

ROBÓTICA E IA PARA LA DETECCIÓN DE PESTES DE TOMATE EN INVERNADEROS

En 2050, la población mundial alcanzará los 9.000 millones de personas, por lo que uno de los grandes retos globales es el desarrollo de soluciones que permitan avanzar hacia fuentes de alimentación sostenibles y eficientes a largo plazo. Tekniker, miembro de Basque Research and Technology Alliance (BRTA), participa en el proyecto europeo [GREENPATROL](#), enfocado a la creación de una solución para mejorar la producción agrícola en invernaderos gracias a la navegación autónoma, robótica e inteligencia artificial.



Figura 1: Prototipo GreenPatrol

La solución desarrollada (Figura 1) está compuesta por una plataforma móvil Segway RMP 440 Flex para la navegación, un brazo robot KUKA LBR iiwa 14 para la inspección de las plantas, 2 sensores OMRON OS32C que cubren todo el perímetro de la plataforma móvil y son utilizados para la seguridad en la navegación autónoma, un láser 3D VELOCITY VLP-16 para obtener información 3D extra para dar soporte a la navegación, un receptor GNSS para obtener la localización del satélite GALILEO, 2 cámaras RGBD RealSense D435 para la detección de personas y la detección de hojas a inspeccionar, dos cámaras RGB IDS UI-5240CP y UI-3013XC para la obtención de imágenes y un equipamiento de pulverización de insecticida desarrollado a medida.

Los mayores retos, tanto científicos como tecnológicos del proyecto GREENPATROL, han sido (1) la localización en interiores usando las señales de los satélites GALILEO [1], (2) la navegación autónoma de la plataforma robótica en un invernadero y (3) la detección automática de plagas usando inteligencia artificial.

Tekniker ha desarrollado el sistema de inspección basado en visión. Después de realizar una comparativa entre técnicas de visión por computador, Machine Learning y Deep Learning, se llegó a la conclusión de que los mejores resultados se obtenían usando Deep Learning [2]. A continuación, se describe el flujo llevado a cabo para la creación de un modelo de detección de las plagas más importantes (*Bemisia Tabaci*, *Trialeurodes Vaporariorum* y *Tuta Absoluta*) en distintos ciclos de vida (huevo, larva e insecto) en invernaderos de tomate (Figura 2)



Figura 2: Flujo creación modelo de Deep Learning

El flujo para la generación de un modelo de Deep Learning se divide en distintos pasos. El primer paso es la generación del dataset. Después de analizar distintos dataset públicos de pestes en plantas de tomate, ninguno contenía las pestes anteriormente citadas. Por lo tanto, se comenzaron a obtener imágenes en dos ubicaciones distintas usando distintas técnicas. Por un lado, en la universidad de Mendel en Brno (República Checa), investigadores del departamento de química y bioquímica de la universidad se encargaron de originar las pestes de manera controlada en distintas cámaras de cultivo. Ellos se encargaron de obtener imágenes de manera manual durante los distintos ciclos de vida de cada peste. Por otro lado, en un invernadero de Lezama se puso un sistema automático de captura de imágenes usando un micro-controlador y una cámara que se movía de manera horizontal y vertical. Mientras se iban captando las distintas imágenes con pestes, expertos de la universidad de Mendel se encargaron de etiquetar las imágenes. Los expertos marcaban dónde se encontraba la peste y de qué tipo era usando una versión modificada de la herramienta de código libre LabelImg [3]. Se etiquetaron 6893 imágenes con distintas pestes. A su vez, se aplicaron distintas técnicas de aumentación de datos (rotaciones, giros verticales y horizontales, añadir ruido, transformaciones, etc.) para aumentar el número de imágenes del dataset y su variabilidad.

Una vez generado el dataset, los siguientes pasos son relacionados con el entrenamiento del modelo. Después de realizar una comparativa entre distintos modelos para aplicar la técnica de aprendizaje por transferencia, se seleccionó el modelo Faster R-CNN ResNet101 [4], ya que obtiene buenos resultados para encontrar objetos pequeños si el tiempo de inferencia no es un factor crítico. El siguiente paso fue la selección de la combinación ideal de los hiperparámetros de entrenamiento. Este es uno de los pasos más complicados del proceso de creación del modelo. El modelo fue entrenado en un PC Intel Core i7 8TH PC con una tarjeta gráfica NVIDIA GEFORCE GTX 1060 6GB. Según la evolución de los resultados, distintos hiperparámetros fueron modificados y el proceso de entrenamiento se volvió a repetir.



Figura 3: Detección de pestes usando IA

La Figura 3 muestra dos ejemplos de detección de Bemisia Tabaci y Tuta Absoluta en plantas de tomate.

REFERENCIAS

1. Obregón D. et al. (2019) Precise Positioning and Heading for Autonomous Scouting Robots in a Harsh Environment. In: Ferrández Vicente J., Álvarez-Sánchez J., de la Paz López F., Toledo Moreo J., Adeli H. (eds) From Bioinspired Systems and Biomedical Applications to Machine Learning. IWINAC 2019. Lecture Notes in Computer Science, vol 11487. Springer, Cham
2. Gutierrez, A., Ansuategi, A., Susperregi, L., Tubío, C., Rankić, I., & Lenža, L. (2019). A Benchmarking of Learning Strategies for Pest Detection and Identification on Tomato Plants for Autonomous Scouting Robots Using Internal Databases. *Journal of Sensors*, 2019.
3. Tzutalin. LabelImg. Git code (2015). <https://github.com/tzutalin/labelImg>
4. Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. In *Advances in neural information processing systems* (pp. 91-99).

AGRADECIMIENTOS

This project has received funding from the European GNSS Agency under the European Union's (EU) Horizon 2020 research and innovation programme under grant agreement no. 776324.