

Sistema de Conteo Forestal, Agrícola y Ganadero mediante procesamiento de imágenes

César Martínez¹, Enrique Albornoz¹, Javier Pizarro² y Ricardo Carolo²

¹ Instituto de investigación en señales, sistemas e inteligencia computacional, sinc(i)
UNL-CONICET, Ciudad Universitaria, Ruta Nacional N° 168, km 472.4, (3000) Santa Fe.
{cmartinez, emalbornoz}@sinc.unl.edu.ar - <http://sinc.unl.edu.ar>

² Grupo MOST S.A.
Reconquista 656, 3er. Piso C.P. (CABA)
{javier.pizarro, ricardo.carolo}@grupomost.com - <http://grupomost.com>

Resumen. Los sistemas de conteo actuales en agricultura y ganadería de precisión son manuales, costosos y se realizan con base en muestreos estadísticos. Consecuentemente, una herramienta que permita precisar y optimizar el sistema de conteo a través del procesamiento de imágenes sería fundamental para evaluar la cantidad de plantas en estadios tempranos, la calidad de los cultivos en el tiempo o el conteo exacto de cabezas de ganado. El proyecto plantea el desarrollo de un prototipo de un sistema software para realizar el conteo de poblaciones de plantas y/o ganado mediante técnicas de visión artificial aplicadas sobre videos tomados desde un dron que sobrevuela el campo o desde cámara en tierra. Se generó un corpus de videos propios para cada aplicación cubriendo diversas alturas y perspectiva del dispositivo de captura, diferentes cultivos y variaciones en las condiciones ambientales. Los resultados fueron satisfactorios en todos los escenarios experimentados, haciendo posible validar el prototipo a fin de escalar a una versión comercial que incorpore robustez frente a variaciones en coloración de objetos, tipos de campo, condiciones ambientales, entre otras.

Keywords: visión computacional, agricultura de precisión, ganadería de precisión, conteo automático.

1 Caracterización del Proyecto

Generalidades

Las mediciones y las caracterizaciones de territorios se realizan con base en estudios detallados y análisis de las características del área. Sin embargo, la forma tradicional de observación actual requiere de recursos, esfuerzos y en algunos casos resulta compleja [1]. La alternativa es la inspección de fotografías de las zonas, que inicialmente se realizaba de manera manual sobre imágenes satelitales o capturadas desde aviones y en la última década, con drones comerciales, involucrando métodos de visión computacional para automatizar las tareas [2].

El área de visión computacional ha sido de ayuda en diversas aplicaciones de agricultura y ganadería de precisión, tales como análisis de caña de azúcar [3], conteos de frutas [4,5], identificación de filas de cultivo [6], clasificación de malezas y de ganado Hereford en un campo de pastoreo [7], detección de plantas de citrus en imágenes tomadas con un dron con redes convolucionales [8], entre otras.

Este trabajo fue financiado parcialmente por el programa Financiamiento

2

Fase Cero de la Fundación Sadosky, destinado a promover la realización de proyectos cortos en los que una empresa y un grupo de investigación trabajen por primera vez de manera conjunta para llevar a cabo estudios de factibilidad, pruebas de concepto, prototipos o pilotos en un tema TIC.

Instituciones y Empresas Participantes

- sinc(i): instituto de investigación y desarrollo de nuevos métodos y algoritmos para procesamiento de señales e imágenes, aprendizaje maquina, minería de datos y sistemas complejos. En el campo del procesamiento de imágenes y visión computacional se tiene una experiencia de 15 años.
- GRUPO MOST ARGENTINA S.A.: empresa argentina dedicada desde 1994 a ofrecer soluciones de negocios y servicios informáticos de última generación. Tiene amplia trayectoria en el mercado de servicios de Administración de Infraestructura de TI, Software Factory, Soluciones Mobile, Capacitación, Outsourcing e implementación de productos de e-Government para ciudades inteligentes.

2 Materiales y métodos

Diseño del sistema

Una vez adquirido el video, éste es dividido en frames para su procesamiento. La etapa de preprocesamiento incluye métodos de realce y restauración para lograr imágenes normalizadas y con buenas características. En la etapa siguiente se segmenta por color a los objetos candidatos y luego se aplican algoritmos de seguimiento de objetos sobre todos los frames. Finalmente, es posible obtener el conteo, implementado aquí con una línea inferior que cuenta el cruce de centroides.

Bases de datos

En el marco del proyecto se generaron distintas bases de datos¹, una para cada aplicación, las cuales fueron revisadas manualmente y etiquetadas por expertos en agricultura y ganadería, más una base de datos disponible públicamente:

1. Datos para conteo forestal: 16 videos de aprox. 1 minuto de duración c/u, tamaños variables entre 854x480 px a 1920x1080 px, tasa de frames por segundo experimentada a 25, 30, 48 y 120 FPS, altura variable desde el piso (caminata con celular) hasta drones a 80 m.

¹ Los autores agradecen las bases de datos provistas por Estudio G&D de Ing. Mariano Delbuono.

2. Datos para conteo agrícola: 64 videos a 1920x1080 px, duración media 20 segundos, altura variable entre nivel de piso (caminata) y dron a baja altura.

3. Datos para conteo de ganado: el corpus propio consta de 4 videos a 1920x1080 px y 120 FPS, tiempo promedio 82 segundos. El corpus adicional utilizado fue el “Verschoor Aerial Cow Dataset” con 6 videos de 1920x1080 px a 60 FPS, tiempo promedio 47 segundos.

3 Resultados

Los resultados en el conteo de plantas fueron muy satisfactorios, donde fue posible lograr buenos desempeños para el caso de diversos cultivos. En el caso de conteo forestal se alcanzaron buenos resultados en el caso de baja altura donde los árboles son visibles con color y área adecuadas para no ser confundidos con el resto del suelo. En conteo de ganado, aunque aceptables en general, se obtuvieron resultados que indican dos cuestiones: por un lado, que es factible avanzar con el método de visión computacional planteado como una alternativa de solución. No obstante, los errores surgidos también visualizan que el desempeño basado en visión computacional clásica podría tener un techo debido a que los objetos tienen mucha variabilidad, hay cúmulos de animales que generan objetos de área muy grande, similitud de animales con partes del terreno, etc. Estos problemas podrían ser abordados mediante técnicas de inteligencia artificial basadas en aprendizaje profundo.

La Figura 2 muestra un ejemplo de ventana de análisis de cada aplicación.

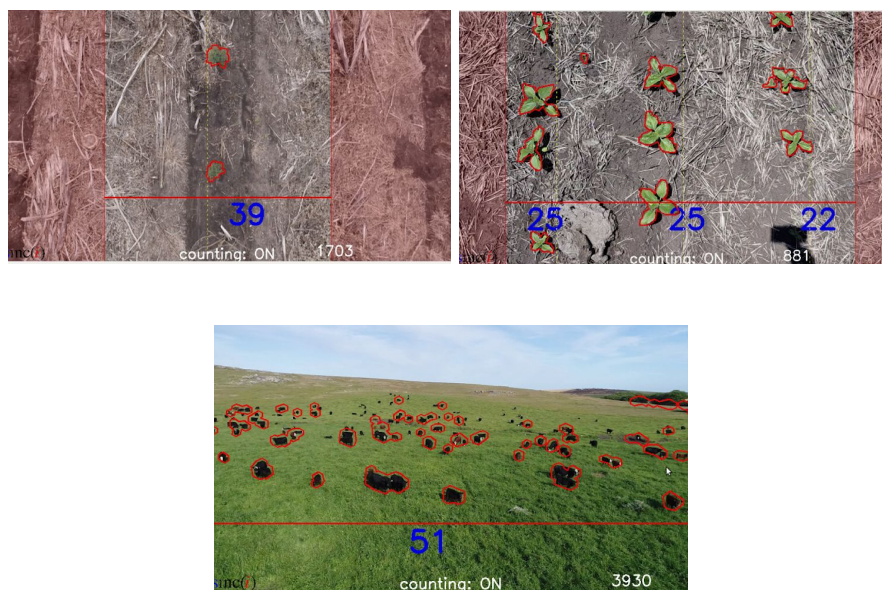


Fig. 2. Ejemplo de análisis forestal y agrícola (arriba) y ganadero (abajo).

4 Conclusiones

Desde un punto de vista técnico, podemos afirmar que el proyecto resultó exitoso ya que se pudo llevar a cabo la definición de 3 tareas de interés en agricultura y ganadería de precisión, el desarrollo y experimentación respectivas, finalizando con prototipos que validan la solución tecnológica propuesta. A fin de escalar estos sistemas iniciales y dar respuesta a productores de manera masiva, se debe avanzar en la mejora y agregado de robustez frente a variabilidad relevada y discutida previamente, lo cual puede también abordarse en un futuro a medida que se vayan registrando más videos.

Desde el punto de vista de la colaboración universidad-empresa, consideramos de manera conjunta que el proyecto mejoró las capacidades de uno y otro lado, con aprendizajes mutuos de lenguaje específico del dominio de aplicación, posibilidades y limitaciones de la visión computacional, necesidades del medio productivo y cómo dar respuesta desde la academia, entre otros aspectos surgidos de la interacción.

Finalmente, como próximos pasos podemos mencionar la realización de pruebas de concepto con productores que se quieran sumar en esta etapa, permitiendo el relevamiento de opiniones y evaluaciones sobre esta tecnología por parte de diversos expertos usuarios.

Referencias

1. Montanari, A., et al. Surveying areas in developing regions through context aware drone mobility. En Proceedings of the 4th ACM Workshop on Micro Aerial Vehicle Networks, Systems, and Applications. ACM, p. 27-32 (2018).
2. America, N. Drones and aerial observation: New technologies for property rights, human rights, and global development—A primer. Retrieved June, vol. 7, p. (2016).
3. Kamilaris, A.; Prenafeta-Boldu, F. Deep learning in agriculture: A survey. Computers and Electronics in Agriculture, vol. 147, p. 70-90 (2018).
4. Rahnemoonfar, M.; Sheppard, C. Deep count: fruit counting based on deep simulated learning. Sensors, vol. 17, no 4, p. 905 (2017).
5. Chen, S., et al. Counting apples and oranges with deep learning: A data-driven approach. IEEE Robotics and Automation Letters, vol. 2, no 2, p. 781-788 (2017).
6. Zhao, S.; Zhang, Z. A new recognition of crop row based on its structural parameter model. IFAC-PapersOnLine, vol. 49, no 16, p. 431-438 (2016).
7. Sadgrove, E., et al. Fast object detection in pastoral landscapes using a Colour Feature Extreme Learning Machine. Computers and electronics in agriculture, vol. 139, p. 204-212 (2017).
8. CSILLIK, Ovidiu, et al. Identification of citrus trees from unmanned aerial vehicle imagery using convolutional neural networks. Drones, 2018, vol. 2, no 4, p. 39.