

## Reconocimiento automático de ganado bovino a partir de imágenes aéreas tomadas con drones: Un enfoque exploratorio.

### Automatic recognition of cattle from aerial images taken with drones: An exploratory approach

Diana Isabel Gómez Bedoya<sup>1\*</sup>, Reinel Castrillón<sup>2\*</sup>

<sup>1</sup>Facultad de Ingenierías, Universidad Católica de Oriente, Colombia

<sup>2</sup>Grupo de Investigación GIMU, Universidad Católica de Oriente, Colombia

\*Autor de correspondencia: lcastrillon@uco.edu.co

**RESUMEN**– El sector ganadero en Colombia se ha visto afectado en los últimos años por el aumento del robo de ganado bovino generando pérdidas millonarias para el gremio. La ganadería en el país se realiza por pastoreo extensivo lo que hace difícil de monitorear los animales en tiempo real. En este trabajo se propuso una primera fase hacia la construcción de un sistema para la vigilancia automática de ganado a cielo abierto, mediante la adquisición de imágenes aéreas tomadas con drones. Para llevarlo a cabo, se tomaron alrededor de 13000 fotografías de ganado en cuatro fincas del oriente antioqueño, se etiquetaron manualmente y se construyó un modelo para la detección de ganado a partir de una arquitectura de redes neuronales profundas llamada YOLO. En las métricas de evaluación de desempeño del modelo entrenado, se obtuvieron valores de precisión del 82% con niveles de sensibilidad del 75% en etapas de prueba y validación. A pesar de que el estudio planteado es de tipo exploratorio, los resultados obtenidos muestran el potencial de utilizar este tipo de herramientas en la construcción de una aplicación funcional para la prevención del robo de ganado en Colombia.

**Palabras clave**– *Abigeato, aprendizaje profundo, detección de objetos, redes neuronales convolucionales, YOLO.*

**ABSTRACT**– The livestock sector in Colombia has been affected in recent years by the increase in the theft of bovine cattle, generating millions of losses for the sector. Extensive grazing carries out livestock in the country, which makes it difficult to monitor the animals in real time. This paper proposes a first phase towards the construction of a system for the automatic monitoring of livestock in the open sky through the acquisition of aerial images taken with drones. To carry it out, about 13,000 photographs of cattle are captured in four farms in eastern Antioquia, manually labeled and a model for cattle detection is constructed from a deep neural network architecture called YOLO. In the performance evaluation metrics of the trained model, precision values of 82% are obtained with recall levels of 75% in the testing and validation stage. Although the proposed study is exploratory, the results show the potential to use this type of tools in the construction of a functional application for the prevention of cattle theft in Colombia.

**Keywords**– *Cattle theft, convolutional neural networks, deep learning, object detection, YOLO.*

### 1. Introducción

Colombia es un país de vocación agrícola. La ganadería es la actividad más importante del sector agropecuario, donde se destaca particularmente la producción bovina. De acuerdo con datos del ministerio de Agricultura, la actividad ganadera predomina en 27 de los 32 departamentos del país [1]. La leche y la carne hacen parte fundamental de la dieta del colombiano promedio, es por esta razón, que la afectación del sector de cualquier tipo incide de manera directa o indirecta en cada uno de los ciudadanos.

Uno de los grandes flagelos del sector ganadero en el país es el abigeato [2]–[5], nombre técnico con el que se conoce al hurto de ganado. De acuerdo con cifras de

autoridades como la Fiscalía, la Policía Nacional y las alcaldías de varios municipios de Antioquia, Arauca, Bolívar, Casanare, Cesar, Córdoba, La Guajira, Magdalena Medio y Meta, entre el año 2012 y el año 2016 se presentaron en Colombia 9024 casos de hurto de ganado; esto trae consigo pérdidas económicas para el sector, por ejemplo, en el departamento del Cesar se han reportado pérdidas anuales de 13200 millones de pesos (COP), en Antioquia se estiman pérdidas por 400 millones de pesos (COP) y en la Guajira las pérdidas están calculadas en 1200 millones de pesos (COP) [6].

El sector agropecuario en Colombia se caracteriza por su poco grado de tecnificación [1] lo cual contrasta con las evoluciones tecnológicas y desarrollos científicos que

se adelantan a nivel mundial. El uso de la tecnología como una herramienta que pueda ayudar a prevenir el hurto de ganado parece no ser considerado en los ámbitos locales, a pesar de que la ganadería en el país se realiza principalmente por pastoreo extensivo y el proceso de vigilancia de grandes cantidades de ganado en extensos territorios resulta en una tarea de alta complejidad, poco precisa y demandante de gran cantidad de tiempo y esfuerzo físico.

### 1.1 Trabajos relacionados

En la literatura científica se han propuesto diferentes herramientas tecnológicas para realizar vigilancia de animales en espacios libre:

Puetaman et al. (2014) propusieron un dispositivo prototipo basado en tecnología *Xbee* que, ubicado en el cuello de la res, puede determinar el estado de vida del animal mediante el monitoreo de la temperatura y, además, identificar si el animal se encuentra dentro del área de pastoreo permitida, mediante la emisión de una señal de radiofrecuencia transmitida desde el dispositivo a un sistema central [7].

Por otro lado, Kaixuan y Dongjian (2015) propusieron algoritmos de procesamiento de imágenes para la detección de vacas en estado libre con el fin de realizar análisis de comportamiento. Las pruebas fueron realizadas a partir de capturas de video con cámaras estáticas en primer plano, alcanzando niveles de detección (en ambiente no controlado y con luz natural) del 88.34% [8].

Simarcek et al. (2012) presentaron una solución para el conteo de animales en vía silvestre para propósitos de conservación a partir de la aplicación de técnicas de visión por computador sobre imágenes satelitales. Los investigadores utilizaron las diferencias en reflectancia espectral existentes entre los especímenes a detectar y su entorno. Mediante métodos de segmentación rápida, funciones de densidad de probabilidad y teoría de grafos se logran aislar los individuos para el conteo alcanzando niveles de sensibilidad superiores al 90% [9]. Un enfoque similar mediante la utilización de imágenes satelitales, técnicas de aprendizaje automático, sistemas neurodifusos y procesamiento de señales para la identificación y conteo de grandes mamíferos, fue propuesto por Xue et al. (2017) [10].

En esta misma línea de tareas de censo y conservación de especies salvajes, van Gemert et al. (2014)

propusieron un sistema de conteo de animales usando imágenes capturadas con drones. Ellos utilizaron algoritmos DPM (*Deformable Part-based Model*) para la detección de los objetos de interés y máquinas de soporte vectorial (SVM) para su clasificación. Ellos obtuvieron niveles de sensibilidad de 0.72 aproximadamente [11].

Lhoest et al. (2015) propusieron una nueva metodología para el conteo de comunidades de hipopótamos mediante el uso de drones y cámaras térmicas infrarrojas, realizando la detección mediante la aplicación de técnicas de procesamiento digital de imágenes (segmentación por polígonos, niveles de gris, ubicación de centroides) [12]. Los resultados mostraron errores de conteo promedio de 2.3%.

Chamoso et al. (2014) utilizaron imágenes aéreas tomadas con drones y redes neuronales convolucionales para el conteo de ganado en fincas, obteniendo precisiones de conteo superiores al 97% [13]. Sadgrove et al. (2017) propusieron un sistema general para la detección de objetos en fotografías aéreas en zonas de pastoreo utilizando características de color. Generalmente, el uso de color en imágenes requiere mayor cantidad de cómputo para su procesamiento; sin embargo, los autores propusieron el uso de un nuevo enfoque al utilizar redes neuronales artificiales con aprendizaje extremo de máquina con el fin de reducir la carga computacional. Los autores lograron obtener porcentajes en la detección de ganado del 86% sobre un total de 200 muestras [14]. Andrew et al. (2017) propusieron un sistema usando imágenes capturadas con drones y visión por computador con aprendizaje profundo, para la identificación y localización de un tipo particular de ganado (*Holstein Friesian*), alcanzando niveles de precisión del 99.3%. El principal aporte de este trabajo es que además de detectar el ganado, los animales también pueden ser individualizados [15].

Finalmente, Sharma y Shah (2017) proponen un sistema para vehículos autónomos para la detección de animales en vías con el fin de prevenir accidentes. Ellos lograron identificar correctamente los animales en carreteras con una precisión del 82.5% con un vehículo viajando a 35 km/h, en un tiempo suficiente para evitar la colisión. Para el sistema de detección y reconocimiento, ellos utilizan 2200 imágenes de animales, a diferentes distancias y ubicaciones, utilizan filtros HOG (histograma de gradientes orientados) para

la extracción de descriptores y clasificadores en cascada para la identificación [16].

## 1.2 Brechas de investigación y desafíos

A partir de la revisión de las diferentes investigaciones científicas reportadas con el tema de detección de animales en espacios abiertos o de pastoreo, se extraen las siguientes consideraciones:

- El uso de dispositivos ubicados sobre el animal muestra ser una alternativa funcional, sin embargo, hay algunos inconvenientes que pueden limitar su uso como, por ejemplo: el dispositivo puede ser manipulado, es invasivo y puede representar una molestia para el animal, hay dependencia de un sistema central de información en constante operación, puede requerir personal experto, es costoso y, en entornos agrestes, puede estar sujeto a fallas.
  - El uso de cámaras fijas que capturen los animales en primer plano resulta útil para clasificación, individualización y análisis de comportamiento (alimentación, reposo, movimiento de la boca, locomoción, gestación, celo), no así para aplicaciones de vigilancia y conteo.
  - El uso de cámaras térmicas ubicadas en drones es efectivo para la detección de grandes especies animales en vida salvaje. Este tipo de tecnología puede ser incorporado al conteo de ganado. Pese a ello, esta tecnología aún puede resultar costosa para un ganadero promedio. Además, una de las principales ventajas del uso de cámaras térmicas es la vigilancia nocturna, característica que no sería utilizada en este contexto, debido a que en Colombia el ganado es guardado en establos durante las horas de la noche.
  - El uso de imágenes satelitales no resulta viable actualmente para aplicaciones en tiempo real.
  - Aprovechar las características fenotípicas de una raza de ganado en particular ayuda considerablemente para la identificación de ganado; sin embargo, en una proporción considerable de fincas ganaderas en Colombia se trabaja con diferentes tipos de raza simultáneamente.
  - El uso de fotografías capturadas en espacios no controlados representa grandes desafíos en el desarrollo de aplicaciones de detección e identificación de objetos. Las imágenes varían de acuerdo al ángulo del sol, reflexión de la luz, el fondo del objeto, la distancia del objeto, cambios de brillo durante el día, tipo de cámara, estación del año, etc.
- Escriba el tto aquí

- La captura de imágenes aéreas usando drones, aplicando técnicas de visión por computador, aprendizaje automático y aprendizaje profundo, es el camino a seguir en el desarrollo de aplicaciones para el conteo y detección de objetos en espacios abiertos.

Del análisis de estas consideraciones resulta claro que a la fecha no se cuenta con una aplicación completamente funcional que pueda ser utilizada para el monitoreo automático de ganado en espacio abierto. Por lo tanto, es necesario desarrollar un sistema de vigilancia y conteo que utilice imágenes adquiridas con drones, que pueda ser utilizado como un mecanismo para prevenir el robo de ganado en el país. El sistema a desarrollar debe incluir funcionalidades como:

- Procesamiento en tiempo real.
- Algoritmos para la detección automática del ganado.
- Algoritmos para seguimiento y conteo.
- Autonomía de vuelo en drones.
- Algoritmos óptimos para los recorridos en drones (garantizar el conteo completo en la menor cantidad de tiempo).

En este trabajo se presenta una aproximación inicial hacia la realización de las primeras dos funcionalidades propuestas, esto es, desarrollar herramientas algorítmicas para el reconocimiento automático de ganado de diferentes razas, en tiempo real, mediante la utilización de redes neuronales convolucionales de alto desempeño (*YOLO V2*), que puedan ser incorporadas a sistemas de vigilancia aérea (drones). Se propone un enfoque exploratorio debido a que, a pesar de que los estudios revelan resultados alentadores en el área, el tema aún se encuentra en una etapa de germinación.

## 2. Materiales y métodos

En la **Figura 1** se presenta en esquema general de cada una de las etapas seguidas en el desarrollo de este trabajo. Inicialmente se realizó un proceso de adquisición de las imágenes; posteriormente se realizaron manualmente las anotaciones sobre las imágenes; en tercer lugar, los conjuntos de imágenes se dividieron entre datos de entrenamiento y datos de prueba; en el paso siguiente se realizó el proceso de detección de ganado en las fotografías utilizando redes neuronales

convolucionales; y finalmente, se evaluó el desempeño del sistema entrenado utilizando diferentes métricas.

## 2.1 Adquisición

Los conjuntos de imágenes aéreas fueron adquiridos con un dron *DJI Phantom 3* el cual tiene integrada una cámara (resolución de imagen  $1920 \times 1080$ , 30 fps) con movimiento a tres ejes en un sistema de cardán. Las fotografías fueron adquiridas en cuatro fincas del municipio de La Ceja, oriente antioqueño, en diferentes jornadas y horas del día. En ninguna de las fincas había una raza de ganado predominante, por lo tanto, en cada una de las imágenes se observan vacas con diferentes características fenotípicas. No se siguió ningún protocolo de vuelo para la captura de las imágenes, sin embargo, las fotografías se tomaron a una distancia no menor de 15 m, con el fin de evitar el estrés, ansiedad y alteración del comportamiento natural de los animales. Después del proceso de adquisición, se cuenta con una base de datos de 13346 imágenes.

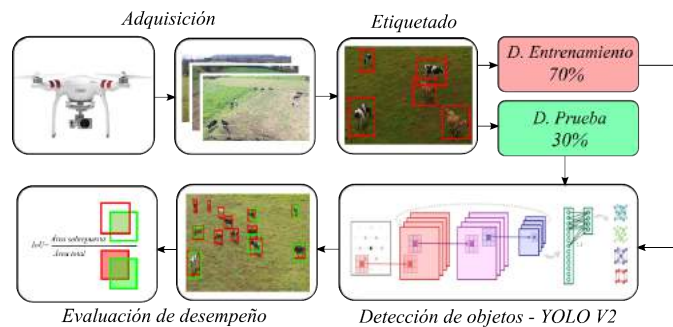


Figura 1. Esquema de la metodología propuesta.

## 2.2 Etiquetado

El uso del detector de objetos en imágenes empleado en este trabajo (*YOLO V2*) requiere datos de entrenamiento que incluyan etiquetas de cada una de las clases de objetos que se desea identificar. Estas etiquetas corresponden a recuadros dibujados sobre cada una de las imágenes en el lugar que se encuentran los objetos de interés (la ubicación de las vacas para este caso). El proceso de etiquetado debió realizarse manualmente sobre cada imagen. Si bien existen múltiples herramientas para realizar este proceso, en este trabajo se utilizó *DarkLabel V.1.3* [17], debido a su rapidez, versatilidad, fácil uso y a que entrega los etiquetados en formato de texto plano tal y como lo requiere el detector de objetos que se decidió usar. En la **Figura 2** se presenta

un ejemplo de etiquetado de imágenes usando la herramienta *DarkLabel*.

## 2.3 Detección de Objetos

Clásicamente, los problemas relacionados con la visión por computador han sido resueltos utilizando técnicas de procesamiento de imágenes para la extracción de descriptores (forma, color, textura) que permitan la identificación y clasificación de objetos usando métodos estadísticos y de aprendizaje automático. Sin embargo, en años recientes, el uso del aprendizaje profundo ha alcanzado una mayor aceptación en problemas de clasificación de imágenes y detección de objetos, debido, principalmente, a que este tipo de sistemas ha logrado superar la capacidad de clasificación humana [18]. En el aprendizaje profundo no se requiere la extracción de descriptores, sino que el sistema automático se entrena para que adquiera la capacidad de extraer por sí mismo las características relevantes de las imágenes. Este enfoque resulta útil cuando el problema a tratar es complejo y se tiene alta variabilidad en las características de las imágenes. Debido a las condiciones no controladas y diferentes variantes que presenta el problema de la identificación de ganado en espacio libre, en este trabajo se optó por utilizar técnicas de aprendizaje profundo.





Figura 2. Etiquetado de imágenes usando *DarkLabel V. 1.3*.

*YOLO (You Only Look Once)* es una red creada para la detección de objetos en imágenes y videos basada en aprendizaje profundo, particularmente el uso de redes neuronales convolucionales. La principal ventaja de *YOLO* es que solo requiere ver la imagen una vez para realizar la predicción utilizando una sola red neuronal [19]. En la actualidad, *YOLO* es la aplicación más rápida para la detección de objetos en imágenes [20], con

capacidad de procesamiento de videos en tiempo real (hasta 171 fps) [21].

Para llevar a cabo la detección, *YOLO* primero divide la imagen en una cuadrícula de  $S \times S$ . En cada una de las celdas generadas predice  $N$  (clases) posibles etiquetas y calcula el nivel de probabilidad de cada una de ellas, es decir, se calculan  $S \times S \times N$  diferentes cajas, la gran mayoría de ellas con un nivel de certidumbre muy bajo. Después de obtener estas predicciones se procede a eliminar las cajas que estén por debajo de un valor umbral. A las cajas restantes se les aplica un algoritmo (*Non-Max Suppression*) para eliminar posibles objetos que fueron detectados por duplicado y así dejar únicamente el más exacto de ellos (ver **Figura 3**) [19].



**Figura 3.** Funcionamiento general de YOLO. La imagen se divide en una cuadrícula de  $S \times S$  (izquierda). Sobre cada celda se calcula el nivel de certidumbre de cada una de las  $N$  clases posibles (centro). Se eliminan las celdas con bajo nivel de certidumbre y se eliminan duplicados (derecha). Disponible en [19].

En este trabajo se ha usado *YOLO V2*, el cual es una versión mejorada de la red original que ofrece un mejor balance entre velocidad y precisión [22]. El entrenamiento se ha realizado sobre en *framework* para redes neuronales basado en lenguaje C y optimizado para CUDA llamado *DarkNet* [23]. El proceso se ha llevado cabo sobre una plataforma en la nube (*Paperspace*) configurado con una GPU NVIDIA Quadro P4000, CUDA 9.0 y cuDNN.

El conjunto de imágenes capturadas y etiquetadas se divide en dos partes: el 70% se utiliza para entrenamiento y el restante 30% para pruebas y validación. La optimización de los hiperparámetros de la red neuronal se realiza sobre un total de 8000 iteraciones (*epochs*).

## 2.4 Transferencia de aprendizaje

El aprendizaje por transferencia (*transfer learning*) es un método de aprendizaje automático en el que un modelo desarrollado para una tarea se reutiliza como punto de partida para un modelo en una segunda tarea. Se

usa debido a los vastos recursos de cómputo y tiempo requeridos para desarrollar modelos de redes neuronales desde cero y los excelentes resultados que proporciona en problemáticas relacionadas [24]. En este caso, se utilizó una red neuronal convolucional con arquitectura *YOLO V2* la cual se modifica para la detección de una sola clase (la clase vaca) a partir de una red neuronal que fue pre-entrenada con una base datos popularmente utilizada en aprendizaje profundo (*ImageNet*) [25]. La red pre-entrenada corresponde al modelo *darknet19\_448* la cual fue descargada directamente del sitio web de los autores de *YOLO*.

## 2.5 Evaluación de desempeño

A continuación, se describen diferentes métricas utilizadas para la evaluar el desempeño de sistemas de detección de objetos en imágenes. Estas métricas son obtenidas a partir de aplicar el modelo entrenado a los datos de prueba.

### 2.5.1 Intersección sobre la unión IoU (*Intersection over Union*)

También es conocido como índice Jaccard. Es una métrica para determinar con qué grado precisión el modelo entrenado puede detectar cierto objeto. Idealmente, este valor debe ser de uno (100%). En la **Figura 4** se presenta gráficamente como se calcula el índice IoU. Los cuadros rojos representan las etiquetas marcadas manualmente sobre el objeto de interés en una imagen, mientras que los cuadros verdes representan la predicción dada por el modelo sobre el mismo objeto en la misma imagen.

$$IoU = \frac{\text{Área sobrepuesta}}{\text{Área total}}$$

**Figura 4.** Explicación gráfica del índice Intersección sobre unión.



### 2.5.2 Precisión (*Precision*)

Mide que porcentaje de predicciones positivas son correctas:

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

Donde  $TP$  (cantidad de objetos de la clase correctamente identificados) son los verdaderos positivos y  $FP$  corresponde a los falsos positivos (cantidad de objetos que no son de la clase detectados como objetos de la clase).

### 2.5.3 Sensibilidad (*Recall*)

Mide qué tan bueno es un sistema para detectar objetos de la clase de interés. Se define como:

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

Donde  $FN$  (cantidad de objetos de la clase detectados que no son pertenecientes a la clase) corresponde a los falsos negativos.

### 2.5.4 Índice F1 (*F1-score*)

También conocido como coeficiente Sørensen-Dice. Representa una medida armónica de balance entre la precisión y la sensibilidad. Idealmente debe tomar el valor de 1. Matemáticamente se define como:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3)$$

### 2.5.5 Media de Precisión mAP (*mean Average Precision*):

Es el promedio de las precisiones máximas a diferentes valores de sensibilidad.

## 3. Resultados y discusión

En la **Figura 5** se presenta algunas imágenes que presentan el funcionamiento del modelo entrenado. Los recuadros cian en las imágenes corresponden a las etiquetas realizadas manualmente, mientras que los recuadros verdes corresponden con las predicciones realizadas con el modelo neuronal entrenado.

El modelo fue probado sobre un total de 4004 fotografías que no fueron incluidas en el entrenamiento (son desconocidas para el sistema), de donde se derivan las diferentes métricas presentadas en la **Tabla 1**.

El valor de certidumbre utilizado para determinar si un objeto detectado corresponde o no a un objeto de la clase, fue del 25%. El sistema fue entrenado con una única clase, lo que hace que la red se especialice y por lo tanto la métrica de Media de Precisión mAP sea mayor que los valores reportados normalmente en la literatura sobre detección de objetos.

El abaratamiento de la tecnología de drones y sistemas de adquisición, así como los avances en el campo de la inteligencia artificial hacen que el uso de este tipo de sistemas para el monitoreo y vigilancia automática de ganado en espacio abierto sea una posibilidad tangible, poco invasiva y económica en un futuro cercano.



**Figura 5.** Resultados de detección de ganado en imágenes de prueba. En la imagen superior izquierda se puede observar la dificultad del modelo para detectar pequeños objetos.

**Tabla 1.** Métricas de desempeño obtenidas en la modelación de un sistema de detección de ganado a partir de fotografías aéreas.

Métrica de Desempeño	Valor obtenido
Precisión	82%
Sensibilidad ( <i>recall</i> )	75%
<i>F1-score</i>	0.78
Verdaderos positivos ( <i>TP</i> )	27183
Falsos positivos ( <i>FP</i> )	5999
Falsos negativos ( <i>FN</i> )	8923
<i>IoU</i> promedio	64.77 %
Media de precisión ( <i>mAP</i> )	71.51%

Respecto a los resultados obtenidos en este trabajo cabe resaltar los siguientes aspectos:

- Este trabajo demuestra que la tarea de identificación de ganado en espacio abierto

puede ser realizada usando técnicas estándar de aprendizaje profundo. Los valores en las diferentes métricas de desempeño son aceptables, pero hay todavía un gran margen de mejora, para que pueda ser implementado en aplicaciones reales.

- El uso de técnicas de procesamiento de imágenes tales como normalización del color, submuestreo y filtrado en una etapa previa al entrenamiento del sistema, puede ayudar a disminuir la carga computacional en el cálculo de los hiperparámetros de la red neuronal y mejorar los resultados obtenidos.
- Puede ser recomendable seguir un protocolo de vuelo durante la etapa adquisición de las imágenes a una altura fija con el fin de lograr uniformidad en los detalles de los animales, de esta manera se puede evitar que algunas de las vacas en las imágenes queden pequeñas y sin detalles, lo que las hace invisibles y difícil de detectar para redes neuronales basadas en *YOLO* [22].

El desarrollo de dispositivos electrónicos de alto desempeño y bajo costo, y nuevas tecnologías de procesamiento (como las GPU) pueden ayudar a que algoritmos y conocimientos matemáticos originados hace algunos años puedan ser implementados hoy en día para aplicaciones en tiempo real, de manera particular, en el campo del procesamiento de imágenes, visión por computador y el aprendizaje automático. Aunque la literatura en el tema de aplicación de técnicas de reconocimiento automático para el monitoreo de ganado en Colombia no es muy amplia, este proyecto puede ser una oportunidad latente para sembrar una semilla de investigación en este campo.

#### 4. Conclusiones

En este trabajo se ha evaluado la posibilidad de utilizar aprendizaje profundo para aplicaciones de detección de ganado en campo abierto a partir de fotografías aéreas adquiridas con drones. Se han utilizado redes neuronales convolucionales a partir de arquitectura desarrollada en C y optimizada para cada CUDA denominada *YOLO*, con la que se ha logrado obtener precisiones de predicción del 82%, con niveles de sensibilidad del 75% y media de precisión mAP del 71.51%, lo que indica que es una herramienta prometedora para este tipo de aplicaciones. Pese a que el

estudio ha sido de tipo exploratorio, se presentan elementos suficientes para que este trabajo pueda ser replicado y realizado a una escala mayor y obtener resultados mejores.

En futuros trabajos se propone aumentar el tamaño de la base de datos, incluyendo nuevas imágenes capturadas en diferentes fincas, con distintas horas del día, con diferentes condiciones climáticas, en escenarios completamente independientes, para evitar que los datos de entrenamiento y prueba puedan estar correlacionados; las imágenes deben capturarse siguiendo protocolos de navegación definidos (altura de vuelo y posicionamiento de la cámara). También se propone la utilización de *YOLO V3*, *Fast R-CNN* y redes *SSD (single shot detection)* para realizar análisis comparativo y mejorar las capacidades de detección, manteniendo los valores de velocidad. Finalmente, se propone desarrollar algoritmos para la detección e identificación de animales en grandes manadas, debido a que, cuando los animales están aglomerados, se hace difícil su individualización para aplicaciones de conteo.

#### 5. Referencias

- [1] W. Vergara, “La ganadería extensiva y el problema agrario. El reto de un modelo de desarrollo rural sustentable para Colombia,” *Rev. Cienc. Anim.*, vol. 3, pp. 45–53, 2010.
- [2] R. Caracol, “Hurtan más de 1.000 cabezas de ganado en Caquetá,” *Caracol Radio*, 2017.
- [3] K. H. Vega, “Abigeato, el otro dolor de cabeza de los ganaderos colombianos,” *Altus en Línea*, 2015.
- [4] La Opinión, “Fedegan preocupada por aumento de cifras de robo de ganado,” *La Opinión*, 2017.
- [5] Portafolio, “Se incrementó el robo de ganado en el país,” *Portafolio*, 2013.
- [6] R. El Mundo, “Unaga denunció hurto de ganado en Colombia,” *El Mundo*, 2017.
- [7] I. A. Puetaman and C. M. Báez, “Prototipo de sistema de vigilancia para fincas ganaderas como prevención al abigeato,” *Rev. UNIMAR*, vol. 32, no. 1, pp. 67–81, 2014.
- [8] Z. Kaixuan and H. Dongjian, “Target detection method for moving cows based on background subtraction,” *Int. J. Agric. Biol. Eng.*, vol. 8, no. 1, pp. 42–49, 2015.
- [9] B. Sirmacek, M. Wegmann, A. D. P. Cross, J. G.

- C. Hopcraft, P. Reinartz, and S. Dech, "Automatic population counts for improved wildlife management using aerial photography," in *International Environmental Modelling and Software Society (iEMSs)*, 2012.
- [10] Y. Xue, T. Wang, and A. K. Skidmore, "Automatic Counting of Large Mammals from Very High Resolution Panchromatic Satellite Imagery," *Remote Sens.*, vol. 9, no. 9, p. 878, 2017.
- [11] J. C. van Gemert, C. R. Verschoor, P. Mettes, K. Epema, L. P. Koh, and S. Wich, "Nature conservation drones for automatic localization and counting of animals," in *Workshop at the European Conference on Computer Vision*, 2014, pp. 255–270.
- [12] S. Lhoest, J. Linchant, S. Quevauvillers, C. Vermeulen, and P. Lejeune, "HOW MANY HIPPOS (HOMHIP): Algorithm for automatic counts of animals with infra-red thermal imagery from UAV," in *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2015, vol. 40, pp. 355–362.
- [13] P. Chamoso, W. Raveane, V. Parra, and A. González, "UAVs applied to the counting and monitoring of animals," in *Ambient Intelligence-Software and Applications*, Springer, 2014, pp. 71–80.
- [14] E. J. Sadgrove, G. Falzon, D. Miron, and D. Lamb, "Fast object detection in pastoral landscapes using a Colour Feature Extreme Learning Machine," *Comput. Electron. Agric.*, vol. 139, pp. 204–212, 2017.
- [15] W. Andrew, C. Greatwood, and T. Burghardt, "Visual localisation and individual identification of Holstein Friesian cattle via deep learning," in *Proc. IEEE International Conference on Computer Vision (ICCV), Venice, Italy*, 2017, pp. 22–29.
- [16] S. U. Sharma and D. J. Shah, "A practical animal detection and collision avoidance system using computer vision technique," *IEEE Access*, vol. 5, pp. 347–358, 2017.
- [17] "DarkLabel1.3 Image Labeling And Annotation Tool," 2017. [Online]. Available: <https://darkpgmr.tistory.com/16>.
- [18] R. Geirhos, D. H. J. Janssen, H. H. Schütt, J. Rauber, M. Bethge, and F. A. Wichmann, "Comparing deep neural networks against humans: object recognition when the signal gets weaker," *arXiv Prepr. arXiv1706.06969*, 2017.
- [19] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You only look once: Unified, real-time object detection," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 779–788.
- [20] A. Sachan, "Zero to Hero: Guide to Object Detection using Deep Learning: Faster R-CNN, YOLO, SSD," *CV-Tricks*, 2018. [Online]. Available: <https://cv-tricks.com/object-detection/faster-r-cnn-yolo-ssd/>. [Accessed: 04-Feb-2019].
- [21] J. Redmon and A. Farhadi, "Yolov3: An incremental improvement," *arXiv Prepr. arXiv1804.02767*, 2018.
- [22] J. Redmon and A. Farhadi, "YOLO9000: better, faster, stronger," in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017, pp. 7263–7271.
- [23] J. Redmon, "Darknet: Open source neural networks in c," *http://pjreddie.com/darknet*, vol. 2016, 2013.
- [24] J. Brownlee, "A Gentle Introduction to Transfer Learning for Deep Learning," *Machine Learning Mastery*, 2017. [Online]. Available: <https://machinelearningmastery.com/transfer-learning-for-deep-learning/>. [Accessed: 04-Feb-2019].
- [25] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei, "Imagenet: A large-scale hierarchical image database," in *Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on*, 2009, pp. 248–255.