

IDENTIFICACIÓN Y GEORREFERENCIACIÓN COOPERATIVA DE FOCOS LARVARIOS UTILIZANDO VEHÍCULOS AÉREOS NO TRIPULADOS

(PINV18-596)

Ing. David Britez

October 28, 2021

Contenido

Introducción

Recolección de imágenes

Metodología

- Preprocesamiento de datos.

- Entrenamiento de la red neuronal

Detección y geolocalización de objetos en ortomosaico

- Generación de ortomosaico

- Geolocalización de objetos en ortomosaico

Pruebas y Resultados

- Redes Neuronales

- Visualización de resultados

Introducción

- La epidemia del dengue toma lugar en Paraguay año tras año, el dengue es una enfermedad viral que tiene 4 serotipos
- la epidemia del año 2018 se debió al serotipo 1.
- En el año 2019 los serotipos circulantes fueron serotipo 1, 2 y 4, con una tasa de mortalidad de 0.076, según Plataforma de Información en Salud para las Américas (PLISA), .
- Solo en Asunción (Capital del país) los neumáticos usados, cubetas descartables y desechos sólidos como criadero de mosquito representan entre un 58% a 72% del total de criaderos entre los años 2011 y 2014.
- Por lo que la eliminación de los criaderos de mosquitos es primordial para prevenir la propagación del virus.

Introducción

Por lo tanto el propósito de este trabajo es aplicar redes neuronales convolucionales (CNN) para detección y geolocalización de neumáticos como posibles focos larvarios, en imágenes obtenidas mediante un dron.

Recolección de imágenes

La recolección de imágenes se realizó con un drone *DJI Mavic 2 Pro*, el mismo captura imágenes con resolución de 5472×3648 píxeles, y vídeo hasta 4K, autonomía de vuelo hasta 31 minutos y velocidad máxima de 72 km/h.



Pix4D Capture

Para la planificación de vuelo se utilizó la aplicación *freeware Pix4D Capture* y con soporte para el *Mavic 2 Pro*. Fueron colocadas de forma estratégica cubiertas de vehículos en zonas de distintos contrastes para tener la mayor variedad posible a la hora de entrenar la red neuronal. La altura de vuelo seleccionada fue de 70 m, obteniendo así un *Ground Sample Distance (GSD)* de 2.45 cm/píxel, esto debido a que en la zona se encuentran antenas de telefonías locales con alturas de 60 m.

Pix4D Capture




En esta sección se presentan los procedimientos realizados para:

- Pre procesamiento de los datos.
- Entrenamiento de la red neuronal.
- Evaluación de la red neuronal.


Preprocesamiento de datos

En esta sección se presentan los procedimientos realizados para el pre procesamiento de los datos, entrenamiento de la red neuronal, generación de un ortomosaico y como realizar la geolocalización. El preprocesamiento consiste en seleccionar las imágenes relevantes para el entrenamiento de la red. Las imágenes fueron etiquetadas mediante la utilización de la herramienta *LabelImg*, que consisten en encerrar en recuadros los objetos que queremos detectar y asignar una etiqueta, debido a la resolución de las imágenes de 5472×3648 píxeles, fue necesario realizar un sectorización de las zonas de interés donde efectivamente se encuentran los neumáticos, obteniendo imágenes de 300×300 píxeles.

Preprocesamiento de datos



DJI_0114.jpg



DJI_0115.jpg




DJI_0116.jpg




DJI_0141.jpg



DJI_0145.jpg




DJI_0156.jpg



DJI_0190.jpg



DJI_0196.jpg

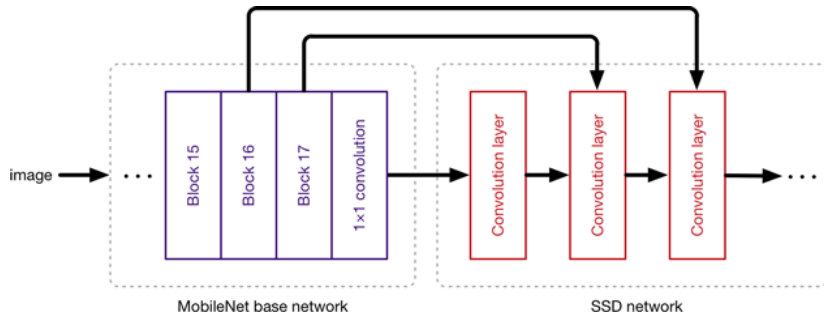


DJI_0197.jpg

Entrenamiento de la red neuronal

La red neuronal entrenada fue la *SSD Mobilenet V2 fpn lite 320x320*, las redes *SSD Mobilenet* son unas de las mas utilizadas para realizar detección de objetos en tiempo real debido a su velocidad y precisión. La velocidad de esta red se debe a que utiliza la red *Mobilenet V2* como extractor de características, y posteriormente la red *SSD* para realizar la detección de objetos.

Entrenamiento de la red neuronal




Entrenamiento de la red neuronal

El entrenamiento se realizó durante 50K pasos, debido a la estabilización de la curva de aprendizaje. Esta red fue entrenada en la plataforma *Google Colab* con una *GPU Tesla T4* y las siguientes configuraciones de pipeline, *batch size* de 16, y para compensar la cantidad de imágenes para el entrenamiento, se utilizaron las técnicas de *data augmentation* de *horizontal flip*, *vertical flip*, *rotation 90* de tensorflow. Para el entrenamiento se utilizaron imágenes de 300x300 píxeles con neumáticos (también conocidas como llantas en Paraguay), separadas en 163 imágenes para *train*, aproximadamente 75% del total y 57 imágenes para *test* aproximadamente 25% del total.

Entrenamiento de la red neuronal

Loss/total_loss
tag: Loss/total_loss





Evaluación de la red neuronal

Para determinar que tan precisa es la red neuronal se deben tener en cuenta cuatro casos posibles a la hora de realizar una detección, Verdaderos Positivos (TP) donde detecta un neumático en la imagen y efectivamente hay neumático, Verdaderos Negativos (TN) donde la red no detecta un neumático y efectivamente no hay, Falsos Positivos (FP) donde la red detecta neumático donde efectivamente no hay neumático y Falsos Negativos (FN) cuando la red no es capaz de detectar donde si hay neumático.

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

Evaluación de la red neuronal



Evaluación de la red neuronal

Los parámetros de evaluación para la red son los siguientes:

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1Score = \frac{2 * Recall * Precision}{Recall + Precision} \quad (4)$$

Generación de ortomosaico

Para la obtención del *ortomosaico* se utilizó la aplicación *WEB ODM open source*, la misma puede ser utilizada para generar modelos 3D, modelos de elevación, curvas de nivel, y generar ortomosaicos georeferenciados.

Una vez se procesen las imágenes se puede visualizar el ortomosaico en el mapa, ver modelo 3D o descargar los archivos. Para realizar la geolocalización mediante la generación de un *ortomosaico* con *WEBODM*, y así cada *pixel* de la misma tiene una latitud y longitud asignada.

Geolocalización de objetos en ortomosaico.



Geolocalización de objetos en ortomosaico

Para la obtención de coordenadas a partir del ortomosaico se utilizo la librería *rasterio*, de *python*, la misma permite leer y escribir datos *raster* (datos geoespaciales organizados en forma de matriz) pero en formato de *numpy array* (Libreria de *python* que permite trabajar con vectores n dimensionales).

Geolocalización de objetos en ortomosaico

Para esto simplemente se debe especificar a *rasterio* cual es la imagen en formato tif de la cual se desea obtener las coordenadas geospaciales y el sistema de referencia de coordenadas utilizado, y el resultado son dos matrices con las mismas dimensiones que la imagen de entrada, la primera matriz contiene la latitud de cada píxel y la segunda la longitud de cada píxel.


Geolocalización de objetos en ortomosaico

Entonces una vez que la red neuronal detecta un objeto, las coordenadas del centro del mismo corresponde a la posición de la matriz de latitud y longitud obtenidos con *rasterio*. De esta forma una vez que la red detecte un objeto las coordenadas en píxeles (x,y) del mismo son la fila (x) y columna (y) correspondiente tanto en la matriz de latitud como en la de longitud.

Pruebas y Resultados

En esta sección se presentan la pruebas realizadas para la detección de neumáticos en ortomosaico, los enfoques abordados, y los resultados.

1. Utilización de una CNN de detección aplicada a un ortomosaico (EQ1).
2. Utilización de una CNN de súper resolución en conjunto con la CNN de detección aplicada a un ortomosaico (EQ2).



Pruebas y Resultados

En la siguiente figura se puede apreciar la mejora en cuanto a la utilización de una CNN súper resolución, esta aporta mayor información a la CNN de detección para aumentar el rendimiento, sin embargo.

Métrica	Test	EQ 1	EQ 2
Accuracy	94.82%	92.3%	98.75%



Visualización de resultados

Los resultados de detección son corroborados por una persona, estos resultados son almacenados en la BD, Mongo DB, con los siguientes datos:

- Etiqueta del objeto detectado (Ej. Llanta)
- Latitud
- Longitud
- Nivel de confianza
- Fecha
- Ciudad
- Numero de misión

Y estos datos son presentados en Google Data Studio.

Proyecto de Investigación PINV 18-596

"Identificación y Georreferenciación Cooperativa de Focos Larvarios utilizando Vehículos Aéreos no Tripulados"

Filtrar por:

Objeto detectado

Ciudad


Mision

Nivel de Confianza

0

100

Selecciona un periodo



Objeto: ● Basura ● Terreno baldío ● Neumatico ● Pozo ● Piscina ● Tanque

