



Aplicación de la red convolucional Mask R-CNN para la estimación del peso corporal del cuy

Application of the convolutional network Mask R-CNN for the estimation of the body weight of the guinea pig

Ormeño-Ayala, Yeshica Isela^{1*}

Zapata-Ttito, Abel Gabriel¹

¹Universidad Nacional de San Antonio Abad del Cusco, Cusco, Perú

Recibido: 13 Sep. 2023 | **Aceptado:** 9 Oct. 2023 | **Publicado:** 10 Ene. 2024

Autor de correspondencia*: iselayes@gmail.com

Como citar este artículo: Ormeño-Ayala, Y. I. & Zapata-Ttito, A. G. (2024). Aplicación de la red convolucional Mask R-CNN para la estimación del peso corporal del cuy. *Revista Científica de Sistemas e Informática*, 4(1), e614. <https://doi.org/10.51252/rcsi.v4i1.614>

RESUMEN

La inteligencia artificial puede contribuir en el seguimiento del ciclo productivo del cuy mediante la aplicación de redes convolucionales, siendo una necesidad la estimación de su peso. Este estudio se enfocó en la aplicación de la red convolucional Mask R-CNN, utilizando una aplicación móvil como herramienta para la captura de imágenes. La metodología abarcó las siguientes etapas: i) revisión bibliográfica, ii) recolección de datos (imágenes y pesos de cuyes), iii) procesamiento de imágenes mediante aumento de datos, iv) construcción de un dataset (selección de imágenes y transformación de datos), v) adaptación y entrenamiento de la red convolucional, vi) análisis de los resultados para validar su desempeño, y finalmente, vii) implementación de una aplicación móvil como herramienta de estimación de peso. Se logró recopilar un conjunto de 6244 imágenes de cuyes con sus respectivos pesos y máscaras, junto con la adaptación de la red Mask R-CNN. Estas tareas condujeron a una correlación de $R^2 = 80,2\%$ con el conjunto de validación, así como al desarrollo de un prototipo funcional capaz de estimar el peso de los cuyes utilizando la cámara de un teléfono celular.

Palabras clave: aplicación móvil; dataset de imágenes; inteligencia artificial; redes convolucionales

ABSTRACT

Artificial intelligence can contribute in tracking the productive cycle of the cuy through the application of convolutional networks, being a necessity the estimation of its weight. This study focused on the application of the Mask R-CNN convolutional network, using a mobile application as a tool for image capture. The methodology covered the following stages: i) bibliographic review, ii) data collection (images and pig weights), iii) image processing through data augmentation, iv) construction of a dataset (image selection and data transformation); , v) adaptation and training of the convolutional network, vi) analysis of the results to validate its performance, and finally, vii) implementation of a mobile application as a weight estimation tool. A set of 6244 pig images with their respective weights and masks was managed to be collected, together with the Mask R-CNN network adaptation. These tasks led to a correlation of $R^2 = 80.2\%$ with the validation set, as well as to the development of a functional prototype capable of estimating the weight of pigs using the camera of a cell phone.

Keywords: mobile application; image dataset; artificial intelligence; convolutional networks



1. INTRODUCCIÓN

El cuy o cobaya es un animal de origen andino que tiene una carne con un alto valor nutricional, debido a que posee un porcentaje de 20,3% en proteína y menos del 10% en grasa (Gil Santos, 2007). Siendo su carne apta para todos los grupos poblacionales y en diversas situaciones fisiológicas, su consumo demanda un incremento en la producción de cuyes. Por lo que un seguimiento continuo optimizaría la producción cárnica. Por estas razones, la estimación del peso del cuy es necesaria para agilizar el proceso de pesaje en la crianza masiva de cuyes.

La estimación del peso del animal consiste en la obtención de un valor aproximado de su peso corporal, que puede ser realizado por observación usando instrumentos de medición o implementando técnicas de inteligencia artificial. A pesar de que existen instrumentos de medición exactos, la tarea de pesaje se vuelve exhaustiva, causándoles estrés, e incluso generar accidentes durante esta tarea. Por estas razones, existen investigaciones que usan técnicas de inteligencia artificial para desarrollar esta labor de medición del peso de animales, que toman en consideración: reducción del tiempo, no invasión del espacio de crianza, aplicación en grandes cantidades de animales y con un margen de error aceptable.

Actualmente, existen investigaciones desarrolladas en el cerdo (Wang et al., 2008; Kashiha et al., 2014; Wongsriworaphon et al., 2015; Jensen & Dominiak, 2018; Jun et al., 2018; Pezzuolo et al., 2018; Buayai et al., 2019; Cang et al., 2019; Fernandes et al., 2019), el ganado vacuno (Miller et al., 2019; Cominotte et al., 2020), el pollo (Mortensen et al., 2016; Ma et al., 2021) y el pescado (Konovalov et al., 2019). Dichas investigaciones fueron revisadas durante la exploración de la bibliografía, sin encontrarse alguna respecto a la estimación del peso en los cuyes, lo que motivó aún más el desarrollo de esta investigación.

En los trabajos revisados, las técnicas utilizadas realizan el proceso de segmentación de imagen y estimación del peso como procesos secuenciales que conducen a requerir mayor tiempo y esfuerzo. En algunos casos se emplean cámaras estáticas ubicadas en la parte posterior del corral o cámaras LiDAR, implicando un mayor coste para la captura de imágenes. La finalidad de esta propuesta es mejorar la eficiencia temporal al fusionar la captura de imágenes y el procesamiento de datos en un único proceso, mediante el uso de la cámara del teléfono móvil. Se pretende lograr una automatización completa de los sistemas, siguiendo la característica destacada en los modelos de predicción, según señalan Dohmen et al. (2022).

Los avances desarrollados en el campo de la inteligencia artificial como el deep learning o técnicas de machine learning, poseen varios modelos o arquitecturas para la clasificación de imágenes, detección de objetos y otras diversas tareas. Según He et al. (2017), el Mask RCNN es un modelo de detección de objetos y segmentación de instancias que clasifica, detecta y genera una máscara a un determinado objeto que ya ha aprendido, utilizando el dataset COCO (Common Objects in Context) (Lin et al., 2014). Por su arquitectura, el modelo Mask R-CNN, además de obtener la detección y generación de una máscara puede permitirnos crear una rama para la estimación del peso. Qiao et al. (2019) indican que, se puede emplear el modelo Mask R-CNN para la extracción de contorno en ganado vacuno mostrando un resultado de MPA (*Mean Pixel Accuracy*) igual a 0.92, además de extraer contornos de más de 1 vacuno en una imagen.

Por tanto, la propuesta consistió en modificar Mask R-CNN para que genere una estimación del peso del cuy, además de detectar su ubicación en la imagen capturada. Para este desarrollo, fue esencial la construcción de un dataset de imágenes con sus respectivos pesos, que sirvió para un desarrollo de predicción del peso del cuy. También, se obtuvo un prototipo de aplicación móvil para la labor del pesaje en un ambiente de crianza del cuy.

El propósito principal de este estudio fue llevar a cabo la adaptación de la red convolucional Mask R-CNN para la estimación del peso del cuy basado en imagen, que consistió en desarrollar un dataset de imágenes de cuyes con sus respectivos pesos, adaptar la red Mask R-CNN, entrenar y evaluar la red adaptada, e implementar un prototipo de aplicación móvil que permita la estimación del peso del cuy mediante imagen.

2. MATERIALES Y MÉTODOS

Los materiales utilizados para la realización de esta investigación se dividieron en software y hardware, que se detallan en la Tabla 1:

Tabla 1.
Software y Hardware empleados

| Software | |
|--|--|
| Sistema operativo | Windows 10 x64 |
| Lenguaje de programación | python 3.7 |
| Sistema de gestión de paquetes | Anaconda 2.0.4 |
| Librerías | numpy (1.16.4), scipy (1.2.2), Pillow, cython, matplotlib, scikit-image, tensorflow (1.14.0), tensorflowgpu (1.14.0), keras (2.1.5), h5py (2.10.0), imgaug, pycocotools, cuda (7.0), cudann (7.0). |
| Sistema de control de versiones | GitHub |
| Software de etiquetado | Labelbox |
| Hardware | |
| Teléfono celular | Xiaomi Redmi Note 7. Cámara principal de 48 megapíxeles y 5 megapíxeles, f/1.8. |
| Balanza | JBC Modelo DY130, capacidad 40 kg, precisión 1-5 gramos. |
| Ordenador portátil | Asus ROG Zephyrus S GX531GS. Procesador Intel Core i7-8750H, 16GB RAM DDR4, 512GB SSD, Tarjeta de vídeo NVIDIA GeForce GTX 1070 Max-Q (6GB de memoria, 1280 núcleos) |

En la Figura 1 se muestra la metodología que se basó en el desarrollo de un sistema de visión artificial (González Marcos et al., 2006), que sigue las siguientes etapas: 1) la revisión bibliográfica de modelos, arquitecturas, técnicas y modelos, 2) la recolección de datos donde se captura imágenes de cuyes con sus respectivos pesos, 3) procesamiento de imágenes, donde se selecciona, segmenta y aumenta los datos recolectados, 4) la construcción del dataset que es la agrupación de los datos ya procesados, 5) la adaptación y entrenamiento de la red convolucional Mask R-CNN, 6) el análisis de los resultados obtenidos y 7) el desarrollo de una aplicación móvil del modelo entrenado.

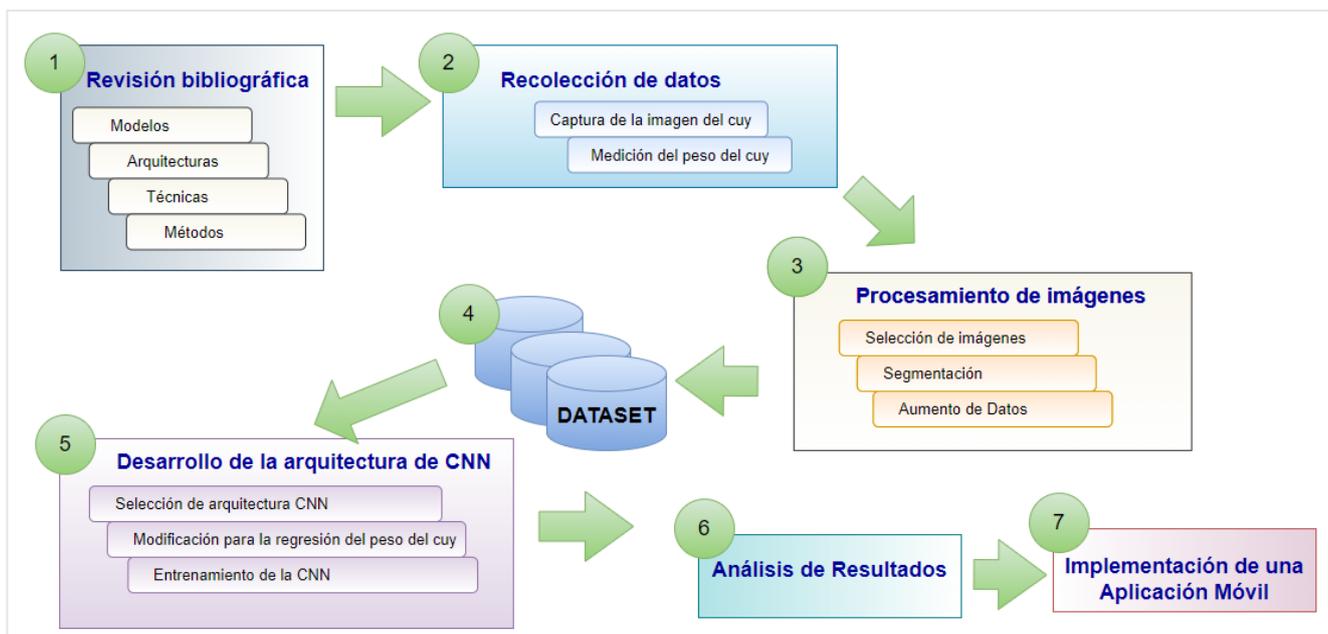


Figura 1. Metodología propuesta

1ra etapa: revisión bibliográfica

La revisión bibliográfica se realizó en base al análisis de artículos científicos que tuvieron como objetivo la estimación del peso animal usando técnicas de inteligencia artificial. Su recopilación se realizó mediante búsquedas en bibliotecas digitales con la cadena: estimación de peso. De los artículos revisados, se seleccionó aquellos relacionados al uso de imágenes bidimensionales como imagen de entrada. Además del uso de métodos de inteligencia artificial para la estimación del peso animal; en la Tabla 2, se observan las investigaciones más relevantes, el animal de estudio y el porcentaje de exactitud que se obtuvo.

Tabla 2.

Artículos importantes de la revisión bibliográfica

| Autor | Animal de estudio | Técnicas empleadas | MAPE | R² |
|--------------------------|--------------------------|-----------------------------------|-------------|----------------------|
| Mortensen et al. (2016) | Pollo | Red neuronal artificial bayesiana | 7,80% | - |
| Jensen & Dominiak (2018) | Cerdo | Red neuronal convolucional | - | 96% |
| Jun et al. (2018) | Cerdo | Red neuronal totalmente conectada | - | 79% |
| Buayai et al. (2019) | Cerdo | Perceptrón multicapa | 2,84% | 87% |
| Cang et al. (2019) | Cerdo | Faster R-CNN | 0,50% | - |
| Fernandes et al. (2019) | Cerdo | Análisis Estadístico | 3,00% | 92% |
| Konovalov et al. (2019) | Pescado | Red neuronal convolucional | 4,28% | - |
| Miller et al. (2019) | Vacuno | Red neuronal artificial | - | 88% |
| Cominotte et al. (2020) | Vacuno | Red neuronal artificial | - | 92% |
| Ma et al. (2021) | Pollo | Red neuronal artificial bayesiana | 3,00% | - |

2da etapa: recolección de datos

La recolección de datos comprendió la captura de imágenes de cuyes usando la cámara de un teléfono celular y la obtención del peso del cuy usando una balanza digital. Para este proceso de recolección de datos se contó con la coordinación y participación de algunos criadores de la región del Cusco, labor realizada en sus respectivas granjas. La recolección se realizó en 6 granjas de cuyes bajo la supervisión del dueño o encargado de la granja entre los meses de febrero y agosto del año 2021, siendo un total de 225 cuyes, la población de cuyes de los que se recolectaron los datos.

Este proceso se realizó de la siguiente forma: primero, se seleccionó un cuy y se transportó a una poza vacía que estuvo situada en el piso; segundo, se procedió a capturar la imagen del cuy dentro de la poza, con una distancia aproximada de 1 metro desde el piso hasta la cámara, para cada cuy se capturó entre 3 a 5 imágenes en diferentes posiciones dentro de la poza; tercero, se procedió a registrar el peso del cuy usando una balanza digital, para finalmente devolver al cuy a su respectiva poza o jaula.

3ra etapa: procesamiento de imágenes

El procesamiento de imágenes comprendió la selección, segmentación y aumento de imágenes.

1. La selección de imágenes consistió en determinar qué imágenes recolectadas cumplieran con los requisitos para formar parte del dataset, los requerimientos fueron: la imagen debió ser cuadrada (1x1), solo un cuy dentro de la imagen y visualizar el cuerpo completo del cuy. Además, después de la selección se procedió a redimensionar la imagen a un tamaño de 640x640 píxeles, para reducir el peso del archivo de la imagen. En esta parte, la información recolectada de los pesos fue almacenada en un documento de texto (.txt), donde se referencia el nombre de archivo de la imagen con el peso del cuy. En la Figura 2 se muestra la redimensión de una imagen que cumplió los requerimientos para formar parte del dataset de un tamaño de 3000x3000 píxeles a 640x640 píxeles.

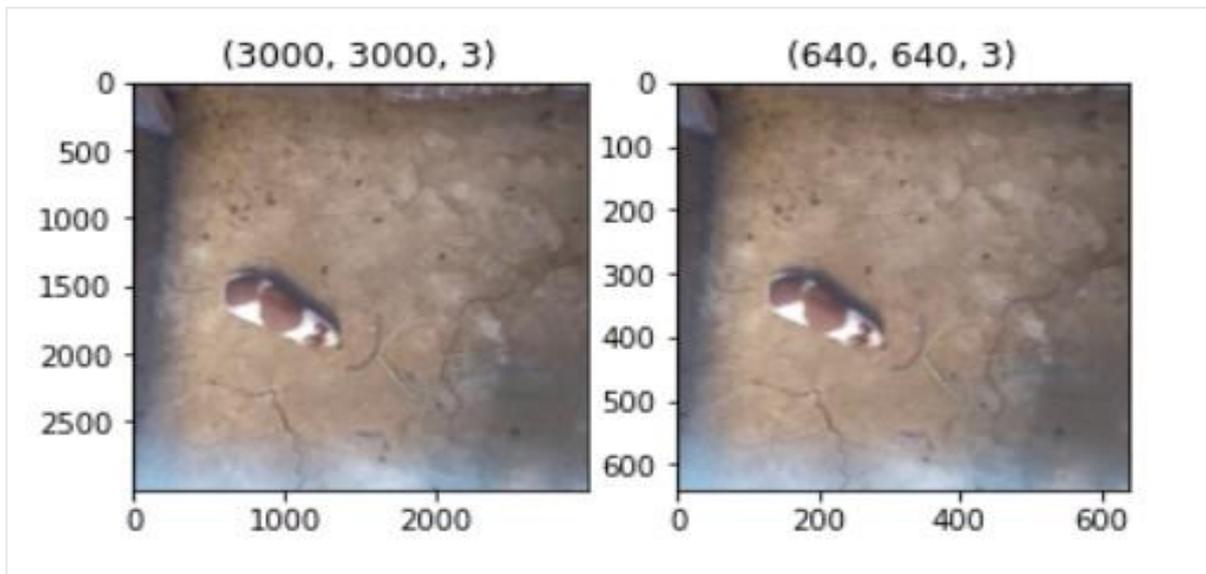


Figura 2. Selección de imágenes

- La segmentación de imágenes se realizó usando la plataforma de etiquetado Labelbox. Esta herramienta permitió dibujar una máscara sobre el área que ocupa el cuy dentro de la imagen. En la Figura 3 se muestra la segmentación de un cuy usando la plataforma Labelbox, con la máscara en un color azul claro que delimitó el área que ocupa el cuy dentro de la imagen. Luego de segmentar todas las imágenes se procedió a descargarlas usando una librería de utilidades desarrollado en el lenguaje de programación Python (Wilding-McBride & Pun, 2018); las máscaras se descargaron en formato PNG y se referenció con el mismo nombre de archivo que la imagen original.



Figura 3. Segmentación de imagen usando Labelbox

- El aumento de datos se realizó para incrementar la cantidad de imágenes del dataset, esta etapa consistió en generar imágenes similares a las seleccionadas, girándolas y modificando levemente los píxeles de la imagen. En la Figura 4 se muestra como a partir de la imagen original se procedió a obtener 3 imágenes más.

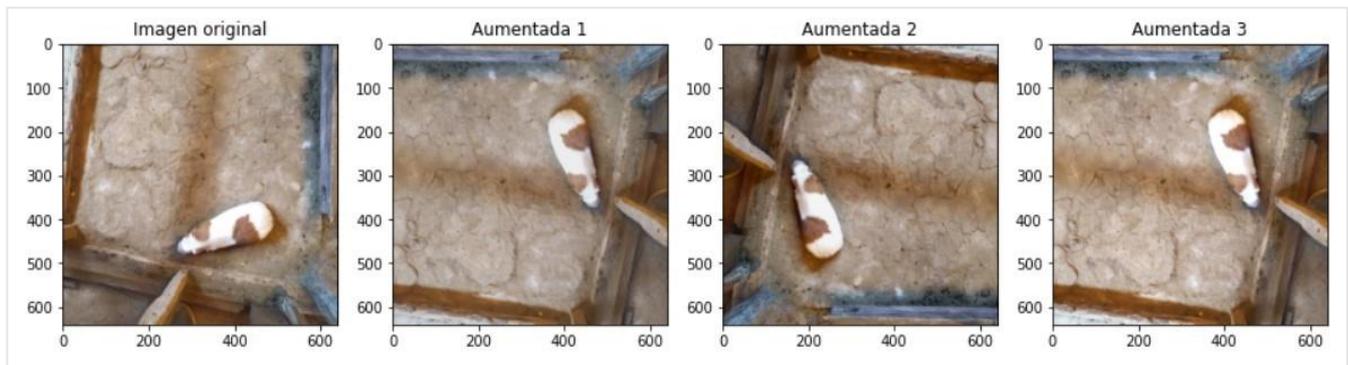


Figura 4. Aumento de datos

4ta etapa: construcción del Dataset

La construcción del dataset fue el proceso de la agrupación de las imágenes etiquetadas con el peso medido del cuy. Después del procesamiento de imágenes se obtuvo un total de 6 244 imágenes, que fueron separadas en 4 992 para el entrenamiento (80%) y 1 252 para la validación (20%), además de obtener un documento de texto con los nombres de archivo de las imágenes y los respectivos pesos del cuy.

5ta etapa: desarrollo de la arquitectura

El desarrollo de la arquitectura se realizó en base al modelo Mask R-CNN (He et al., 2017), que es una arquitectura de segmentación de instancias que permite detectar máscaras de los objetos con los que fue entrenado.

Para el desarrollo del modelo se utilizó la implementación de Abdulla (2017), quien empleó la librería Keras y Python. Este modelo se ilustra en la Figura 5 que se inicia con i) el preprocesamiento de la imagen de entrada, ii) empleo de la red troncal (ResNet50 o ResNet101) para obtener mapas de características, luego iii) se incluye la red RPN (Regional Proposal Network) que propone regiones de interés del objeto a identificar, después iv) pasa a una capa de mapa de características, en donde se seleccionan las regiones de interés que más influyen para encontrar el objeto a buscar, para luego dividirse en dos ramas: a) una obtiene la clasificación de la categoría del objeto y el cuadro delimitador y la otra b) genera la máscara y estima el peso del cuy.

Para el entrenamiento del modelo, se usó los pesos pre-entrenados del dataset COCO, además de configurar el entrenamiento usando la red troncal ResNet50. El entrenamiento se realizó en tres partes, la primera fue un entrenamiento de 50 épocas de 500 pasos para el entrenamiento y 50 pasos para la validación, en cambio el segundo y tercer entrenamiento fue de 50 épocas de 1 000 pasos para el entrenamiento y 100 pasos para la validación.

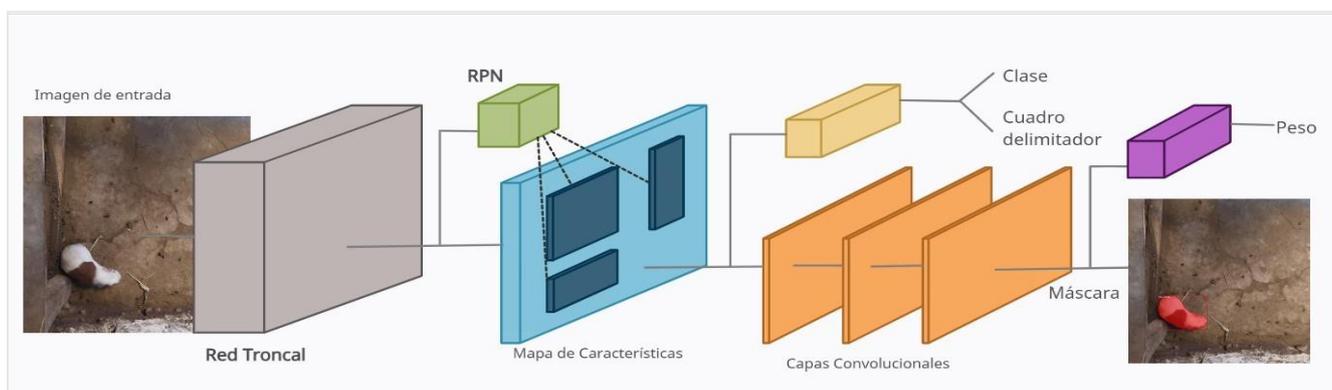


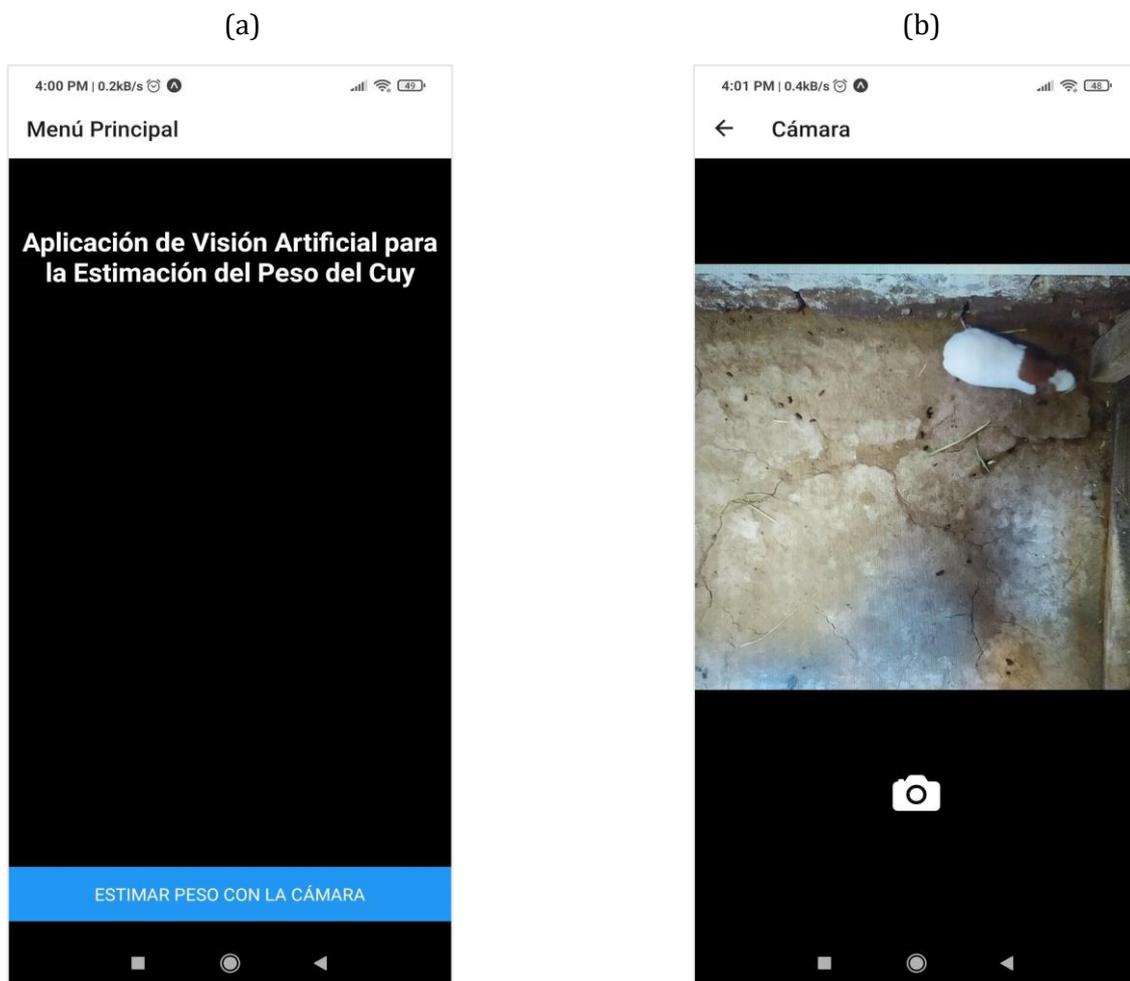
Figura 5. Modelo Mask R-CNN modificado

6ta etapa: análisis de resultados

El análisis de resultados comprendió el uso de métricas para evaluar la precisión de la red entrenada, en este caso se usó métricas de regresión como: MAPE (Error Perceptual Absoluto Medio) y el coeficiente de correlación R^2 , dichas métricas comparan la distancia entre el valor estimado y el valor medido. En este caso, después del entrenamiento de la red se obtuvieron los siguientes valores: MAPE= 12,60% y $R^2 = 80,21\%$. Estos datos muestran que la estimación del peso del cuy puede ser realizada aplicando una red convolucional como Mask R-CNN para la estimación del peso del cuy, donde la correlación al conjunto de validación es de 80,21%.

7ma etapa: prototipo de Aplicación Móvil

Como parte de la aplicación de la red convolucional para la estimación del peso del cuy, se procedió a desarrollar un prototipo que permitió realizar la tarea de estimar el cuy usando un equipo móvil como el teléfono celular. En la implementación se utilizó el framework React Native para el desarrollo de la aplicación móvil en dispositivos con sistema operativo Android, implementando un API con el framework Flask, que al recibir una imagen del dispositivo móvil se procesa para obtener la estimación del peso del cuy. En la Figura 6 se puede observar las interfaces del prototipo desarrollado, en la imagen 6a se muestra la interfaz de bienvenida e inicio de la aplicación, en la imagen 6b se muestra el uso de la cámara del dispositivo móvil para la captura de la imagen del cuy, la imagen 6c se muestra una interfaz de espera mientras la imagen es enviada al API para ser procesada y la parte 6d muestra el resultado del API donde muestra la localización del cuy con una máscara en color rojo, además del peso estimado.



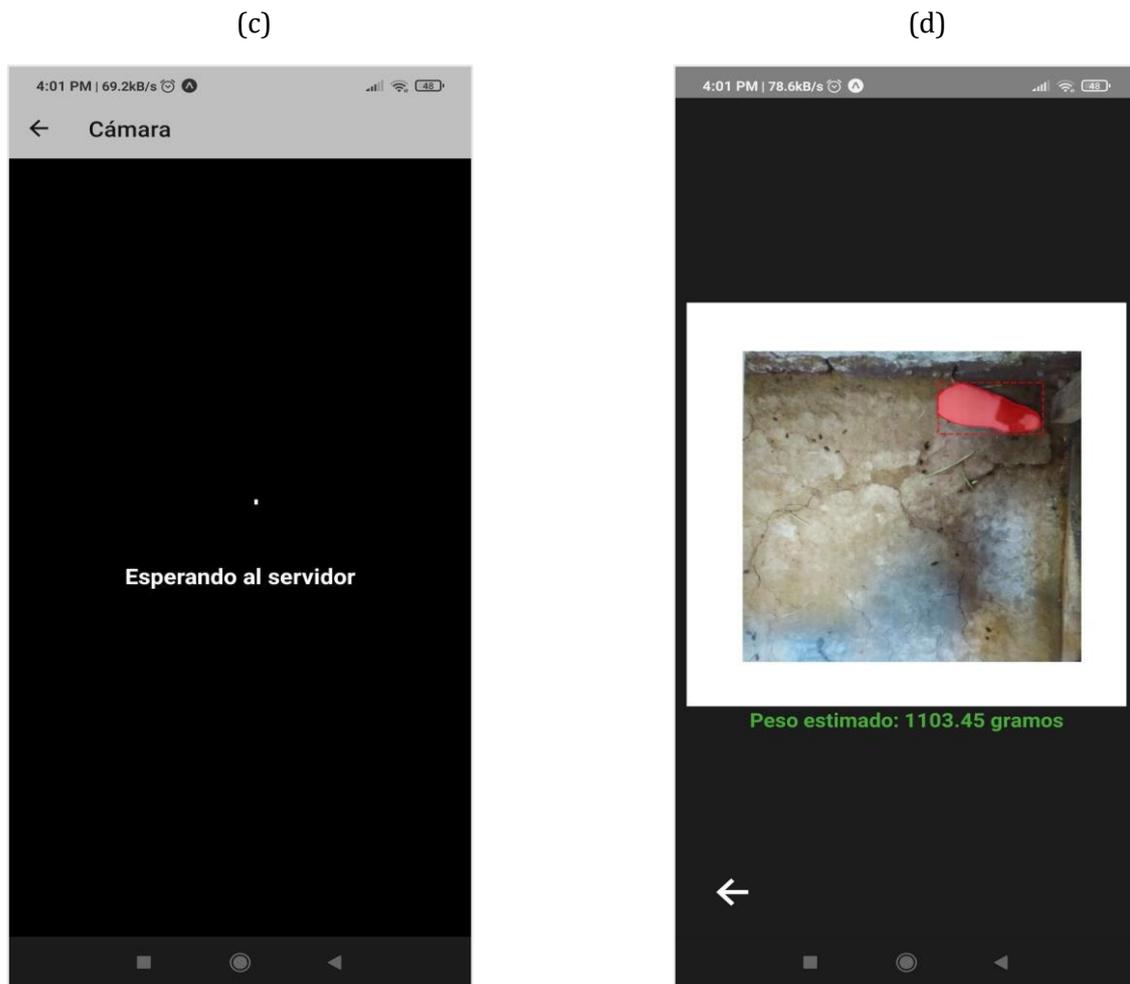


Figura 6. Interfaz de la Aplicación para la estimación del peso del cuy

3. RESULTADOS Y DISCUSIÓN

La presente investigación mostró la aplicación de una red convolucional adaptada para la estimación del peso del cuy, donde se obtuvo un dataset de imágenes de cuyes, máscaras y sus respectivos pesos, el cual puede ser extendido o utilizado en alguna investigación similar. Además, se mostró la adaptación de la red convolucional Mask R-CNN para la estimación del peso del cuy con una correlación del 80,21%. Sin embargo, como se muestra en la Tabla 3, también se obtuvieron resultados de otras métricas aplicadas en el conjunto de entrenamiento y el conjunto de evaluación del dataset desarrollado, donde los mejores resultados se obtienen en el conjunto de entrenamiento, obtenidos en el tiempo en que la red convolucional aprendió de las imágenes de entrada.

Tabla 3.

Resultados de las métricas de evaluación al modelo

| Métrica | Resultado (conjunto de entrenamiento) | Resultado (conjunto de evaluación) |
|---------------------------------------|--|---------------------------------------|
| Error Absoluto Medio | 59,50 | 106,76 |
| Raíz del Error Cuadrático Medio | 76,25 | 139,17 |
| Error Porcentual Absoluto Medio | 6,55% | 12,60% |
| Coefficiente de correlación (R^2) | 93,31% | 80,21% |

Mask R-CNN adaptado

El aspecto más importante fue la incorporación de una red convolucional como Mask R-CNN en la estimación del peso del cuy, soportado en una herramienta no invasiva para la estimación del peso del cuy.

Además de servir como base para investigaciones donde se busque obtener características de animales de granja como el cuy a partir de la captura de una imagen.

A diferencia de los trabajos realizados por Jensen & Dominiak (2018), Buayai et al. (2019) y Jun et al. (2018) donde se obtuvieron $R^2 = 96\%$, $R^2 = 87\%$ y $R^2 = 79\%$ respectivamente; esta investigación en base al modelo Mask R-CNN realiza en un solo proceso la segmentación de imagen y la estimación del peso, obteniendo un $R^2 = 80\%$, considerándose un porcentaje aceptable en las mediciones de pesos, además de optimizar el tiempo y reducir el esfuerzo en la labor de estimar el peso del cuy a comparación de un pesaje tradicional que implica la movilización del animal de su jaula o poza a una balanza.

CONCLUSIONES

La adaptación de la red convolucional Mask R-CNN para la estimación del peso del cuy muestra que se pueden adaptar otros modelos de inteligencia artificial para tareas relacionadas con animales de granja como el cuy, como en este caso el pesaje. Los resultados revelan una correlación de 80,21% con el conjunto de validación. Además, un dataset de 6 244 imágenes de cuyes con sus respectivas máscaras y pesos que sirve de base para futuras investigaciones en este ámbito, no sólo en la estimación del peso sino también describiendo características de salud del cuy o estimación de producción cárnica.

La aplicación móvil desarrollada es una herramienta accesible y útil para diferentes usuarios como investigadores, empresarios y especialmente para los productores de cuyes, ya que permitió realizar el seguimiento continuo del peso del cuy, facilitando sus labores de una forma más eficiente y reduciendo el esfuerzo.

Se puede recomendar ampliar el estudio de cómo adaptar otros modelos de inteligencia artificial para el campo del seguimiento en la crianza de animales de granja, además de incrementar los conjuntos de datos, que permitiría mejorar la precisión de las adaptaciones.

FINANCIAMIENTO

Por el Programa Yachaininchis Wiñariñampac Fondecyt UNSAAC, mediante el Proyecto de Investigación con fondos Canon "Aplicación de la Ingeniería de Requisitos a los proyectos de Investigación de la UNSAAC en desarrollo de Software y uso de TIC's", Contrato N°. 021-2018-UNSAAC.

CONFLICTO DE INTERESES

No existe ningún tipo de conflicto de interés relacionado con la materia del trabajo.

CONTRIBUCIÓN DE LOS AUTORES

Conceptualización, curación de datos, análisis formal, adquisición de fondos, investigación, administración del proyecto, software, supervisión, validación, visualización, redacción -borrador original, redacción -revisión y edición: Ormeño-Ayala, Y. I. & Zapata-Ttito, A. G.

REFERENCIAS BIBLIOGRÁFICAS

- Abdulla, W. (2017). *Mask R-CNN for object detection and instance segmentation on Keras and TensorFlow*. GitHub. https://github.com/matterport/Mask_RCNN
- Buayai, P., Piewthongngam, K., Leung, C. K., & Saikaew, K. R. (2019). Semi-Automatic Pig Weight Estimation Using Digital Image Analysis. *Applied Engineering in Agriculture*, 35(4), 521–534. <https://doi.org/10.13031/aea.13084>
- Cang, Y., He, H., & Qiao, Y. (2019). An Intelligent Pig Weights Estimate Method Based on Deep Learning in

- Sow Stall Environments. *IEEE Access*, 7, 164867–164875.
<https://doi.org/10.1109/ACCESS.2019.2953099>
- Cominotte, A., Fernandes, A. F. A., Dorea, J. R. R., Rosa, G. J. M., Ladeira, M. M., van Cleef, E. H. C. B., Pereira, G. L., Baldassini, W. A., & Machado Neto, O. R. (2020). Automated computer vision system to predict body weight and average daily gain in beef cattle during growing and finishing phases. *Livestock Science*, 232, 103904. <https://doi.org/10.1016/j.livsci.2019.103904>
- Dohmen, R., Catal, C., & Liu, Q. (2022). Computer vision-based weight estimation of livestock: a systematic literature review. *New Zealand Journal of Agricultural Research*, 65(2–3), 227–247.
<https://doi.org/10.1080/00288233.2021.1876107>
- Fernandes, A. F. A., Dórea, J. R. R., Fitzgerald, R., Herring, W., & Rosa, G. J. M. (2019). A novel automated system to acquire biometric and morphological measurements and predict body weight of pigs via 3D computer vision. *Journal of Animal Science*, 97(1), 496–508.
<https://doi.org/10.1093/jas/sky418>
- Gil Santos, V. (2007). Importancia del Cuy y su Competitividad en el Mercado. *Archivos Latinoamericanos De Producción Animal*, 15(5). https://ojs.alpa.uy/index.php/ojs_files/article/view/2741
- González Marcos, A., Martínez de Pisón Ascacíbar, F., Pernía Espinoza, A., Alba Elías, F., Castejón Limas, M., Ordieres Meré, J., & Vergara González, E. (2006). *Técnicas y Algoritmos Básicos de Visión Artificial* (1st ed.). Universidad de La Rioja.
- He, K., Gkioxari, G., Dollar, P., & Girshick, R. (2017). Mask R-CNN. *2017 IEEE International Conference on Computer Vision (ICCV)*, 2980–2988. <https://doi.org/10.1109/ICCV.2017.322>
- Jensen, D., & Dominiak, K. (2018). Automatic estimation of slaughter pig live weight using convolutional neural networks. *II International Conference on Agro BigData and Decision Support Systems in Agriculture*.
- Jun, K., Kim, S. J., & Ji, H. W. (2018). Estimating pig weights from images without constraint on posture and illumination. *Computers and Electronics in Agriculture*, 153, 169–176.
<https://doi.org/10.1016/j.compag.2018.08.006>
- Kashiha, M., Bahr, C., Ott, S., Moons, C. P. H., Niewold, T. A., Ödberg, F. O., & Berckmans, D. (2014). Automatic weight estimation of individual pigs using image analysis. *Computers and Electronics in Agriculture*, 107, 38–44. <https://doi.org/10.1016/j.compag.2014.06.003>
- Konovalov, D. A., Saleh, A., Efremova, D. B., Domingos, J. A., & Jerry, D. R. (2019). Automatic Weight Estimation of Harvested Fish from Images. *2019 Digital Image Computing: Techniques and Applications (DICTA)*, 1–7. <https://doi.org/10.1109/DICTA47822.2019.8945971>
- Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., & Zitnick, C. L. (2014). *Microsoft COCO: Common Objects in Context* (pp. 740–755). https://doi.org/10.1007/978-3-319-10602-1_48
- Ma, W., Li, Q., Li, J., Ding, L., & Yu, Q. (2021). A method for weighing broiler chickens using improved amplitude-limiting filtering algorithm and BP neural networks. *Information Processing in Agriculture*, 8(2), 299–309. <https://doi.org/10.1016/j.inpa.2020.07.001>
- Miller, G. A., Hyslop, J. J., Barclay, D., Edwards, A., Thomson, W., & Duthie, C.-A. (2019). Using 3D Imaging and Machine Learning to Predict Liveweight and Carcass Characteristics of Live Finishing Beef Cattle. *Frontiers in Sustainable Food Systems*, 3. <https://doi.org/10.3389/fsufs.2019.00030>
- Mortensen, A. K., Lisouski, P., & Ahrendt, P. (2016). Weight prediction of broiler chickens using 3D computer vision. *Computers and Electronics in Agriculture*, 123, 319–326.

<https://doi.org/10.1016/j.compag.2016.03.011>

- Pezzuolo, A., Guarino, M., Sartori, L., González, L. A., & Marinello, F. (2018). On-barn pig weight estimation based on body measurements by a Kinect v1 depth camera. *Computers and Electronics in Agriculture*, *148*, 29–36. <https://doi.org/10.1016/j.compag.2018.03.003>
- Qiao, Y., Truman, M., & Sukkarieh, S. (2019). Cattle segmentation and contour extraction based on Mask R-CNN for precision livestock farming. *Computers and Electronics in Agriculture*, *165*, 104958. <https://doi.org/10.1016/j.compag.2019.104958>
- Wang, Y., Yang, W., Winter, P., & Walker, L. (2008). Walk-through weighing of pigs using machine vision and an artificial neural network. *Biosystems Engineering*, *100*(1), 117–125. <https://doi.org/10.1016/j.biosystemseng.2007.08.008>
- Wilding-McBride, D., & Pun, D. (2018). *Mask R-CNN utils*. GitHub. <https://github.com/DiUS/MaskRCNN-utils>
- Wongsriworaphon, A., Arnonkijpanich, B., & Pathumnakul, S. (2015). An approach based on digital image analysis to estimate the live weights of pigs in farm environments. *Computers and Electronics in Agriculture*, *115*, 26–33. <https://doi.org/10.1016/j.compag.2015.05.004>