

Desarrollo de un sistema de detección y conteo automático para *Metisa plana* Walker (Lepidoptera: Psychidae)*

Development of an Automated Detection and Counting System for the Bagworms *Metisa plana* Walker (Lepidoptera: Psychidae)

AUTORES: Abdul Rashid Mohamed Shariff, Facultad de Ingeniería, Universidad Putra (Malasia). Mohd Najib Ahmad, Facultad de Ingeniería, Universidad Putra (Malasia) (MPOB). Ishak Aris, Facultad de Ingeniería, Universidad Putra (Malasia). Izhal Abdul Halin, Facultad de Ingeniería, Universidad Putra (Malasia). Ramle Moslim, (MPOB).

CITACIÓN: Shariff, A. R., Ahmad, M. N., Aris, I., Halin, I. A., & Moslim, R. (2019). Desarrollo de un sistema de detección y conteo automático para *Metisa plana* Walker (Lepidoptera: Psychidae). *Palmas*, 40 (Especial Tomo I), 111-116.

PALABRAS CLAVE: *Metisa plana*, segmentación de imagen, características de color, detección de objetos, agricultura de precisión.

KEYWORDS: *Metisa plana*, image segmentation, color features, object detection, precision agriculture.

*Artículo original recibido en inglés y traducido por Carlos Arenas París.



ABDUL RASHID MOHAMED SHARIFF
Investigador Facultad de Ingeniería,
Universidad Putra (Malasia)
Researcher
Faculty of Engineering, University
Putra (Malaysia)

Resumen

Metisa plana Walker es una de las principales y más serias amenazas de plagas de insectos comedores de hojas de las plantaciones de palma de aceite en Malasia. El impacto económico de un ataque moderado de este, con un daño de hojas de 10 a 50 %, puede ocasionar pérdidas en el rendimiento de este cultivo cercanas a 43 %. La población no controlada de *Metisa plana* suele aumentar por encima de los límites del umbral, causando brotes serios de esta plaga. Debido a su impacto, es necesario monitorear y detectar la población de este insecto en la palma de aceite para garantizar una planeación apropiada de cualquier acción de control en las áreas infestadas, lo cual requiere un sistema de monitoreo preciso para vigilar la población y los niveles de infestación. Por ello, se inició un estudio sobre el desarrollo

de un algoritmo de procesamiento de imágenes para la detección y el conteo de especies de *Metisa plana* Walker, utilizando la segmentación de imágenes con base en características de color y forma en combinación con aprendizaje profundo y redes neuronales celulares (RNC) para la detección de objetos en tiempo real. El procesamiento de color se acercó a una precisión baja en la detección, con un promedio de 40 y 34 % a una distancia de cámara de 30 cm y 50 cm, respectivamente. Aplicando una red neuronal convencional profunda, el porcentaje de detección aumentó considerablemente, con una precisión de hasta 95 %, con una mayor precisión a 30 cm de distancia. Se recomendó desarrollar este robusto algoritmo, puesto que la información será útil, importante y crucial para crear un sistema o dispositivo de monitoreo, y para integrarlo con imágenes inalámbricas basadas en el internet de las cosas (IoT, por sus siglas en inglés) en el futuro.

Abstract

The bagworm is one of main and serious leaf eating insect pest threats of the oil palm plantations in Malaysia. The economic impact from a moderate bagworm attack of 10-50% leaf damage may cause 43% yield loss. A precise monitoring system through the application of device to monitor bagworm population and infestation level is required to overcome recurrence outbreak. Hence, a study on the development of image processing algorithm for detection and counting of the oil palm bagworms species of *Metisa plana* Walker was initiated by using image segmentation based on color and shape features, combined with deep learning and Cellular Neural Networks (CNN) towards real time object detection. The color space processing technique showed that the average accuracy of detection was low, 40 and 34%, within 30 and 50 cm camera distance, respectively. However, to overcome low accuracy and slow processing of dataset, the deep convolutional neural networks was performed and resulted in high accuracy for object/bagworm detection, with a 85-95% accurate detection rate.

Introducción

Metisa plana Walker y *Pteroma pendula* Joannis son las principales y más serias plagas de las plantaciones de palma de aceite en Malasia. En el pasado, se implementó el manejo integrado de plagas de *M. plana*. Sin embargo, la información sobre su dinámica de población, incidencia, características biológicas y dispersión es insuficiente y existen brechas. Con base en registros de infestaciones (1986-2000), se confirmó que más de 63.955 ha de palma de aceite sembradas en 69 fincas de Malasia peninsular fueron atacadas por *M. plana* y *P. pendula*. Se evidenció que las infestaciones son de especies únicas y mixtas, oscilando entre cero y 7.811 ha por año (Ho *et al.*, 2011).

Realizar un censo es vital para el control efectivo de *M. plana* en las plantaciones de palma de aceite, puesto que este procedimiento permite contabilizar directamente el número de plagas de insectos para hacer evaluaciones posteriores. Su procedimiento involucra

una inspección superficial en búsqueda de signos de incidencia de la plaga y una evaluación o “enumeración” más detallada (Corley *et al.*, 2003). Los datos promedio determinan la gravedad de los brotes de la plaga de insectos, información que puede ser utilizada para la sincronización precisa del control de plagas. En la actualidad, el censo se realiza manualmente mediante la observación a simple vista y métodos de conteo. Adicionalmente, se puede compilar la recolección de datos precisos para el posterior análisis y evaluación de las medidas de control tomadas para combatir la *M. plana*. Posteriormente, se investigan y estiman los resultados para obtener un mejor rendimiento de racimos de fruta fresca en el futuro. Con el fin de compilar una recolección precisa de datos, se propone un método avanzado que emplea el análisis de imágenes y técnicas de aprendizaje profundo.

Esta última técnica es una parte del aprendizaje automático en el que un modelo o sistema realiza tareas de clasificación o funciones directamente a partir

de una imagen, una palabra o un sonido. Se opera con base en una arquitectura de redes neuronales. Irónicamente, “profundo” se refiere al número de capas que funcionan en la red: entre más capas, más profunda es. Normalmente, las redes profundas tienen cientos de capas, mientras que las neuronales obsoletas solo dos o tres. Además, esta técnica reemplaza la habilidad manual en la extracción de características, mediante el uso de algoritmos efectivos sin o con supervisión parcial, junto con la eliminación jerárquica de características (Aiman & Vishwakarma, 2017; Bengio, 2012).

Considerando la importancia de la recolección precisa de datos, el desarrollo del dispositivo basado en tierra con un algoritmo robusto es la primera innovación en la historia de la industria de la palma de aceite, en reducir el error humano en el censo y promover prácticas de agricultura de precisión. Aplicando algoritmos de procesamiento de imágenes, el dispositivo sirve para monitorear la población de *M. plana* y, en consecuencia, incrementar el rendimiento y la productividad del cultivo. El objetivo de este estudio es evaluar la efectividad y grado de precisión de los algoritmos de procesamiento de imagen desarrollados para detectar y contar la población de *M. plana* en plantaciones de palma de aceite infestadas.

Materiales y métodos

Se aplica un enfoque de procesamiento de imágenes para extraer *M. plana* y separarlas del fondo. La construcción de un algoritmo de análisis de imágenes consta de cuatro etapas: i) la primera incluye el desarrollo de un algoritmo de segmentación para localizar/detectar la región de interés (RdI) en un conjunto de datos basado en el procesamiento de colores y para trazar los objetos (*M. plana*) y remover el fondo innecesario; ii) la segunda usa el método del operador morfológico, que se enfoca en extraer el objeto que corresponden con el patrón de la forma, y elimina regiones no objetivo en el conjunto de datos; iii) la tercera aplica un algoritmo de clasificación supervisada con base en los datos de entrenamiento específico para el reconocimiento de tamaño y forma, y también para identificar las *M. plana* vivas y muertas; iv) la cuarta trata del algoritmo de conteo para determinar la población de *M. plana* que corresponden a grupos

específicos, con lo que se pueden detectar los insectos vivos. Adicionalmente, se realizó una evaluación y monitoreo del rendimiento del algoritmo desarrollado con éxito utilizando el *software* Python.

Para apoyar los resultados de procesamiento de color se desarrolló un conjunto de datos entrenado para la detección de objetos y reconocimiento de las etapas de *M. plana* y se creó un algoritmo utilizando técnicas de aprendizaje profundo con redes neuronales celulares (RNC). Una RNC está conformada por una capa de entrada, una de salida y muchas escondidas en medio. La convolución coloca las imágenes de entrada en un conjunto de filtros, cada uno de los cuales activa ciertas características de las mismas. La posición de la cámara respecto a los objetivos se fijó a 30 y 50 cm de distancia, con el fin de reducir o minimizar los cambios en las condiciones de luz, sombras, vibración u objetos repentinos capturados durante la grabación.

El aprendizaje profundo con un algoritmo de RNC para detectar *M. plana* se realizó de la siguiente manera:

Proceso de entrenamiento

- Las muestras de entrenamiento fueron recolectadas por MPOB HQ en Bangiy Banting, Selangor, Malasia.
- Se tomó una muestra de cuadros de un archivo de video.
- Las imágenes se etiquetaron y se determinó, manualmente, su cuadro delimitador alrededor de la figura de la *M. plana*.
- La imagen etiquetada fue trabajada utilizando modelos preentrenados.
- Los modelos se tomaron de una RNC preentrenada.

Pruebas del modelo

- El archivo de video fue cargado y se capturó un cuadro.
- Se redimensionó una imagen de entrada a 960 x 540 píxeles.
- Esta se procesó en la RNC para identificar el objeto (*M. plana*).

- d. Luego, apareció un conjunto de datos con información del objeto dentro del cuadro delimitador.
- e. La información del procesamiento de la RNC fue visualizada, superponiendo el cuadro delimitador alrededor del objeto con niveles de confianza por encima de 90 %.
- f. Posteriormente, este cuadro fue guardado en un archivo de video.

Resultados y discusión

Procesamiento del color

La técnica del procesamiento de espacios de color mostró que la precisión de la detección era baja, con un promedio de 40 y 34 %, con una distancia de cámara de 30 y 50 cm, respectivamente. Se establecieron los parámetros a su valor óptimo, pero los resultados continúan siendo bajos para la detección del objeto. Igualmente produjo reconocimiento erróneo (Figura 1). Esto se debió a la similitud de colores entre los folíolos dañados y la *M. plana*. Utilizando métodos de espacio de color, parece difícil enfocarse en el objetivo, aunque se filtró la imagen mediante un operador de suavizado gaussiano para eliminar ruido y mejorar la calidad (Nameirakpam *et al.*, 2015).

Figura 1. Detección errónea del color en objetos objetivo mediante técnica de procesamiento de color.



Aprendizaje profundo con RNC

El porcentaje de detección aumentó considerablemente al aplicar una red neuronal profunda convolucional, llegando a una precisión de entre el 88 y 100 %. Respecto a la distancia de la cámara, la de 30 cm resultó en un mayor porcentaje de detección debido a la cercanía y a una mayor detección del foco, lo que permitió un mejor efecto de reconocimiento de objetos (Figura 2). Por lo tanto, la distancia de la cámara juega un papel importante para maximizar los detalles del objeto reconocido durante la toma de la imagen (Westerman *et al.*, 2013) (Figura 4).

Conclusiones

A partir de este estudio, revelamos que el aprendizaje profundo con RNC es factible y tiene potencial para ser más práctico en la detección de objetos/ *M. plana*, con alta precisión, detección de aproximadamente 85 a 95 %, en comparación con el enfoque de procesamiento de color por sí solo. Respecto a la distancia de la cámara, la de 30 cm resultó en un mayor porcentaje de detección debido a la cercanía y a un mayor enfoque, lo que otorgó un mejor efecto de reconocimiento de objetos.





Figura 2. Efecto de la distancia de la cámara en la detección de *M. plana* a 30 cm (arriba) y 50 cm (abajo).





Figura 3. Precisión de detección aumentada con el enfoque de aprendizaje profundo a 30 cm (arriba) y 50 cm (abajo) de distancia de la cámara.

Referencias

- Bengio, Y. (2012). Deep learning of representations for unsupervised and transfer learning. *ICML Unsupervised and Transfer Learning*, 27, 17-36.
- Corley, R. H. V., & Tinker, P. B. H. (2003). Chapter 12: Disease and pest of the oil palm. In *The Oil Palm* (4th Ed.). London: Blackwell Science Ltd.
- Ho, C. T., Yusof, I., & Khoo, K. C. (2011). Infestations by the bagworms *Metisa plana* and *Pteroma pendula* for the period 1986-2000 in major oil palm estates managed by Golden Hope Plantation Berhad in Peninsular Malaysia. *Journal of Oil Palm Research*, 23, 1040-1050.
- Nameirakpam, D., Khumanthem, M., & Yambem, J. C. (2015). Image Segmentation using K-means Clustering Algorithm and Subtractive Clustering Algorithm. *Procedia Computer Science*, 54, 764-771.
- Westerman, S., Buchner, H. H. F., Schramel, J., Tichi, A., & Stanek, C. (2013). Effects of infrared camera angle and distance on measurement and reproducibility of thermographically determined temperatures of the distolateral aspects of the forelimbs in horses. *JAVMA Scientific Reports*, 242, 388-395.