de la sección de la imagen con nivel de 1, para identificar la posición (x,y) de su centroide. Haciendo un estudio de esta información se encontró un umbral de área correspondiente a la presencia de malezas en el cultivo, el cual fue utilizado como elemento fundamental en la binarización, detección y como señal de encendido del sistema de aplicación de insumos. Si el valor del área de la imagen se encuentra sobre el umbral establecido, se dibuja un círculo de color rojo en la posición del centroide de los píxeles correspondientes a maleza en la imagen, como se observa en la Figura 6.

La iluminación es uno de los factores más importantes para tener en cuenta en el procesamiento de las imágenes en entornos reales en campo y, a su vez, una de las mayores dificultades (Tang et al., 2016). Un bajo nivel de iluminación causa falencias en el método de procesamiento de imagen basado en el color, haciendo que los píxeles pertenecientes a las malezas no sean detectados, o que las plantas del cultivo sean consideradas como malezas, causando errores de detección. Para asegurar la correcta adquisición de imágenes en campo, se definió un nivel de umbral de iluminación. Este umbral se utiliza antes de iniciar el sistema de detección de malezas. Cada determinado tiempo se verifica el estado de iluminación de captura; si está sobre el umbral, el vehículo continúa adquiriendo imágenes; pero, en caso contrario, el sistema detiene el proceso de detección y aplicación del insumo en campo. Como criterio de selección de umbral por imagen se hizo la conversión del espacio de color RGB a HSI (Hue: Valor, Saturation: Saturación e Intensity: Intensidad). Posteriormente se determinó el valor medio de la intensidad del conjunto de píxeles que conforman cada imagen.




Figura 6. a) Imagen con señalamiento de presencia de maleza b) Imagen binarizada.

III. Resultados y Discusión

A continuación, se hace un análisis cuantitativo y cualitativo de los resultados obtenidos en el diseño e implementación del sistema inteligente de detección y aplicación de insumo asociado a los procedimientos de adquisición, segmentación, binarización, identificación de malas hierbas y aspersion.

A. Análisis del procesamiento de imágenes

En esta sección se analizan los resultados de la aplicación de los algoritmos relacionados con el procesamiento de imágenes, es decir, segmentación, clasificación y detección. Para estudiar el comportamiento de los límites de nivel de tono, saturación y valor, se desarrolló una aplicación en Python, como se aprecia en la Figura 7. Usando esta herramienta se seleccionaron los valores para la definición de la presencia de malezas en las imágenes (Tabla 1).

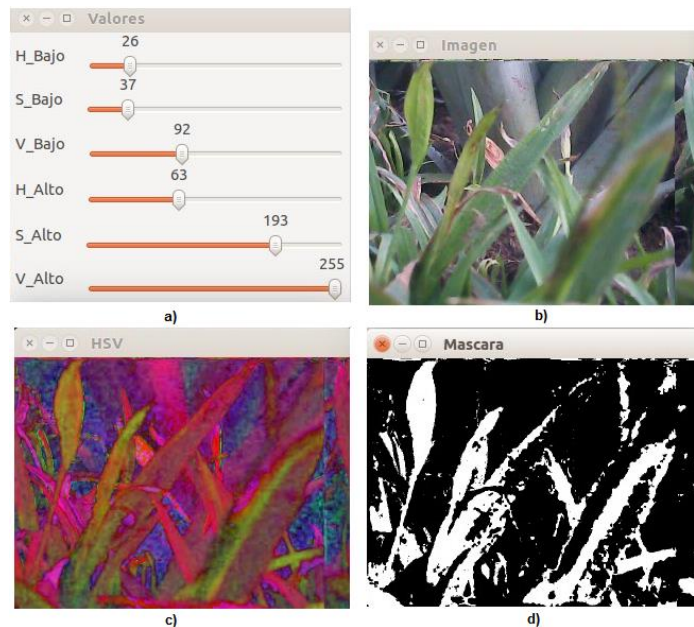


Figura 7. Aplicación en Python para encontrar los límites de color HSV. a) Slider para escoger los rangos límites. b) Imagen original. c) Imagen convertida a HSV. d) Imagen binarizada.

Tabla 1. Rangos seleccionados para la binarización de la imagen por presencia de malezas

Rango	Límite bajo			Límite alto		
	H	S	V	H	S	V
1	28	80	150	88	170	255
2	26	37	92	63	193	255
3	40	40	90	78	115	255
4	40	40	90	50	170	255

Nota: H: 0 - 180, S: 0 – 255 y V: 0-255

De acuerdo con el análisis de las imágenes adquiridas, considerando el comportamiento del procedimiento de segmentación y binarización ante la variabilidad de colores, densidad y tipos de malezas que atacan el cultivo, se seleccionó como el rango óptimo el **1**. Por otro lado, las imágenes cuyos valores de luminosidad fueron bajos, mostraron un comportamiento desfavorable ante el procesamiento. Las imágenes que se adquirieron en horas de la mañana presentaron un nivel de intensidad superior a **0.5**, mientras que las que se tomaron en horas de la tarde presentaron niveles de intensidad bajos; de forma tal que se puede considerar que el exceso de luminosidad del entorno al igual que la escasez de esta, afectan la calidad de la adquisición. En la Tabla 2 se puede observar el resultado de la clasificación de plantas con maleza y sin maleza según los niveles de intensidad para 347 imágenes seleccionadas aleatoriamente para este procedimiento.

Tabla 2. Tabla de comparación de valores de intensidad lumínica

	Plantas	Con maleza		Sin maleza	
		Detectó	No detectó	Sin detección	Detección errónea
Intensidad <0.4	39	18	12	9	0
0.4 <=Intensidad< 0.5	14	9	4	1	0
Intensidad > 0.5	294	141	39	109	5
Total	347	168	55	119	5

Para hallar el porcentaje de clasificación correcto (PCC), se aplicó la fórmula descrita en la ecuación (1).

$$PCC = \frac{VP + VN}{VP + VN + FP + FN} \quad (1)$$

Donde VP (Verdaderos Positivos) es el número de casos donde hubo maleza y se detectó su presencia. VN (Verdaderos Negativos) es el número de casos donde no hubo maleza y se descartó su presencia. FP (Falsos Positivos) es el número de casos donde no hubo maleza, pero erróneamente fue detectada, y FN (Falsos Negativos) es el número de casos donde hubo maleza, pero no fue detectada. Con base en la Tabla 2, VP=168; VN=119; FP=55, y FN=5. Así, el porcentaje de clasificación correcto fue de 82.7 %.

Analizando las columnas de porcentajes de la Tabla 2 se deduce que las imágenes con valores de intensidad lumínica baja presentan mayor error en cuanto a la omisión de detección de malezas; por este motivo se estableció un umbral de intensidad lumínica de 0.45. De esta manera, las imágenes con valores de intensidad superior a dicho umbral son consideradas adecuadas para el procesamiento, mientras que las demás, no. Para fines de aplicación en campo, el prototipo se limita a un funcionamiento óptimo bajo condiciones de luminosidad adecuadas; en el proceso de adquisición consecutiva de imágenes en el campo, el sistema de procesamiento no evalúa el nivel de luminosidad para cada cuadro de imagen capturado porque esto retarda el proceso de detección, pero sí lo hace cada dos minutos, con el objeto de realizar un monitoreo de calidad de imágenes capturadas. Si existen anomalías en la calidad de imagen, el sistema descarta la detección o detiene el proceso de detección de malezas.

B. Sistema de bombeo y aspersión implementado

Inicialmente se consideró posicionar el tanque almacenador del líquido en la parte trasera baja del vehículo y la bomba en la parte superior, para que absorbiera el líquido y mediante la válvula *check* no permitiera la devolución de este. Pero, por condiciones de diseño, se optó por posicionar el tanque en la parte superior y la bomba abajo para garantizar la alimentación de fluido a los conductores por la fuerza gravitatoria. La lanza pulverizadora se ajustó al cuerpo del vehículo de tal modo que el chorro cayera justo en el lugar desde donde la cámara captura la imagen que se va a procesar. En la Figura 8 se muestra el montaje final del sistema de bombeo y aspersión implementado.

C. Sistema prototipo integrado y pruebas finales de detección

El sistema prototipo físicamente implementado consta de la tarjeta Raspberry Pi conectada a su alimentación eléctrica, una batería que otorga 5 voltios y hasta 2 amperios en una hora. El encendido de la tarjeta se hace mediante un interruptor, y un led indica su estado (encendido o apagado). La Raspberry Pi, junto con los componentes conectados a ella (adaptador inalámbrico, cámara, módulo Relé y led), genera un consumo energético alrededor de 1.3^a. Así, el tiempo que la batería es capaz de suministrar la alimentación continua a la tarjeta es de una hora y media aproximadamente. El prototipo ha sido desarrollado para evaluar el desempeño del sistema inteligente en cuanto a detección de maleza y aplicación de insumos. Los resultados obtenidos evidencian la calidad del funcionamiento del sistema, permitiendo de esta forma establecer como investigaciones futuras el uso de vehículos más grandes y fuentes de alimentación más acertadas para el trabajo en campo de forma continua. En la Figura 8 se aprecia el resultado final del prototipo desarrollado.

Se realizaron las respectivas pruebas en el campo de estudio, (cultivo de piña con una densidad de 50000 plantas/ha) para el día 22 de julio de 2018 en horas de la mañana. El prototipo recorrió una hilera de 143 plantas de piña, de allí se obtuvieron los resultados que se muestran en la Figura 9, donde el PCC fue del 83.2 %, un porcentaje cercano al valor esperado de 85 %.



Figura 8. Funcionamiento de sistema prototipo en campo.

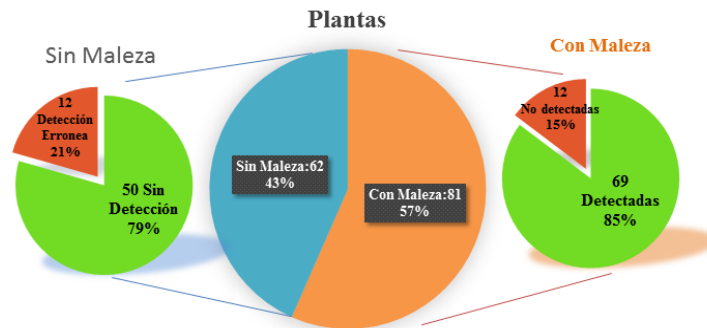


Figura 9. Resultados de prueba en campo.

Debido a que el prototipo no cuenta con un sistema de autoguiado, el control del desplazamiento de este se hace mediante el control remoto del vehículo, a una velocidad inferior a 3 km/h, con un tiempo de accionamiento del sistema de activación del sistema de bombeo de aprox. 0.7 segundos. En la Figura 10 se aprecian dos fotografías tomadas mientras el sistema aplica el herbicida (emulación), luego de detectar malezas presentes en las plantas del cultivo.



Figura 10. Emulación de aplicación de insumo agrícola a malezas.

Los resultados encontrados permiten establecer las pautas necesarias para la detección de las malezas entre hileras del cultivo, que serán usadas para el desarrollo de plataformas robóticas más avanzadas, con capacidad de maniobrabilidad y autonomía mayores.

V. Conclusiones

Se desarrolló y evaluó un algoritmo de procesamiento de imágenes para detectar malezas en el cultivo de piña. Los procesos de detección de malezas incluyeron conversión de espacio de color de imágenes, estimación del valor umbral estadístico, segmentación adaptativa de imagen, filtro mediano y cálculo de características morfológicas. El algoritmo desarrollado fue validado con datos al aire libre no controladas. Además, el algoritmo de detección de malezas en el cultivo de piña tuvo una eficiencia de más del 80 %, lo cual significa que presenta resultados satisfactorios y demuestra que evita el uso excesivo de herbicidas selectivos a plantas que en el momento no lo requieren. El algoritmo desarrollado para la detección de malezas y el procesamiento de imágenes proporciona un método de bajos requerimientos de procesamiento, apto para ser utilizado en sistemas embebidos.

La ejecución de este proyecto ha demostrado que es posible diseñar e implementar un sistema de detección de malezas de bajo costo basado en la visión artificial, gracias al acoplamiento a un vehículo terrestre de tamaño reducido, liviano y resistente para este tipo de aplicaciones en la agricultura. El uso de *hardware* potente y económico, así como de *software* libre o código abierto, lo hace un sistema flexible. El prototipo debe evaluarse en diferentes condiciones y mejorarse con otros sistemas de adquisición, vehículos de mejores prestaciones, sistemas de comunicación más eficientes y desarrollando mejores algoritmos de análisis de información basados en las diversas áreas de la inteligencia artificial.

La eficiencia del sistema depende del *hardware* usado para adquisición y procesamiento. La rapidez del procesamiento depende de las dimensiones de la imagen que se ha de procesar, por tanto, fue necesario redimensionar la imagen antes de procesarla para que la respuesta del sistema fuera inmediata. Por otro lado, la calidad de la imagen es notablemente afectada por el nivel de intensidad lumínica, por eso los umbrales de intensidad son pieza fundamental en el desarrollo de este tipo de sistemas.

En la siguiente etapa de la investigación se pretende mejorar el sistema de guía del vehículo en el campo y el sistema de comunicaciones para la supervisión del movimiento y aplicación de insumos del prototipo elaborado.

Agradecimientos

Agradecemos a la Dirección de Investigaciones de la Universidad de los Llanos por la financiación del proyecto institucional titulado “Sistema automático de detección de malezas y aplicación de herbicida usando tecnologías de agricultura de precisión”. Andrés Jiménez López expresa su agradecimiento a la Gobernación de Boyacá, Colombia, por la beca de Doctorado de la Convocatoria para la Formación de Capital Humano de Alto Nivel para el Departamento de Boyacá- 2015 y también a la Universidad Nacional de Colombia.

Referencias

- Abouzahir, S., Sadik, M. & Sabir, E. (2017). IoT-empowered Smart Agriculture: A Real-Time Light-Weight Embedded Segmentation System. In *International Symposium on Ubiquitous Networking*, Springer, Cham, May 2017, pp. 319-332. https://doi.org/10.1007/978-3-319-68179-5_28
- Abouzahir, S., Sadik, M. & Sabir, E. (2018). Enhanced Approach for Weeds Species Detection Using Machine Vision. In *2018 International Conference on Electronics, Control, Optimization and Computer Science (ICECOCS)- IEEE*, Kenitra, Morocco, 1-6. December 2018. 1-6. <https://doi.org/10.1109/ICECOCS.2018.8610505>
- Agrawal, K. N., Singh, K., Bora, G. C. & Lin, D. (2012). Weed Recognition Using Image-Processing Technique Based on Leaf Parameters. *J. Agric. Sci. Technol. B*, 2(8B), 899. <http://www.davidpublishing.org/show.h...>
- Bakhshipour, A. & Jafari, A. (2018). Evaluation of Support Vector Machine and Artificial Neural Networks in Weed Detection Using Shape Features. *Computers and Electronics in Agriculture*, 145, 153-160. <https://doi.org/10.1016/j.compag.2017.12.032>
- Barrero, O., Rojas, D., González, C. & Perdomo, S. (2016). Weed Detection in Rice Fields Using Aerial Images and Neural Networks. In *2016 XXI Symposium on Signal Processing, Images and Artificial Vision (STSIVA)- IEEE*, Bucaramanga, Colombia, August 2016, 1-4. <https://doi.org/10.1109/STSIVA.2016.7743317>
- Bastidas, D. A., Guerrero, J. A. & Wyckhuys, K. (2013). Residuos de plaguicidas en cultivos de pasifloras en regiones de alta producción en Colombia. *Revista Colombiana de Química*, 4(22), 39-47.
- Bradski, G. & Kaehler, A. (2008). *Learning OpenCV: Computer Vision with the OpenCV Library*. O'Reilly Media, Inc. ISBN: 978-0-596-51613-0
- Brenes-Prendas, S. & Agüero-Alvarado, R. (2007). Reconocimiento taxonómico de malezas y descripción de su manejo, en cuatro fincas productoras de piña (*Ananas comosus* L.) en Costa Rica. *Agronomía Mesoamericana*, 18(2), 239-246. <http://www.redalyc.org/articulo.oa?id=43718209>
- Di Cicco, M., Potena, C., Grisetti, G. & Pretto, A. (2017). Automatic Model Based Dataset Generation for Fast and Accurate Crop and Weeds Detection. In *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)-IEEE*, Vancouver, BC, Canada, 5188-5195, September 2017, 5188-5195. <https://doi.org/10.1109/IROS.2017.8206408>
- Farooq, A., Hu, J. & Jia, X. (2018). Weed Classification in Hyperspectral Remote Sensing Images Via Deep Convolutional Neural Network. In *IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium – IEEE*, Valencia, Spain, July, 2018, pp. 3816-3819. <https://doi.org/10.1109/IGARSS.2018.8518541>
- Gee, C., Bossu, J., Jones, G. & Truchetet, F. (2008). Detecting Crops and Weeds in *Precision Agriculture*, SPIE Newsroom, 2008, <https://doi.org/10.1117/2.1200809.1226>
- Jaramillo-Colorado, B. E., Palacio-Herrera, F. & Pérez-Sierra, I. (2016). Residuos de pesticidas organofosforados en frutas obtenidas de plazas de mercado y supermercados en Cartagena, Colombia. *Revista Ciencias Técnicas Agropecuarias*, 25(4), 39-46.

Lottes, P., Behley, J., Chebrolu, N., Milioto, A. & Stachniss, C. (2018). Joint Stem Detection and Crop-Weed Classification for Plant-Specific Treatment in Precision Farming. In *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)–IEEE*, Madrid, Spain, October 2018, 8233-8238. <https://doi.org/10.1109/IROS.2018.8593678>

Lottes, P., Hoferlin, M., Sander, S., Müter, M., Schulze, P., & Stachniss, L. C. (2016). An Effective Classification System for Separating Sugar Beets and Weeds for Precision Farming Applications. In *2016 IEEE International Conference on Robotics and Automation (ICRA)–IEEE*, Stockholm, Sweden, May, 2016, 5157-5163. <https://doi.org/10.1109/ICRA.2016.7487720>

Pérez-Ortiz, M., Gutiérrez, P. A., Peña, J. M., Torres-Sánchez, J., López-Granados, F. & Hervás-Martínez, C. (2016). Machine Learning Paradigms for Weed Mapping Via Unmanned Aerial Vehicles. In *2016 IEEE Symposium Series on computational intelligence (SSCI)–IEEE*, Athens, Greece, December, 2016, pp. 1-8. <https://doi.org/10.1109/SSCI.2016.7849987>

Potena, C., Nardi, D. & Pretto, A. (2016). Fast and Accurate Crop and Weed Identification with Summarized Train Sets for Precision Agriculture. In *International Conference on Intelligent Autonomous Systems, Springer, Cham*, July, 2016, pp. 105-121. https://doi.org/10.1007/978-3-319-48036-7_9

& Corscadden, K. W. (2019). Development and Field Evaluation of a Machine Vision Based In-Season Weed Detection System for Wild Blueberry. *Comput. Electron. Agric.*, 162, 1-13. <https://doi.org/10.1016/j.compag.2019.03.023>

Reyes, Y., Vergara, I., Torres, O., Lagos, M. D. & Jiménez, E. E. G. (2016). Contaminación por metales pesados: Implicaciones en salud, ambiente y seguridad alimentaria. *Ingeniería Investigación y Desarrollo: I2+ D*, 16(2), 66-77.

Russell, S. J. & Norvig, P. (2016). *Artificial Intelligence: A Modern Approach* (3th ed.). Pearson.

& Siegart, R. (2017). Weednet: Dense Semantic Weed Classification Using Multispectral Images and Mav for Smart Farming. *IEEE Robotics and Automation Letters*, 3(1), 588-595. <https://doi.org/10.1109/LRA.2017.2774979>

Sandino, J. & González, F. (2018). A Novel Approach for Invasive Weeds and Vegetation Surveys Using UAS and Artificial Intelligence. In *2018 23rd International Conference on Methods y Models in Automation y Robotics (MMAR)–IEEE*, Miedzyzdroje, Poland, August 2018, 515-520. <https://doi.org/10.1109/MMAR.2018.8485874>

Segura, M. A. M. (2015). Uso de agroquímicos en la producción intensiva de piña en Costa Rica. *Pensamiento Actual*, 15(25), 183-195. <https://revistas.ucr.ac.cr/index.php/pensamientoactual/article/view/22604/24028>

Siddiqi, M. H., Ahmad, I. & Sulaiman, S. B. (2009). Edge Link Detector Based Weed Classifier. In *2009 International Conference on Digital Image Processing–IEEE*, Bangkok, Thailand, March 2009, 255-259. <https://doi.org/10.1109/ICDIP.2009.64>

Tang, J. L., Chen, X. Q., Miao, R. H. & Wang, D. (2016). Weed Detection Using Image Processing under Different Illumination for Site-Specific Areas Spraying. *Computers and Electronics in Agriculture*, 122, 103-111. <https://doi.org/10.1016/j.compag.2015.12.016>

Utstumo, T., Urdal, F., Brevik, A., Dørum, J., Netland, J., Overskeid, Ø. & Gravidahl, J. T. (2018). Robotic In-Row Weed Control in Vegetables. *Computers and Electronics in Agriculture*, 154, 36-45. <https://doi.org/10.1016/j.compag.2018.08.043>

Wang, A., Zhang, W. & Wei, X. (2019). A review on weed detection using ground-based machine vision and image processing techniques. *Computers and Electronics in Agriculture*, 158, 226-240. <https://doi.org/10.1016/j.compag.2019.02.005>

Wagstaff, K. L. & Liu, G. Z. (2018). Automated Classification to Improve the Efficiency of Weeding Library Collections. *The Journal of Academic Librarianship*, 44(2), 238-247. <https://doi.org/10.1016/j.acalib.2018.02.001>

Weatherspark.com (2019). [online] <https://weatherspark.com/y/24273/Average-Weather-in-Villavicencio-Colombia-Year-Round>

Yang, C. C., Prasher, S. O., Landry, J. A. & Ramaswamy, H. S. (2003). Development of a Herbicide Application Map Using Artificial Neural Networks and Fuzzy Logic. *Agricultural Systems*, 76(2), 561-574. [https://doi.org/10.1016/S0308-521X\(01\)00106-8](https://doi.org/10.1016/S0308-521X(01)00106-8)

Zhang, W. & Wei, X. (2019). A Review on Weed Detection Using Ground-Based Machine Vision and Image Processing Techniques. *Computers and Electronics in Agriculture*, 158, 226-240. <https://doi.org/10.1016/j.compag.2019.02.005>

Zheng, Y., Zhu, Q., Huang, M., Guo, Y. & Qin, J. (2017). Maize and Weed Classification Using Color Indices with Support Vector Data Description in Outdoor Fields. *Computers and Electronics in Agriculture*, 141, 215-222. <https://doi.org/10.1016/j.compag.2017.07.028>

Cómo citar este artículo: Jiménez. A., Camargo. D. & García. D. (2020). Sistema inteligente para el manejo de malezas en el cultivo de piña con conceptos de agricultura de precisión. *Cien. Agri.* 17(3):122-136. <https://doi.org/10.19053/01228420.v17.n3.2020.10830>