

Sistema de visión inteligente para monitorizar polinizadores (MonPo) usando aprendizaje profundo

Daniela Bolaños-Flores¹, Tania A. Ramírez-del Real²,
Magali Arellano-Vázquez³, Dagoberto Armenta-Medina³,
Guadalupe O. Gutierrez-Esparza⁴, Hamurabi Gamboa-Rosales³

¹ Universidad Tecnológica del Centro de Veracruz,
México

² Consejo Nacional de Ciencia y Tecnología,
Centro de Investigación en Ciencias de Información Geoespacial,
México

³ Consejo Nacional de Ciencia y Tecnología,
Centro de Investigación e Innovación en Tecnologías de la Información,
México

⁴ Consejo Nacional de Ciencia y Tecnología,
Instituto Nacional de Cardiología Ignacio Chávez,
México

14484@utc.v.edu.mx, tramirez@centrogeo.edu.mx,
{magali.arellano, dagoberto.armenta,
hamurabi.gamboa}@infotec.mx, ggutierrez@conacyt.mx

Resumen. Los ecosistemas están en constante amenaza, uno de los factores relevantes es, la crisis mundial de polinización. Adquirir el entendimiento sobre polinizadores y su comportamiento se ha convertido en un tema emergente para la sociedad. Actualmente, algunos de los métodos para registrar la actividad de los polinizadores en el campo son de forma manual, lo anterior implica tiempo y alto costo de mano de obra. El avance tecnológico permite la utilización de sistemas de videovigilancia en el sector agrícola, posibilitando la captura de datos sobre la interacción entre insectos y plantas. En el presente trabajo es propuesto un sistema de videovigilancia para monitorizar polinizadores (abejas y mariposas), denominado MonPo. El sistema consiste en una cámara Web, un sensor para detectar el movimiento y una raspberry Pi 3 como procesador digital. El cual logra identificar abejas y mariposas con una exactitud mayor al 90 %, empleando una red de aprendizaje profundo (VGG-16). El sistema MonPo almacena los datos cuando se detecta el movimiento, específicamente la fecha, hora y la clase del polinizador identificado (abeja o mariposa). Lo anterior permitirá realizar un análisis referente a la presencia de polinizadores en las diferentes estaciones del año, así como las plantas que favorecen la polinización.

Palabras clave: Polinizadores, procesamiento de imágenes, videovigilancia, aprendizaje profundo.

Intelligent Vision System to Monitor Pollinators (MonPo) Using Deep Learning

Abstract. Ecosystems are in constant threat; one of the relevant factors is the global pollination crisis. Gaining an understanding of pollinators and their behavior has become an emerging issue for society. Some of the methods to record pollinator activity in the field are manual, which implies time and high labor costs. Technological advance allows the use of video surveillance systems in the agricultural sector, making it possible to capture data on the interaction between insects and plants. In the present work, a video surveillance system is proposed to monitor pollinators (bees and butterflies), called MonPo. The system consists of a webcam, a sensor to detect motion, and a Raspberry Pi 3 as a digital processor. Which manages to identify bees and butterflies with an accuracy greater than 90 %, using a deep learning network (VGG-16). The MonPo system stores data when movement is detected, precisely the date, time, and class of the identified pollinator (bee or butterfly); the above will allow an analysis regarding the presence of pollinators in the different seasons of the year, as well as the plants that favor pollination.

Keywords: Pollinators, image processing, video surveillance, deep learning.

1. Introducción

Actualmente, el uso de la tecnología se ha expandido en diversas áreas, una de éstas, es el sector agrícola, particularmente en la polinización, donde se requiere la acción de insectos con la capacidad de transportar el polen entre las flores para así lograr la producción de frutos y semillas. La polinización es esencial para la producción de alimentos, la viabilidad y diversidad genética de las especies vegetales con flor.

Los polinizadores son un grupo diverso de animales que incluyen algunas variedades de insectos, como lo son los coleópteros, lepidópteros, dípteros, además de muchas aves, murciélagos, roedores e incluso lagartijas. Los polinizadores son responsables del 80 % de reproducción de las especies vegetales, la variedad de éstos dificulta el estudio en extenso del declive de la población; la principal causa identificada es la pérdida del hábitat [1].

La modificación del entorno natural repercute en que los polinizadores no logran adaptarse, al no encontrar suficiente comida ni lugares de anidamiento. En el caso de las superficies de cultivo, los polinizadores aunque pueden encontrar los recursos suficientes, se enfrentan a agroquímicos y no solo los insecticidas, sino fungicidas que afectan la microbiota de la flora y a herbicidas que reducen los recursos florales disponibles [1].

Últimamente el uso excesivo de plaguicidas, herbicidas e insecticidas en el aire libre, así como también el cambio en el uso del suelo, la invasión de plantas y animales no nativos en los ecosistemas naturales, han sido un factor negativo para los principales polinizadores [5].




Fig. 1. Propuesta del sistema de visión inteligente para la detección de polinizadores.

Los plaguicidas se consideran una de las mayores amenazas para la conservación de la biodiversidad, reduciendo las fuentes de abastecimiento alimenticio de dichos insectos y disminuyendo su ciclo de vida, lo anterior, puede generar una perturbación en la humanidad debido a una disminución del 35 % [7] de la producción mundial de cultivos, además de afectar la salud, cambiando así la dieta de la humanidad mientras se incrementa la tasa bruta de mortalidad, a consecuencia de la falta de nutrientes que se obtienen de las frutas y verduras.

El cambio climático afecta a los polinizadores, como en el caso de la llegada de especies exóticas que compiten con las especies nativas, llevando a estas poblaciones a su extinción [1]. La monitorización de los polinizadores es una herramienta básica para la conservación, ya que pueden detectar de manera temprana señales de alerta en su comportamiento, además provee información para su estudio.

La disponibilidad de datos ecológicos abre la puerta al uso de minería de datos basados en la predicción, como el aprendizaje automático para la identificación de patrones. La proliferación de dispositivos para monitorización de polinizadores y sensado de variables climáticas aunado al apoyo de la ciencia ciudadana es una oportunidad para la creación conjunta de fuentes de datos [1].

Hoy en día, existe una gran cantidad de sistemas para detección de animales, pero suelen estar limitados en su funcionamiento, ya que algunos requieren una caja trampa, o cuentan con una limitada precisión, es por ello que en este trabajo se propone realizar un sistema encargado de detectar y clasificar a distintos polinizadores para la monitorización del comportamiento, mediante la aplicación de herramientas de aprendizaje automático.

El sistema hace uso de un algoritmo basado en Inteligencia Artificial para la clasificación de las distintas especies de insectos voladores, y en un futuro extraer la información de los patrones de comportamiento, así como tener propuestas para su conservación y cuidado. Este trabajo presenta la implementación de una arquitectura de una red neuronal convolucional para la detección y clasificación de algunos polinizadores, en particular abejas y mariposas, lo anterior permite estudiar su comportamiento, en diferentes estaciones del año.

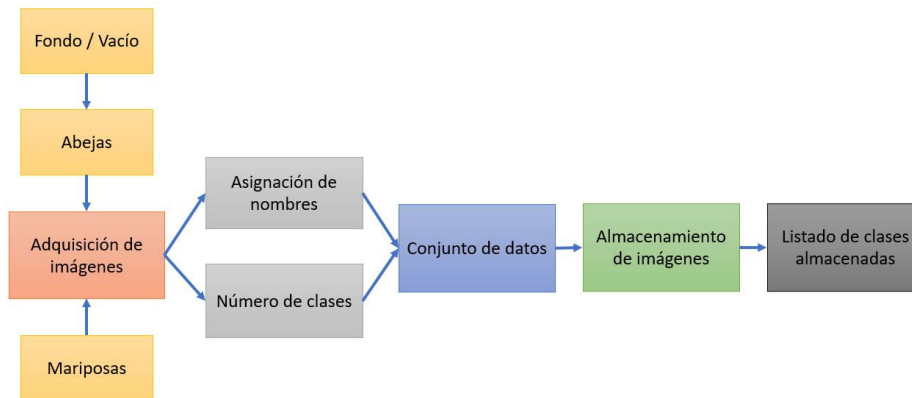


Fig. 2. Diagrama de adquisición de imágenes.

El sistema está basado en un procesador digital de arquitectura abierta (Raspberry Pi 3), que incluye una cámara para la toma de fotografía, además se incluye un sensor de movimiento para precisar el momento de captura de imagen.

El artículo está organizado de la siguiente manera, en la sección 2 se presentan los trabajos relacionados, en particular los sistemas similares para la detección automática de polinizadores, en la sección 3 se detalla el desarrollo del sistema propuesto, en la sección 4 se muestran los resultados obtenidos en la identificación de polinizadores, finalmente en la sección 5 se establecen las conclusiones, así como el trabajo futuro.

2. Trabajos relacionados

Existen diversos trabajos que clasifican polinizadores, algunos de ellos utilizan técnicas de inteligencia artificial, sin embargo, muchos de ellos realizan la detección fuera de línea. Entre los estudios enfocados en la monitorización de polinizadores, en general los apicultores revisan la colmena para inspeccionar la cantidad de polen y néctar, lo que permite la detección temprana de enfermedades o plagas, las revisiones regulares permiten prevenir plagas, virus o infecciones bacterianas y este proceso se hace de manera manual.

Sin embargo, regularmente las colmenas se encuentran en lugares aislados y las revisiones manuales interfieren en el ciclo de vida de las colonias de abejas. La monitorización automática hace posible capturar grandes cantidades de datos acerca del comportamiento de abejas, sin interferir en su cotidianidad. Las variables como la temperatura interna de la colmena, el sonido de los zumbidos, la variación de peso de la colmena, fotografías y vídeos del flujo de abejas aportan importante información sobre la salud de la colmena.

El análisis de estos datos de manera continua apoya a la identificación de patrones que alerta cambio en la vida normal de la colmena. En [6] se realiza un amplio estudio de las grabaciones de los zumbidos, se ha determinado que se pueden generar dos tipos zumbidos; el primero se produce por el rápido batido de de las alas que genera un zumbido audible y perceptible por los dispositivos de grabación; el segundo se




Fig. 3. Arquitectura red neuronal convolucional VGG-16.




Fig. 4. Diagrama de creación del modelo.

produce cuando las abejas visitan una flor, éstas generan una vibración usando los músculos de sus alas y tórax lo que causa que el polen se transfiera a otras flores, produciéndose así la polinización. Utilizando un sistema de adquisición de datos automático que usa muestras de audio que a su vez alimentan modelos de aprendizaje automático para asistir a los cuidadores de las colmenas, reduciendo o evitando así las revisiones manuales.

Existen otros sistemas de monitorización miniatura, sin embargo, son invasivos, como el mostrado en [4], que incluye un sistema de ubicación geográfica, sensores de humedad, temperatura y radiación solar, este dispositivo se instala pegándolo en la espalda de un abejorro. El trabajo presentado en [10] desarrolla un sistema de visión para el conteo y reconocimiento de insectos voladores en la agricultura inteligente.

La imagen digital de los insectos voladores se obtiene cuando llegan a los sembradíos y los atrapan, para después detectar las diferentes especies de vuelo, como también el ambiente en el que se encuentre. La técnica utilizada es una red YOLO y una máquina de soporte vectorial (SVM, por sus siglas en inglés), en conjunto logran una exactitud aproximada al 90 %.

3. Desarrollo

La Figura 1 muestra la propuesta del sistema de visión artificial inteligente para la detección y monitorización de polinizadores: MonPo. El sistema está colocado en el área de monitorización (planta), donde se detecta la presencia de los diferentes insectos voladores que circulan, por medio de un sensor modelo HC-SR501, conocido como

Tabla 1. Conjunto de datos de entrenamiento y prueba.

| Clase | Imágenes de entrenamiento | Imágenes de prueba | Total |
|----------|---------------------------|--------------------|-------|
| Abeja | 1154 | 385 | 1539 |
| Mariposa | 116 | 372 | 1488 |
| Fondo | 1071 | 357 | 1428 |

sensor infrarrojo piroeléctrico (PIR, por sus siglas en inglés), este sensor detecta el movimiento de cuerpos que emiten radiación electromagnética infrarroja dependiendo de su temperatura. Una vez que el insecto haya sido detectado, el sensor manda una señal digital en alto para proceder a la activación y toma de fotos mediante la cámara, se toma una ráfaga de imágenes en un lapso de tiempo determinado, mientras que el insecto está realizando la polinización en las flores.

Posterior a la captura de fotografías, las imágenes se procesan con ayuda de la Raspberry Pi, mediante un modelo elaborado a través de una red neuronal convolucional (VGG-16 [9]), la cual está entrenada con un conjunto de datos.

Una vez entrenada, se realiza el análisis de la clasificación y predicción en tiempo real acerca de los insectos mencionados anteriormente. Por último, una vez terminado la experimentación de la predicción, se envía un bit que contenga la etiqueta que pertenece a cada clase del insecto detectado.

3.1. Adquisición de imágenes

En la Figura 2 se muestra el proceso para realizar la adquisición de imágenes y la preparación de éstas para la configuración del entrenamiento.

Antes de adquirir las imágenes, es importante dividir en clases los diferentes tipos de polinizadores utilizados, los cuales son: “abejas” y “mariposas”, además se considera una clase extra, la cual pertenece a la planta y se denomina “fondo”, las imágenes se guardan en formato “jpg” o “png”.

– Asignación de nombres.

Se realiza el cambio de nombre de las fotografías, se modifica el nombre por defecto generado por la cámara a una cadena que compuesta por una numeración consecutiva para cada imagen.

– Número de clases.

Posteriormente, se etiquetan las clases con números, es decir, para la clase abejas se le proporciona el número “1”, para “mariposa” el número “2” y por último para “fondo/vacío” el número “3”.

– Conjunto de datos.

Para que el sistema realice la identificación y detección de insectos polinizadores, es necesario entrenar la red neuronal convolucional (VGG16, ver Figura 3), por medio de imágenes referentes a abejas, mariposas y fondo, es importante mencionar que algunas imágenes fueron obtenidas de la base de datos de la plataforma




Fig. 5. Diagrama electrónico del sistema.

“Kaggle”, además se complementó con fotografías propias adquiridas en pruebas en el área de experimentación. El conjunto de datos se divide con el número total de imágenes por cada clase, teniendo un 75 % para el apartado de entrenamiento y un 25 % para validación.

– Almacenamiento de imágenes.

El modelo de la red neuronal convolucional VGG16 se genera por medio del notebook “Google Colab”, debido a esto, es necesario subir las carpetas de las clases mencionadas anteriormente a la plataforma de “Google Drive”.

– Listado de clases almacenadas.

Por otra parte, antes de proceder a la configuración de entrenamiento, se genera un archivo de texto con extensión “.txt”, con el propósito de listar las imágenes que pertenecen al conjunto de datos de entrenamiento para cada clase.

3.2. Configuración de la red y generación del modelo

Con base en el método de aprendizaje profundo se hace el proceso de entrenamiento, con el propósito de realizar predicciones, es decir, crear un modelo que se adapte a la necesidad del proyecto, en este caso, enfocado para el análisis de los diferentes insectos polinizadores, de manera que realice la detección y clasificación en tiempo real en un entorno adaptado y monitorizado.

La Figura 4 muestra el proceso para la configuración y generación del modelo, debido a que se trabaja en Google Colab [2], primero se da acceso a las carpetas de Google Drive. Teniendo los permisos solicitados, para comenzar con el proceso de entrenamiento se requiere hacer la importación de las librerías necesarias tales como, el módulo de keras [3] para el procesamiento de las imágenes, creación del modelo, el módulo numpy para la creación de vectores y módulos como sklearn [8] que contiene algoritmos de clasificación.




Fig. 6. Diagrama de flujo del funcionamiento del sistema.

Una vez establecido el modelo de la red neuronal convolucional, se establecen los parámetros para el entrenamiento. Finalmente, con el conjunto de datos distribuido como se muestra en la Tabla 1 se procede a la creación del modelo denominado “polinizadores3.h5.”, el cual se exporta a la Raspberry Pi 3.

3.3. Diagrama electrónico

Para el sistema desarrollado, el sensor PIR utilizado es el modelo hc-sr501, el cual tiene la función de detectar el movimiento. Además, cuenta con tres terminales de conexión, una para voltaje de alimentación (5V), la segunda para la señal de salida, la cual está conectada al GPIO 23 (pin de propósito general de entrada/salida, General Purpose Input/Output) de la tarjeta, finalmente, la tercera se conecta a tierra.

Por medio de este sensor se detecta el movimiento del insecto cuando está realizando la polinización, mandando una señal digital en alto cada vez que manifieste algún movimiento. De igual manera, se emplea una cámara web, modelo Logitech C525, conectada por medio del puerto USB 2.0 a la tarjeta Raspberry Pi 3. La Figura 5 muestra el diagrama electrónico del sistema.

3.4. Proceso del sistema MonPo

La Figura 6 muestra el diagrama de flujo del proceso que realiza el sistema MonPo para la detección y clasificación de polinizadores. Primero, los dispositivos se colocan en el área de experimentación, después se carga el modelo “polinizadores3.h5”.



Fig. 7. Posicionamiento de la cámara en el jardín.

Una vez cargado el modelo y ejecutado el programa, el sensor PIR se queda a la espera de la presencia de algún polinizador en el área específica, la señal de movimiento enviada por el sensor activa el funcionamiento del sistema, después se genera una carpeta para el almacenamiento de las fotografías capturadas por la cámara web de los insectos en movimiento. Posteriormente, se procesan las imágenes para la clasificación, en caso que, el modelo haya detectado algún polinizador, envía un mensaje en el puerto serial con el nombre del insecto.

Es importante destacar que el viento puede provocar la activación del sensor, por esta razón existe la clase “fondo”, además el sensor es capaz de accionarse con el desplazamiento de algún objeto, incluso de la misma planta, lo anterior implica que el polinizador debe estar en el ángulo de alcance, el cual es de 120° .

4. Resultados

Para las pruebas de experimentación se realizan dos procesos diferentes, uno cuenta con un sensor para la detección de movimiento de los polinizadores, el segundo se basa en la ejecución del programa con las imágenes almacenadas en la Raspberry Pi 3 para la validación.

El proceso de experimentación es por medio de ejecución remota, es decir, justo después de colocar el sistema completo en el área de prueba, se procede a ejecutar el programa en el momento que se encuentre un polinizador en la zona, para que realice la captura de fotografías mientras que los insectos llevan a cabo la polinización, posterior a eso, se realiza el análisis para la clasificación e identificación.

Para la primera prueba del modelo denominado se obtienen resultados satisfactorios debido a que la estación se colocó en una posición en donde la cámara hace el encuadre al jardín donde se encuentran las flores para tomar fotografías de “vacío/fondo”, como se muestra en la figura 7.



Fig. 8. Fotografías capturadas por la Raspberry Pi y Webcam.

La figura 8 muestra imágenes capturadas por la Raspberry Pi y la Webcam, obteniendo fotografías nítidas de algunas flores del jardín para su posterior análisis y clasificación. Considerando las muestras obtenidas de la experimentación pasada, se opta por entrenar el modelo para aumentar su exactitud de predicción, con el fin de ponerlo en práctica en la segunda fase de experimentación, por lo que se encuentra automatizado gracias a la implementación del sensor de movimiento mencionado anteriormente.

Como se muestra en la Figura 7 para realizar las pruebas en un entorno real de experimentación, se coloca en el jardín de experimentación del Centro de Investigación e Innovación en Tecnologías de la Información y Comunicación (INFOTEC), donde el funcionamiento del sistema se puede efectuar al momento de que el insecto volador se presente frente al sensor, al mismo tiempo que éste realiza la actividad de polinización.

Al momento de cumplir alguno de los dos casos anteriores, es decir, si el sensor es activado, se procede a crear una carpeta con el nombre de cada prueba capturada y el número de detección al que pertenece, una vez teniendo este espacio, se procede a capturar por medio de la cámara web, una ráfaga de 8 imágenes.


Posteriormente, se lleva a cabo el análisis de clasificación e identificación de la información obtenida por esta misma, el resultado se muestra en un archivo CSV con la predicción realizada por el modelo mediante una etiqueta.

El proceso para evaluar el modelo entrenado se realiza con la validación del conjunto de datos reservado para ello (25%). Los resultados obtenidos se muestran en la Tabla 2. Las métricas de precisión, recall y F1-score muestran que el desempeño de la red VGG-16 supera en la mayoría de las clases el 90%.

Finalmente, en la figura 9 se muestra un ejemplo de la validación del experimento realizado en el sistema inteligente, en las figuras 9a, 9b y 9c se encuentran cada una las clases; abeja, mariposa y fondo respectivamente.

Tabla 2. Resultados de las métricas de validación para cada clase.

| | Precision | Recall | F1-score | Support |
|--------------|------------------|---------------|-----------------|----------------|
| Abeja | 0.9828 | 0.8909 | 0.9346 | 385 |
| Mariposa | 0.9046 | 0.9946 | 0.9475 | 372 |
| Fondo | 0.9607 | 0.9580 | 0.9593 | 357 |
| Accuracy | | | 0.9470 | 1114 |
| Macro avg | 0.9494 | 0.9478 | 0.9471 | 1114 |
| Weighted avg | 0.9496 | 0.9470 | 0.9468 | 1114 |

**Fig. 9.** Validación de clases.

5. Conclusiones

En el presente trabajo se hizo uso de una red convolucional VGG-16, además se incluye un escenario de internet de las cosas (IoT, por sus siglas en inglés), con el objetivo de clasificar y detectar polinizadores, específicamente abejas y mariposas. Asimismo, se muestra el uso de procesadores digitales, como lo es una tarjeta Raspberry Pi 3, para la implementación de un modelo de aprendizaje profundo, el cual se aplica en la clasificación de imágenes.

Los resultados presentados en la Tabla 2 muestran un buen desempeño en las métricas establecidas, en cuanto a la prueba sin la implementación del sensor PIR, se obtuvo porcentajes mayores al 95 % de exactitud en 199 imágenes capturadas. Para la última sección de clasificación con los datos de validación pertenecientes al 25 % del total de imágenes de cada una de las clases, en la mayoría de los casos tuvo como resultante porcentajes mayores al 90 %.

El sistema MonPo permite almacenar los datos, particularmente la identificación de polinizadores, así como su comportamiento con las plantas, debido a que se captura la fecha y hora en la cual estuvo presente el insecto. Lo anterior, permitirá realizar un análisis referente a la presencia de polinizadores en las diferentes estaciones del año, así como las plantas que favorecen la polinización. Además, el sistema puede tener más datos para identificación de más factores agroclimáticos, mediante el uso y lectura de más sensores, como lo pueden ser de temperatura, humedad, velocidad del viento, entre otros.

Agradecimientos. Los autores agradecen al Consejo Nacional de Ciencia y Tecnología. En particular, a los proyectos números 576, 735 y 737 del Programa Cátedras CONACyT.

Referencias

1. Bartomeus, I., Dicks, L. V.: The need for coordinated transdisciplinary research infrastructures for pollinator conservation and crop pollination resilience. *Environmental Research Letters*, vol. 14, no. 4 (2019) doi: 10.1088/1748-9326/ab0cb5
2. Carneiro, T., Da Nóbrega, R. V. M., Nepomuceno, T., Bian, G. B., De Albuquerque, V. H. C., Rebouças Filho, P. P.: Performance analysis of google colab as a tool for accelerating deep learning applications. *IEEE Access*, vol. 6, pp. 61677–61685 (2018) doi: 10.1109/access.2018.2874767
3. Chollet, F., et al.: Keras. <https://keras.io> (2015)
4. Iyer, V., Nandakumar, R., Wang, A., Fuller, S. B., Gollakota, S.: Living IoT: A flying wireless platform on live insects. In: *Proceedings of the 25th Annual International Conference on Mobile Computing and Networking*, pp. 1–15 (2019) doi: 10.1145/3300061.3300136
5. Kearns, C. A., Inouye, D. W., Waser, N. M.: Endangered mutualisms: The conservation of plant-pollinator interactions. *Annual Review of Ecology and Systematics*, vol. 29, no. 1, pp. 83–112 (1998) doi: 10.1146/annurev.ecolsys.29.1.83
6. Kulyukin, V., Mukherjee, S., Amlathe, P.: Toward audio beehive monitoring: Deep learning vs. standard machine learning in classifying beehive audio samples. *Applied Sciences*, vol. 8, no. 9, pp. 1573 (2018) doi: 10.3390/app8091573
7. Organización de las Naciones Unidas para la Agricultura y la Alimentación: La reducción de la población de abejas es una amenaza para la seguridad alimentaria y la nutrición. URL <http://www.fao.org/news/story/es/item/1194963/icode/>
8. Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., Duchesnay, E.: Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830 (2011)
9. Simonyan, K., Zisserman, A.: Very deep convolutional networks for large-scale image recognition (2014) doi: 10.48550/ARXIV.1409.1556
10. Zhong, Y., Gao, J., Lei, Q., Zhou, Y.: A vision-based counting and recognition system for flying insects in intelligent agriculture. *Sensors*, vol. 18, no. 5, pp. 1489 (2018) doi: 10.3390/s18051489