



UNIVERSIDAD CÉSAR VALLEJO

**FACULTAD DE INGENIERÍA Y ARQUITECTURA
ESCUELA PROFESIONAL DE INGENIERÍA DE
SISTEMAS**

Algoritmo para la estimación de la masa del ganado bovino
mediante imágenes

**TESIS PARA OBTENER EL TÍTULO PROFESIONAL DE:
INGENIERO DE SISTEMAS**

AUTORES:

Gordillo Vásquez, Giomar (ORCID: 0000-0003-4494-6511)

Vila Huaman, Percy (ORCID: 0000-0001-8439-2918)

ASESORA:

Mag. Amorós Chaves, Gladys Jacqueline (ORCID: 0000-0003-3937-1119)

LÍNEA DE INVESTIGACIÓN

Sistema de información y comunicaciones

LIMA – PERÚ

2021

Dedicatoria

Dedicamos este trabajo de investigación a nuestros padres y seres amados por motivarnos para lograr nuestras metas. A nuestros docentes, por todo los consejos y enseñanzas. Por último y lo más importante, a Dios por darnos la salud y la fuerza para cumplir con este reto.

Agradecimiento

El inmenso agradecimiento a nuestros padres por haber estado presente en este desafío, brindándonos cariño y motivación. A nuestros profesores de la Universidad Cesar Vallejo por darnos los consejos y la exigencia para formarnos como excelentes profesionales. Al señor Hernán Gordillo Vásquez ganadero de la Región de Cajamarca por su colaboración y disposición para sacar adelante el proyecto.

Índice de contenidos

I. INTRODUCCIÓN	1
II. MARCO TEÓRICO	8
III. MÉTODO	18
3.1 Tipo y diseño de investigación	19
3.2 Variable y Operacionalización	19
3.3 Población, muestra y muestreo	21
3.4 Técnicas e instrumentos de recolección de datos	22
3.5 Procedimiento	23
3.6 Método de análisis de datos	23
3.7 Aspectos Éticos	24
IV. RESULTADOS	26
V. DISCUSIÓN	41
VI. CONCLUSIONES	45
VII. RECOMENDACIONES	47
REFERENCIAS	49
ANEXOS	59

Índice de tablas

Tabla 1: Estadístico descriptivos incremento de la precisión	27
Tabla 2: Prueba de normalidad incremento de la precisión	28
Tabla 3: Prueba de Wilcoxon del incremento de la precisión	28
Tabla 4: Prueba estadística Z incremento de la precisión.....	29
Tabla 5: Estadísticos descriptivos reducción del tiempo de entrenamiento	30
Tabla 6: Prueba de normalidad reducción del tiempo de entrenamiento	30
Tabla 7: Prueba de Wilcoxon de la reducción del tiempo de entrenamiento	31
Tabla 8: Prueba estadística Z reducción del tiempo entrenamiento.....	31
Tabla 9: Estadísticos descriptivos reducción del tiempo de identificación.....	32
Tabla 10: Prueba de normalidad reducción del tiempo de identificación.....	33
Tabla 11: Prueba de Wilcoxon de la reducción del tiempo de identificación	33
Tabla 12: Prueba estadística Z reducción del tiempo de identificación	34
Tabla 13: Estadístico descriptivos reducción del uso de CPU.....	34
Tabla 14: Prueba de normalidad reducción del uso de CPU.....	35
Tabla 15: Prueba de Wilcoxon de la reducción del uso de CPU	36
Tabla 16: Prueba estadística Z reducción del uso de CPU	36
Tabla 17: Estadístico descriptivos reducción del uso de memoria RAM	37
Tabla 18: Prueba de normalidad reducción uso de memoria RAM	38
Tabla 19: Prueba de Wilcoxon de la reducción del uso de memoria RAM.....	38
Tabla 20: Prueba estadística Z reducción del uso de memoria RAM.....	39
Tabla 21: Resumen resultados de aceptación o rechazo de las hipótesis	39
Tabla 22: Operacionalización de la variable.....	61
Tabla 23: Matriz de consistencia	62
Tabla 24: Requerimientos funcionales	67
Tabla 25: Ficha de observación para medir la precisión	78
Tabla 26: Ficha de observación para medir el tiempo de entrenamiento	78
Tabla 27: Ficha de observación para la medición del tiempo de identificación	79

Índice de figuras

Figura 1: Mapa de empatía	65
Figura 2: Diagrama de Ishikawa	66
Figura 3: Prototipo interfaz	67
Figura 4: Validación de la aplicación	68
Figura 5: Arquitectura tecnológica para el desarrollo del sistema	69
Figura 6: Arquitectura tecnológica para el usuario final.....	71
Figura 7: Pseudocódigo del algoritmo principal.....	72
Figura 8: Flujograma del algoritmo principal.....	73
Figura 9: Flujograma algoritmo Mask-RCNN.....	75
Figura 10: Diagrama de flujo algoritmo Mask-RCNN	76
Figura 11: Algoritmo CNN básico	77
Figura 12: Diagrama de flujo CNN básico	77

Índice de anexos

Anexo 1: Declaratoria de autenticidad.....	59
Anexo 2: Declaratoria de autenticidad del asesor	60
Anexo 3: Operacionalización de la variable	61
Anexo 4: Matriz de consistencia.....	62
Anexo 5: Metodología de desarrollo.....	64
Anexo 6: Arquitectura tecnológica para el desarrollo del sistema	69
Anexo 7: Arquitectura tecnológica para el usuario final.....	71
Anexo 8: Pseudocódigo y flujograma del algoritmo principal	72
Anexo 9: Flujograma del algoritmo principal.....	73
Anexo 10: Pseudocódigo y flujograma de los algoritmos que sirvieron de base para la elaboración del algoritmo principal original (si aplica)	75
Anexo 11: Instrumentos de recolección de datos de la investigación	78
Anexo 12: Consentimiento informado	81
Anexo 13: Porcentaje de similitud turnitin	¡Error! Marcador no definido.

Índice de abreviaturas

Sigla	Significado	Pág.
OIE	World Organization for Animal Health	2
BID	Banco Interamericano de Desarrollo	2
FAO	Food and Agriculture Organization of the United Nations	2
MINAGRI	Ministerio Nacional de Agricultura y Riego	3
MATLAB	Laboratorio de matrices	10
OpenCV	Open-Source Computer Vision	11
KERAS	Open-Source Neural Networks library	11
TensorFlow	Biblioteca de código abierto para aprendizaje automático	12
Mask-RCNN	Neuronal Network for Object Detection and Semantic	15
CNN	Convolutional Neuronal Network	15
SENASA	Servicio de Sanidad Agraria del Perú	16

Resumen

El objetivo de la presente investigación es determinar el efecto de un algoritmo basado en Mask-RCNN en la estimación de la masa del ganado bovino mediante imágenes. Para lo cual, se midieron los resultados del proceso de estimación de la masa del ganado mediante báscula y fórmula Schaeffer, luego haciendo uso de la aplicación, se realizaron con la finalidad de determinar la mejora a través de los siguientes indicadores: incremento de la precisión, reducción del tiempo de entrenamiento, reducción del tiempo de identificación, reducción del uso de CPU y la reducción del uso de memoria RAM.

La metodología de investigación utilizada fue de enfoque cuantitativo; de tipo aplicada, con un diseño pre-experimental. La población seleccionada para realizar esta investigación la conformaron 600 pares de imágenes de bovinos y la muestra estuvo constituida por 40 pares de imágenes. La técnica de recolección de datos fue la observación y para contrastar la hipótesis de la única variable y comparar el pre-test con el post-test se utilizó la prueba de Wilcoxon. Así se obtuvo como resultado el p valor = 0,00 que es menor al nivel de significancia 0.05 que decide que se desestime la hipótesis nula y se admita la alterna.

Se concluyó que con la implementación del algoritmo de procesamiento de imágenes se mejora significativamente la estimación de la masa del ganado bovino, que quedó demostrado por los resultados que se mejoró la precisión y se logró la reducción de los otros indicadores: tiempo de entrenamiento, el tiempo de identificación, el uso de CPU y el uso de memoria RAM. Esto respecto de sus situaciones iniciales.

Palabras claves: Aplicación web, algoritmos de procesamiento de imágenes, estimación de la masa y visión computacional.

Abstract

The objective of this research is to determine the effect of an algorithm based on Mask-RCNN in the estimation of cattle mass using images. For this purpose, the results of the cattle mass estimation process were measured using the scale and the Schaeffer formula, and then using the application, the following indicators were used to determine the improvement: increase in accuracy, reduction of training time, reduction of identification time, reduction of CPU usage and reduction of RAM usage.

The research methodology used was quantitative; applied, with a pre-experimental design. The population selected for this research consisted of 600 pairs of bovine images and the sample consisted of 40 pairs of images. The data collection technique was observation and the Wilcoxon test was used to contrast the hypothesis of the only variable and to compare the pre-test with the post-test. This resulted in a p-value = 0.00, which is less than the 0.05 significance level that decides to reject the null hypothesis and admit the alternative hypothesis.

It was concluded that with the implementation of the image processing algorithm, the estimation of the mass of cattle is significantly improved, which was demonstrated by the results that the accuracy was improved and the reduction of the other indicators: training time, identification time, CPU usage and RAM usage was achieved. This with respect to their initial situations.

Keywords: Web application, image processing algorithms, mass estimation and computer vision.

I. INTRODUCCIÓN

Desde la antigüedad la ganadería vacuna ha sido considerada como una de las principales ocupaciones que más han contribuido a la seguridad alimentaria y el desarrollo económico de la sociedad. En la actualidad la demanda de productos ganaderos ha aumentado exponencialmente, debido al crecimiento de la población.

En el campo de la ganadería bovina han surgido problemas de producción y productividad que se deben resolver con estrategias adecuadas para satisfacer la demanda de carne, leche y derivados; FAO (2021) indicó que el conocimiento, las técnicas, herramientas y tecnología ayudarán a lograr el desarrollo de una ganadería bovina sostenible (p. 2).

Según Espinoza (2018), las investigaciones parten de problemas (p. 14); por ello en esta sección se presentó la realidad problemática a nivel internacional, regional y a nivel local; en el que se precisa la situación o fenómeno a la que no se le encuentra solución y debe ser concretado con precisión.

En el campo de la ganadería vacuna han ocurrido muchos avances en la crianza y la gestión; como la obtención de diversas razas, el mejoramiento de la alimentación del ganado, la sanidad animal, etc. Al mismo tiempo, según la Organización Mundial de Sanidad Animal (2021) aún persisten dificultades que merman la productividad ganadera, que generalmente ocurre porque no se toman en cuenta otros factores de gestión como la adopción de las tecnologías de forma integral para solucionar los problemas (p. 18).

Desde una perspectiva mundial, la FAO (2019) en el informe sobre la condición de la ganadería, menciona dos tipos de dificultades una de ellas es la lenta transferencia y adopción tecnológica, con una acentuada diferencia entre la ganadería de los países desarrollados y de las naciones en vías de desarrollo. Y la otra es la débil gestión del ganado y establo (p. 16).

A nivel de Latinoamérica, especialistas del BID (2021), en el informe Productividad y eficiencia en la producción ganadera pastoril en América Latina, explican que se ha mejorado la productividad vacuna en un 35% en los países de América del sur (p. 36). Para continuar en esta ruta de crecimiento se debe

optimizar la gestión de los recursos y adoptar nuevos desarrollos tecnológicos con la finalidad de aumentar la eficiencia de la producción ganadera en la región Sudamérica (Nin-Pratt, Freiría y Muñoz, 2019, p. 24).

En el Perú investigadores del Minagri (2017) en su plan ganadero 2017-2021, identificaron los problemas del sector ganadero entre los que mencionan al deficiente manejo de la alimentación y la reproducción; también que existe debilidad o ausencia de programas de control, evaluación del mejoramiento genético y sanitario (p. 12). Por lo que es importante el uso de nuevas técnicas, tecnología y sistemas de manejo; gestión y control para contar con una ganadería competitiva (Naranjo, 2020, p. 9).

El proceso de estimación tradicional del peso vivo del ganado bovino es muy engorroso y estresante; además existen muchas técnicas y procedimientos de medición, algunos de los más confiables según Jang et al (2020) son los siguientes: Bascula, Schaeffer's formula, Agarwal's formula, Weighbridge tape, Weigh tape, Rondo tape y Calculator method (p. 24). De todo estos, la que brinda el peso exacto es la que se realiza mediante la báscula (Corea et al, 2020, p.68); pero también es la técnica que conlleva mayores gastos por la adquisición de una máquina de pesaje y otro inconveniente es que se somete a estrés al animal e incluso la interacción es peligrosa ya que al estar en contacto directo con el ganado se puede recibir cornadas o pisadas en los casos que el animal se asuste o no posea el temperamento tranquilo.

La estimación del peso del ganado es sumamente importante; Wangchuk, Wangdi y Mindu (2018) explicaron que es determinante a la hora de fijar las raciones de comida y los precios de venta de los animales, también para evaluar el valor reproductivo del ganado. Además, el peso corporal es la base principal para preparar las dosis correctas de productos veterinarios terapéuticos para tratar enfermedades del ganado (p. 8).

No se han descubierto en la revisión de la literatura trabajos similares que aborden sobre algoritmos para la estimación de la masa del ganado mediante visión computacional, tampoco del mejoramiento de la productividad ganadera empleando algoritmos computacionales. No obstante, se identificaron algunos estudios interesantes aplicados en el campo de la agricultura que se tomaron

como base para acondicionar, mejorar y crear un algoritmo propio para la ejecución del proyecto.

La investigación se justificó de cuatro formas: metodológica, teórica, tecnológica, y social; de acuerdo a Fernández-Bedoya (2020) esto se realiza para enfatizar la trascendencia e idoneidad del trabajo de investigación (p. 67). La justificación teórica según Baena (2017) es la que va estrechamente vinculado al interés del científico por perfeccionar las concepciones teóricas que encaren el problema (p.124). Con base a estas premisas la investigación tiene por finalidad la contribución al conocimiento disponible, la confrontación de teorías, la generación de debate académico, ser el fundamento para otros estudios similares y el esclarecimiento de las brechas de conocimiento en el área de la visión computacional aplicado en la ganadería.

En lo tecnológico, es importante el desarrollo de una aplicación para la estimación del peso del ganado bovino mediante imágenes, ya que la medición del peso del ganado es un proceso tedioso, costoso y repetitivo; la aplicación ayudará a optimizar esta tarea con el objetivo de mejorar de la productividad ganadera. En palabras de Santiago, Velázquez, Moreno y Salazar (2020) la incorporación de la tecnología influye de manera evidente en la producción ganadera, puesto que es el soporte de muchos procesos fundamentales y es cada vez mayor su uso a nivel mundial, por ello el aprovechamiento de las TICs en los establos y/o granjas puede llevar a la disminución de los costos, contribuir en la competitividad del negocio (p. 239).

Así mismo se justificó metodológicamente debido a que se utilizó técnicas e instrumentos de diseño propio para la recolección de información como la ficha de observación, el cuestionario; y métodos para la evaluación e identificación de las dificultades que impactan en la gestión de la ganadería bovina, además servirá como sustento metodológico para otras investigaciones similares.

En lo social, Salinas y Cardenas (2009) indican que toda investigación debe poseer cierta trascendencia social, logrando ser útil y beneficioso para la sociedad (p. 24). En correspondencia a estas premisas la investigación se justificó socialmente debido a que se llegó a solucionar un problema real de los

ganaderos, en nuestro caso el proceso de estimación del peso vivo del ganado era engorroso y costoso que afectan la productividad y la economía.

Sobre el sustento de la realidad expuesta se propuso el problema general y los problemas específicos de la investigación. El problema general fue: ¿Cuál es el efecto del uso del algoritmo en la estimación de la masa del ganado bovino mediante imágenes? Los problemas específicos de la investigación fueron los siguientes:

- PE1: ¿Cuál es el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN en la precisión?
- PE2: ¿Cuál es el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN en el tiempo de entrenamiento?
- PE3: ¿Cuál es el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN en el tiempo de identificación?
- PE4: ¿Cuál es el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN en el uso de CPU?
- PE5: ¿Cuál es el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN en el uso de memoria RAM?

El objetivo general fue: Determinar el efecto de un algoritmo en la estimación de la masa del ganado bovino mediante imágenes. Los objetivos específicos fueron los siguientes:

- OE1: Determinar el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN en la precisión.
- OE2: Determinar el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN en el tiempo de entrenamiento.

- OE3: Determinar el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN en el tiempo de identificación.
- OE4: Determinar el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN en el uso de CPU.
- OE5: Determinar el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN en el uso de memoria RAM.

En la presente investigación se planteó como hipótesis general: El algoritmo mejora la estimación de la masa del ganado bovino mediante imágenes. Las hipótesis específicas fueron las siguientes:

HE1: El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN incrementará la precisión.

Gómez y Castrillón (2019) lograron la detección automática de ganado bovino mediante algoritmo CNN con una precisión del 82%. Además, Khojastehkey *et al* (2018) estimaron el peso de camellos mediante imágenes con una precisión del 99% empleando una red neuronal artificial multicapa.

HE2: El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el tiempo de entrenamiento.

He, Ghioxari, Dollár y Girshick (2018) necesitaron aproximadamente 20 horas para entrenar Mask-RCNN en una sola instancia P3dn.24xlarge (8 GPU NVIDIA V100) en la plataforma de Amazon. En este mismo sentido investigadores de Google (2021) mediante el entrenamiento para la convergencia con alrededor de 22,500 pasos demoraron aproximadamente 6 horas en una instancia TPU v3-8.

HE3: El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el tiempo de identificación.

Song et al (2017) determinó el peso corporal de vacas lecheras mediante visión tridimensional, logrando la identificación en un tiempo de 0,001 s. En el mismo sentido, en otra investigación de reconocimiento de características mediante imágenes el tiempo de identificación fue 00001ms (Casa, 2020, p. 56).

HE4: El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el uso de CPU (Hao *et al*, 2021, p. 12).

HE5: El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el uso de memoria RAM (Liu, Hi y Li, 2020, p. 1008).

II. MARCO TEÓRICO

En este capítulo se exponen los trabajos previos de diversos autores en los que se desarrollaron algoritmos y aplicaciones enmarcadas en el campo de la visión computacional. De cada uno de estos estudios se presentan los siguientes aspectos: el objetivo, la metodología, los resultados y las conclusiones. También se explican sobre las teorías y conceptos ligados a la visión computacional, procesamientos de imágenes, algoritmos empleados, herramientas para el desarrollo de la aplicación además de la conceptualización de la variable, las dimensiones e indicadores propios de la investigación.

A continuación, se muestran los antecedentes internacionales como la investigación de Ameijeiras, González y Hernández (2020) que analizaron los algoritmos más eficaces para el rastreo y detección de objetos, basados en redes neuronales y facilidad de adaptación a una arquitectura de un sistema de videovigilancia inteligente. Ameijeiras, González y Hernández (2020) evaluaron los siguientes algoritmos: FasterR-CNN, R-FCN, SSD, YOLO, SPPnet, Mask R-CNN, Deep Sort. Ameijeiras, González y Hernández (2020) como resultado afirmaron que en sistemas de videovigilancia se deben integrar dos tipos de algoritmos, SSD con Mobilenet de base para la función de detección, y Deep Sort como rastreador, de esta manera se consigue mejor rendimiento. Ameijeiras, González, Hernández (2020) concluyeron que los algoritmos offline son más eficientes y dan mejores resultados luego de estos tipos de aplicaciones.

Wangchuk, Wangdi, Mindu, Wursinger y Zollitsch (2018), identificaron la técnica más fiable para estimar el peso corporal del ganado para usar en campo. Evaluaron las siguientes técnicas de medición: Weighbridge, Weigh tape, Rondo tape, fórmula de Schaeffer, fórmula de Agarwal y método de calculadora; se utilizó la báscula puente como referencia para las demás técnicas. Wangchuk, et al. (2018) como resultado evidenciaron que la fórmula de Schaeffer no fueron significativamente diferentes de las de Weighbridge, aunque las estimaciones superan en más de 21 kg al ganado Swiss y en más de 44 kg en el ganado Jersey Cross. Wangchuk et al. (2018) establecieron como población 89 vacas Brown Swiss y 34 Jersey Cross utilizaron el análisis de varianza. Concluyeron que la fórmula de Shaeffer es más confiable después de la báscula. Además,

afirmaron que la fórmula de Agarwal y la cinta Rondo son menos confiables y deben dejar de usarse.

Muhammad et al (2015) compararon el rendimiento de diferentes algoritmos de minería de datos para predecir el peso vivo en ovejas Harnai a partir de características biométricas. Evaluaron los siguientes algoritmos: CHAID, EXHAUSTIVE CHAID, CART y ANN. Muhammad et al (2015) establecieron como población 161 corderos Harnai con edades comprendidas entre 6-9 meses, se predijo el peso mediante variables explicativas utilizando medidas corporales lineales; a saber, longitud del cuerpo (BL), altura a la cruz (WH), circunferencia del pecho (CG), circunferencia del abdomen (PG), longitud de la cara (FL), longitud entre las orejas (LBE), longitud de las orejas (EARL), ancho (FTW) y largo (FTL) de la cola y factor sexual. Concluyeron que todos los algoritmos eran eficientes y que el uso de CHAID en la predicción del peso corporal presentó el mejor ajuste tanto en los criterios de calidad del modelo como en un diagrama de árbol de decisión fue el mejor visualmente.

Khojastehkey et al (2020) estimaron el peso vivo de los camellos Kalkoohi a través del procesamiento digital de imágenes. Emplearon MATLAB en donde extrajeron las características numéricas incluido la morfología, eje mayor, la longitud del eje menor, el número de elementos distintos de cero (NNZ) y el diámetro. Khojastehkey et al (2020) como resultado encontraron que la precisión final del modelo para estimar el peso fue del 99% y el coeficiente de correlación entre los pesos estimados por el modelo de red neuronal artificial y los pesos reales de los camellos fue del 98%; la desviación de los peso es de 2,21 Kg. Khojastehkey et al (2020) concluyeron que usar la tecnología de procesamiento de imágenes tiene buen potencial para determinar el peso aproximado de los camellos Kalkoohi convirtiéndose como una gran alternativa para lograr el peso exacto de los camellos que podría ser una buena alternativa a una balanza.

Li et al. (2018) desarrollaron una aplicación de reconocimiento de imágenes en 400 gramos de pimienta, se aplicó regresión logística, red neuronal para determinar el valor predictivo de la germinación de semillas, esta predicción se hizo a través de características físicas (color, ancho, área, largo, proyectado, densidad y peso) y el peso fresco. Li et al. (2018) concluyeron que el modelo desarrollado es efectivo para predecir la germinación de semillas según sus

características físicas y por lo tanto se utiliza como guía para el control de calidad a la hora de seleccionar semillas, reduciendo costos y mano de obra.

Cuevas (2019), implementó un algoritmo para la detección de ganado vacuno. Cuevas (2019) empleó la metodología de investigación aplicada, cuantitativa y experimental; para la obtención de datos e información se utilizó técnicas como el análisis de contenido y la observación. Cuevas (2019) como resultado evidenció que Python, OpenCV y YOLO acondicionadas adecuadamente brindaron resultados satisfactorios en concerniente al reconocimiento del objeto perseguido. Concluyó que el acondicionamiento de algoritmos de procesamiento de imágenes requiere de un exigente ejercicio de prueba con el método de ensayo-error para obtener los resultados esperados, debido a que la detección de objetos es un área en el que ocurren situaciones no previstas en una investigación.

Gómez y Castrillón (2019), desarrollaron una aplicación para la detección y videovigilancia automática de ganado bovino a cielo abierto, mediante la adquisición de imágenes aéreas capturadas con drones. La muestra estuvo conformada por 1300 fotos de ganados de cuatro fincas, que en un primer momento fueron etiquetados de manera manual. El algoritmo para detectar el ganado estuvo basado en redes neuronales partiendo de una arquitectura desarrollada en el lenguaje C. Gómez y Castrillón (2019) concluyó que el algoritmo denominado YOLO logró una precisión del 82% con sensibilidad del 75% y precisiones mAP del 71.51% mostrándonos que es posible usarlo en estos tipos de estudios.

Mota, Juárez y Olgúin (2018) implementaron un algoritmo que resuelve y disminuye el tiempo de selección de los frutos. Este proceso se realiza usando redes neuronales convolucionales, se empleó las librerías (Keras, Tensorflow y OpenCV). Como resultado obtuvieron que la precisión está entre 95.36% y 98.3%. La clasificación se hizo a través de un video en tiempo real con precisión de 95.36%. Mota, Juárez y Olgúin (2018) concluyeron que los resultados son prometedores, pero que pueden mejorar ampliando la base de datos para así entrenar al sistema en calidad de imágenes e iluminación. Además, este tipo de proyectos se pueden usar para detectar otros aspectos.

Castro (2019) determinó el algoritmo inteligente más eficaz para el reconocimiento de imágenes de la enfermedad foliar de palta. En su trabajo de investigación aplicó los siguientes algoritmos: Naive Bayes, Random Forest, Redes Neuronales y Support Vector Machines. Castro (2019) empleó la metodología de trabajo con las siguientes etapas: adquisición de imágenes, preprocesamiento, extracción de características y reconocimiento de imágenes. Castro (2019) luego de la evaluación encontró que el algoritmo de Soporte Vectorial tiene mayor precisión, alcanzando el 96% en la identificación de enfermedades foliares del cultivo de palta, esto después de ser evaluado con una matriz de confusión.

Lugo (2021) desarrolló una aplicación de visión computacional empleando la librería OpenCV y un dron para el reconocimiento de la plaga lancha en cultivos de tomate. El método que utilizó se fundamenta en la integración de redes neuronales artificiales convolucionales con la unidad dnn de la librería OpenCV con la finalidad de lograr el vuelo autónomo. Además, integró un módulo de comunicación que sirve de intermediario entre los datos de telemetría y el envío de datos a la base de datos y a la plataforma web. Lugo (2021) como resultado indicaron que se logró una precisión entre 58% a 85% con sensibilidad máxima de 55% en el reconocimiento de la enfermedad. Lugo (2021) concluyó que la aplicación de visión computacional utilizando librerías OpenCV y un dron logró la identificación y detección de la plaga para alertar a los agricultores de las zonas con mayor grado de propagación en los cultivos a que tomen medidas de control y tratamiento de la enfermedad.

Juanazo (2019) desarrolló una aplicación móvil en Android Studio de procesamiento digital de imágenes para el reconocimiento de banano de exportación. Juanazo (2019) como metodología utilizó las siguientes etapas: adquisición de la imagen, preprocesado, segmentación, extracción de características y clasificación de la imágenes. Juanazo (2019) como conclusión presentó que la aplicación logró la clasificación de los frutos de acuerdo a su madurez con una precisión del 85% para ello utilizó una red neuronal pre entrenada ResNet-50 utilizando la herramienta Deep Learning Toolbox.

En el ámbito nacional se encontraron los siguientes trabajos: la investigación de Arroyo (2021) que desarrolló e implementó un sistema de visión artificial para la alerta y detección de somnolencia. Arroyo (2021) aplicó el método de extracción de regiones utilizando una red neuronal convolucional y las cascadas Haar; para el desarrollo utilizó la biblioteca OpenCV, TensorFlow y Keras con el uso de estas herramientas se entrenó la red convolucional del tipo LedNet, usó el 80% de la base de datos para entrenar y el restante para validar. Arroyo (2021) presentó como resultado el algoritmo logró una precisión de entrenamiento de casi el 99%. Arroyo (2021) concluyó que, durante las pruebas finales, se determinó que, para evitar falsas detecciones de bostezo, se añadió medir la duración de bostezo y pestañeo para aumentar la precisión y extraer valores para la determinación del nivel de somnolencia.

Sucari, Arosquipa, Quina y Quispe (2020) implementaron visión artificial con la ayuda de patrones para lograr clasificar las frutas en agronegocios. Sucari, Arosquipa, Quina y Quispe (2020) plantearon como objetivo determinar la efectividad de utilizar visión computacional en la identificación de patrones para la clasificación de frutas en las empresas agropecuarias. Empleó una base de datos con 50 registros y 6 tipos de frutas considerando 4 detalles y una muestra de 20 frutas, utilizando el método del reconocimiento automático a través de clasificador bayesiano, se logró el reconocimiento hasta un máximo de 93.33% y errando en solo 6.67%. Sucari, Arosquipa, Quina y Quispe (2020) concluyeron que se logró una alta eficacia a la hora de emplear la visión computacional en el reconocimiento de patrones con la finalidad de mejorar la clasificación de frutas.

La visión artificial es un tema transversal en esta investigación, es una tecnología relativamente nueva, que también es conocido como visión por computador, que desarrolla teorías y métodos para la extracción de información útil contenida en las imágenes; según Domínguez (2021) son aplicaciones integradas por hardware y software que permiten la captación y el procesamiento de imágenes (p. 25). En ese mismo sentido Bolaños, Arango y Vallejos (2018) explican que la visión artificial consiste en el recorrido automático de la estructura y características del universo tridimensional, desde una o varias imágenes bidimensionales (p. 35). Es un campo que integra áreas como la óptica, la electrónica, la física del color, la geometría y la ciencia computacional.

En un sistema de visión artificial se pueden encontrar diversos componentes, los investigadores de IBM (2020) indican que lo conforman los siguientes elementos: La iluminación, el lente, el sensor de imagen, el procesamiento de visión y las comunicaciones (párr. 4). Mientras que para Somolinos (2002) lo conforman los siguientes subsistemas: iluminación, captación, procesamiento y periféricos.

En el desarrollo de proyectos de visión computacional se tiene que seguir fases. Gonzáles et al. (2006, p. 124) explican que estas son las etapas más comunes:

1. Captación de imagen: Es una serie de actividades que se realizan para modificar la información luminosa de un escenario en una señal digital.
2. Procesamiento: Consiste en la búsqueda del perfeccionamiento de la imagen mediante actividades como: corrección de la uniformidad luminosa, la supresión de defectos, intensificación de los bordes de los objetos contenidos en la imagen, normalizar los colores, las texturas, etc.
3. Segmentación: El propósito de la segmentación es separar los diferentes objetos entre sí.
4. Representación y descripción: Esta etapa consiste en la interpretación de las características internas (color y textura) y externas (medidas, figuras, curvas, etc.). La descripción trata de la extracción de cualidades con algún dato de relevancia o que sea necesario para distinguir diversos objetos. Por ejemplo: el color y la figura.
5. Reconocimiento e Interpretación: En esta etapa se asigna una etiqueta a un objeto reconocido, además se asigna un significado a diversos objetos reconocidos.

En este proyecto se trabajan con imágenes de ganado bovino, al respecto Alegre, Pajares y De la Escalera (2016) indican que son figuras bidimensionales que expresan la apariencia de un escenario tridimensional. La imagen es el producto de la obtención de una señal generada por un sensor que transforma la información del conjunto de ondas electromagnéticas en sistema binario.

Los algoritmos en informática son una serie de instrucciones que llevan a cabo un proceso, lo hay de diversos tipos y campos de aplicación; en este

proyecto se empleó como base el algoritmo Mask-RCNN; los investigadores Zhang, Chang y Bian (2020) explican que son modelos de aprendizaje profundo que combinan la detección y segmentación de objetivos en una red (p. 6997). Una de sus fortalezas es que permite segmentar con precisión a individuos en diferentes categorías y etiquetar cada pixel en la imagen para distinguir diferentes individuos en la misma categoría.

Mask-RCNN es un modelo de red neuronal artificial (RNC) que está compuesta de neuronas agrupadas en capas, Mera y Ochoa (2020) explican que estas poseen la característica de aprender cualidades de orden superior que se encuentran en los datos a través de muestreos convolucionales por ello es muy empleado en el reconocimiento de imágenes (p. 56).

La estimación de la masa de ganado es una actividad importante para los ganaderos, al respecto Babera (2020) explica que para la estimación de la masa se pueden emplear varias de técnicas, que van desde medición por medio de la báscula, a otras más complejas y modernas como el uso de marcadores radiactivos para determinar el contenido de grasa (p. 124). En esta investigación se empleó la técnica de estimación Schaeffer's, que posee una alta precisión y es respaldado por diversos estudios.

En la investigación se utilizaron las siguientes dimensiones: precisión, tiempo de entrenamiento, tiempo de identificación, uso de memoria RAM y uso de CPU y los indicadores están relacionados al incremento o reducción de cada uno de ellos.

Acerca de la precisión, Xu (2017) expresa que es una de las características del rendimiento y que ayuda a medir la eficacia del algoritmo como proporción de resultados verdaderos en comparación con el total de casos; indica la proximidad del resultado de la medición con respecto al valor verdadero (p. 2).

Según Microsoft (2021) el tiempo de entrenamiento significa emplear datos históricos para desarrollar un modelo que reduzca los errores. El total de minutos u horas requeridos para entrenar un modelo varía mucho y además depende de las propiedades de los algoritmos (número de neuronas en la capa,

condiciones ideales, iteraciones, patrones de entrada y salida, tasa de aprendizaje y momento).

Para Kulkarni, Lohit, Turaga, Kerviche y Ashok (2016), el tiempo de identificación pertenece a una característica de la categoría rendimiento y se mide en segundos, permite calcular el tiempo que demora un modelo en la descubrir los parámetros y características de los objetos (p. 107).

Biswas y Chandrakasan (2018) explican que el uso de memoria RAM influye en el rendimiento del sistema, que para configuraciones exigentes se necesita unidades con mayores capacidades, la velocidad de la misma y menores latencias; estos dispositivos son utilizadas como memoria de trabajo (p. 108, párr. 2).

Menes et al (2015) indican que el uso del CPU corresponde a la categoría de uso de recursos del computador; relacionado a la lectura, interpretación y procesamiento de la información al inicio del sistema operativo luego de las aplicaciones que se ejecuten (p. 108). Una aplicación poseerá mejor rendimiento en relación a la utilización del CPU cuanto menor sea su valor.

En el desarrollo de la aplicación se utilizaron las siguientes tecnología: se usa el lenguaje Python, debido a que posee muchas librerías orientadas a la visión computacional como OpenCV, Numpy, imutils, matplotlib, SciPy, Pil, Scikit-image, tensorflow. García-Monsalves (2017) explica que Python facilita trabajar con machine learning, ciencia de datos, inteligencia artificial, internet de las cosas, etc. (p. 150).

TensorFlow es la principal librería para el proyecto, utilizada para detectar la correlación y descifrar patrones en las imágenes. Google (2020), los desarrolladores de esta librería expresan que es un ecosistema integral para aprendizaje automático, debido a que es el mejor computando gradientes automáticamente a un nivel más profundo que otras librerías.

Otra librería usada es Numpy, la cual proporciona un soporte que permite arreglar imágenes, ya que mediante el uso de operaciones numéricas se pueden modificar los valores de píxeles en una imagen.

Las actividades de este proyecto se realizaron con metodología Design Thinking, una de sus ventajas es que está enfocado en la resolución de cualquier tipo de problemas. Castillo, Álvarez y Cabana (2014) explican que se puede emplear en el desarrollo de productos y servicios, en la elaboración de modelos de negocio, en la planificación estratégica y hasta en el desarrollo de software. Esta metodología tiene las siguientes fases: empatía, definición, ideación, prototipado y testeo (Latorre et al., 2020).

III. MÉTODO

En este capítulo se esclarecerá sobre los siguientes aspectos: el tipo y diseño de investigación, la variable de análisis, la operacionalización, la población, muestra y muestreo seleccionado según criterio; los instrumentos de acopio de datos empleados, los procedimientos, los métodos de análisis de datos detallados y por último los aspectos éticos que fueron tomados en cuenta.

3.1 Tipo y diseño de investigación

La forma de investigación es aplicada, de acuerdo con Vargas (2009), esta se distingue porque persigue el empleo de los conocimientos adquiridos por medio de la sistematización (p. 159). Dicho de otra forma, su implementación busca resolver dificultades en la ejecución de un proyecto apoyándose en la continua indagación y recolección de información para adquirir nuevos conocimientos científicos.

La presente investigación es de enfoque cuantitativo. Falcón et al. (2016) infiere que este enfoque es secuencial, riguroso y refleja la necesidad de medir las magnitudes de los fenómenos investigados (p. 74). Este enfoque se fundamenta en la medición numérica, el uso de la estadística descriptiva e inferencial para probar las hipótesis.

El diseño de la investigación es pre-experimental, según Bernal (citado por Salas, 2013) estos diseños ofrecen un débil control de las variables y no permiten la adjudicación al azar de los individuos al experimento pueden además pueden servir para resolver problemas situacionales (p. 137). En concordancia a esta premisa, en esta investigación no hay manipulación de la variable y tampoco hay grupo control.

3.2 Variable y Operacionalización

La variable de estudio es: Efecto del uso de un algoritmo para estimar la masa del ganado bovino mediante imágenes. Así mismo, en el anexo 3 se muestra la matriz de operacionalización. A continuación, se define el aspecto conceptual y operacional de la variable:

A. Definición conceptual: Song et al (2018, p. 4456) infiere que un algoritmo que permita la estimación continua puede ayudar a los ganaderos a obtener información sobre los cambios del ganado a lo largo del tiempo. La automatización de la estimación del ganado contribuirá a mantener una atención de alta calidad para el ganado en un tamaño y una producción cada vez mayores.

B. Definición operacional: la medición del efecto de la aplicación para la estimación de la masa del ganado bovino mediante imágenes ayudará a mejorar la productividad de la ganadería. (Song et al, 2018, p. 4456).

C. Dimensiones:

- Precisión (Xu, 2017, p. 2).
- Tiempo de entrenamiento (Song et al, 2018, p. 4468).
- Tiempo de identificación (Kulkarni, Lohit, Turaga, Kerviche y Ashok, 2016, p. 15).
- Uso de memoria RAM (Menes et al, 2015, p. 108)
- Uso de CPU (Menes et al, 2015, p. 108).

D. Indicadores:

- Incremento de la precisión (Bonnet et al., 2020, p. 16).
- Reducción del tiempo de entrenamiento (Song et al, 2018, p. 4468).
- Reducción del tiempo de identificación (Kovalyk, 2020, p. 25).
- Reducción del uso de memoria RAM (Menes et al, 2015, p. 108).
- Reducción del uso de CPU (González, 2020, p. 44).

E. Instrumento:

- Se empleó la ficha de observación para la recopilación de información de los cinco indicadores. Además, Campos y Lule (2012) esclarecen que mediante este instrumento el investigador solo se limita a tomar nota de lo sucedido para conseguir sus fines (p. 53).

F. Escala de medición:

- Se utilizó la escala razón para la totalidad de los indicadores debido a que están asignadas para representar variables cuantitativas. Orlandoni (2010) indica que en esta escala los números hacen posible confirmar si un elemento es igual o distinto a otros de la muestra (p. 246).

3.3 Población, muestra y muestreo

La población según López (2004), es una colección de todos los casos que cumplen una serie de especificaciones (p. 69). Se entiende que la población es el conjunto de individuos u objetos de una misma clase que poseen características similares. El proyecto abarca una población de estudio conformada por 600 pares de imágenes (frontal y lateral) de ganado bovino, acopiadas de una granja de la región de Cajamarca.

- Criterios de inclusión: bovinos a partir de un año en adelante, pueden pertenecer a estas categorías de clasificación: vaquilla, torete, vaquillona, vaca y toro. En cuanto a la raza estos pueden ser principalmente criollos y Holstein.

- Criterios de exclusión: bovinos menores a 1 año, animales de otras especies distintas como ovejas, cabras, cerdos, etc.

Así mismo, Ventura-León (2017) definen que la muestra en un proceso cuantitativo es un subgrupo de la población objetivo sobre la que se van a recolectar los datos, debe estar definida o delimitada con precisión con anterioridad y debe representar la población (p. 648). En el proyecto se está considerando como muestra 500 pares de imágenes de ganado bovino.

Seguidamente, Otzen y Manterola (2017) indican que una muestra puede ser obtenida de dos formas: probabilística y no probabilística (p. 226). Los muestreos probabilísticos según Hernández-Ávila y Carpio (2019) están basados en fundamentos matemáticos y emplean métodos que persiguen que todos los sujetos de una población posean la misma probabilidad de ser seleccionados para representarla (p. 76). Y en caso de ser muestras no probabilísticas el único requisito que debe cumplir es la cuota del número requerido de sujetos (Salinas, 2004, p. 122). En el proyecto, la muestra se obtuvo por conveniencia, debido a que solo necesitamos una cuota específica de imágenes de acuerdo a ciertas

características previamente definidas y también por las dificultades para recolectar las imágenes a raíz de la pandemia del COVID-19.

3.4 Técnicas e instrumentos de recolección de datos

En la investigación se utilizó la técnica de la observación no participante y como instrumento la ficha de observación. Para utilizarlos se comprobaron la validez y la confiabilidad de los instrumentos aplicados.

De acuerdo con Campos y Lule (2012), en la observación no participante el observador no interviene en la situación a estudiar. El investigador no se asocia con el acontecimiento ni lo modifica, analiza el marco referencial del evento tal como es, sin que su percepción sea influenciada por las acciones de las personas que observa.

La ficha de observación se utiliza para examinar acontecimientos que aún se desconocen (Arias y Covinos, 2021). En este instrumento las características del objeto estudiado determinan los criterios de interés para el registro de los datos.

Reidl-Martinez (2013) explica que un instrumento en el que su aplicación produce resultados iguales y consistentes, es un instrumento que presenta un alto grado de confiabilidad (p. 018). Por otro lado, la validez es uno de los requisitos esenciales que debe reunir el instrumento, Manterola et al. (2018) indican que la validez evalúa el nivel en que un instrumento mide con veracidad la variable que se intenta calcular (p. 682). Esto quiere decir que para que una investigación tenga información real, debe contar con un instrumento fiable que valide todos los aspectos que se desarrollen a lo largo del desarrollo de la investigación (Villasís et al, 2018, p. 416).

Al respecto, existen diferentes tipos de validez, que relacionan la evidencia (Galicia, Balderrama y Navarro., 2017). Solo se argumentaron las necesarias para esta investigación. En ese mismo sentido, Galicia, Balderrama y Navarro (2018) sostienen que la validación del contenido es un paso esencial en el desarrollo de nuevas medidas, porque representa el inicio de mecanismos asociados a conceptos abstractos para indicadores observables y medibles. La validación está relacionada con la exactitud y el propósito de la aplicación. Del

mismo modo, Hernández, Fernández y Baptista (citaron a Bohrnstedt,1976) explican que la validez de contenido es el grado en que el instrumento refleja el dominio de contenido particular respecto del contenido medido (2010, p. 201).

Según Urrutia, Barrios, Gutiérrez y Mayorga (2014, p. 547) la validez del constructo es un tema esencial en la investigación, precisamente porque muchas de las variables investigadas no son fáciles o no están bien definidas. Adicionalmente Jorna, Castañeda y Veliz (2015) define un constructo como una variable medida que está situada con base y evidencia empírica en la literatura y teoría (p.105). Es por ello, que se requiere un porcentaje mayor al 60% de explicación de la varianza en los factores identificados para validar el instrumento representado en la investigación.

3.5 Procedimiento

El procedimiento permite crear un orden entre los procesos para su mejora en el que también se deben integrar los instrumentos estadísticos para el procesamiento y alejamiento de la subjetividad de los resultados (Pérez, Ocampo y Sánchez, 2015, p.12). En la investigación se realizaron los siguientes pasos:

- Se informó al ganadero aliado sobre los pormenores de la investigación y la aceptación se registró por medio de un documento de consentimiento informado
- Se realizaron la recopilaciones de imágenes.
- Etiquetación de las imágenes empleando identificadores.
- Se organizaron las imágenes en una carpeta de la pc y en Google drive.
- Se realizó el Pre-test mediante la fórmula de Schaeffer's
- Se procesó las imágenes con el algoritmo
- Se analizaron los resultados
- Se midieron los incrementos comparando el pre-test y el post-test

3.6 Método de análisis de datos

A continuación, se explicará de manera descriptiva el método de análisis utilizado en el proyecto de investigación.

En esta investigación se utilizó la prueba de Shapiro-Wilks para contrastar la normalidad de la muestra, Según (Herrera et al., 2012, p. 63) las prueba de Kolmogorov-Smirnov y de Shapiro-Wilks son pruebas de bondad de ajuste que miden el grado de coherencia entre la distribución de un conjunto de datos y una distribución teórica específica. Es decir, se utilizar para verificar si la muestra sigue o no una distribución normal.

Romero-Saldaña (2016) indica que para verificar la normalidad de la muestra cuando el tamaño es igual o menor a 50 y que además el tipo de investigación sea aplicada, se debe utilizar la prueba de Shapiro-Wilks.

En síntesis, se consideró que si la muestra es mayor o igual a 50 se debe utilizar la prueba Kolmogorov-Smirnov; en muestras menores a 50 se usa el test de Shapiro Wilk y que el nivel significancia p decide si la distribución es normal cuando p es mayor e igual a 0.05 y, si p es menor a 0.05 es no normal (Flores, Muñoz y Sánchez, 2019).

3.7 Aspectos Éticos

Con pleno conocimiento de la importancia de la ética en el quehacer investigativo, en esta sección se muestran las legislaciones, principios y resoluciones que fueron tomados en cuenta para asegurar el respeto de la dignidad humana, la protección de los datos personales, el respeto a la privacidad, la confidencialidad, el respeto de la vida y buen trato hacia los animales.

En todo momento la investigación se sujetó en la resolución del consejo universitario N° 0262 de la Universidad César Vallejo 2020, que considera que el código de ética es imprescindible para llevar a cabo una investigación en la UCV (Vicerrectorado de Investigación, N°2, 2020).

La institución superior César Vallejo potencia la originalidad de los trabajos de investigación y reafirma que el plagio es un delito. Por ello en el trabajo se realizó un correcto citado en el formato deseado de acuerdo con la resolución de la institución (Vicerrectorado de Investigación, N°9, 2020).

Además se tomó en cuenta el código de ética del Colegio de Ingenieros del Perú específicamente los siguientes artículos: El Artículo 13°, el cual indica acerca la conducta y comportamiento del ingeniero, que estos deben estar alineados con los objetivos y fines de la Institución; el Artículo 15° indica que los principios fundamentales deben orientar la conducta de un investigador y algunos de estos son: La lealtad profesional, la honestidad, respeto, justicia, inclusión social, la responsabilidad, la solidaridad y el honor profesional.(Colegio de Ingenieros, 1999, p.2-3).

En cuanto al cumplimiento de los principios de la bioética se tuvo en cuenta las acciones que dictamina el Vicerrectorado de Investigación (citó a la UNESCO, 2005) el cual recomienda que se acepten principios éticos universales con base en al respeto de si mismo y de los demás; de sus derechos (Vicerrectorado de Investigación, p. 3, 2020). Además, la investigación se ciñe a los cuatro principios del pensamiento normativo: no maleficencia, beneficencia, autonomía y justicia.

Las conceptualizaciones de los cuatro principios son las siguientes: No maleficencia es nunca hacer daño a los demás. La beneficencia consiste en hacer el bien. La autonomía es el principio que enfatiza la importancia de la libertad y la elección individual. Y por último la justicia es la distribución equitativa de los riesgos, beneficios y costos.

IV. RESULTADOS

En este apartado se llevó a cabo la exposición pormenorizada de los resultados hallados en la investigación de cada uno de los siguientes indicadores: incremento de la precisión, reducción del tiempo de entrenamiento, reducción del tiempo de identificación, reducción del uso de CPU y reducción del uso de memoria RAM. Para ello se realizó el procesamiento de datos de cada uno de los indicadores planteados mediante una ficha de observación. Además, se efectuó el análisis con el programa SPSS Statistics de IBM y MS Excel con la finalidad de sistematizar la obtención de resultados.

4.1 Prueba de hipótesis específica 1

H₁₀: El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN no incrementará la precisión.

H₁₁: El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN incrementará la precisión.

Datos descriptivos del incremento de la precisión

En la tabla 1 se detallan los estadísticos descriptivos de acuerdo a los resultados obtenidos del pre-test y del post-test que pertenecen a una muestra de 40.

Tabla 1: Estadístico descriptivos incremento de la precisión

	N	Media	Desviación estándar	Mínimo	Máximo	Percentiles			
						25	50	75	90
Precisión Pre-test	40	0,9150	0,01396	0,89	0,94	0,90	0,92	0,92	0,94
Precisión Post-test	40	0,9760	0,00672	0,96	0,99	0,97	0,98	0,98	0,98

Se analizó los resultados descriptivos del indicador incremento de la precisión, en el pre-test la precisión media fue 91,50% y en el post-test la media fue 97,60%, esto quiere decir que el algoritmo para la estimación de la masa del ganado bovino incrementó la precisión en 6,10%, que fue hallada mediante la siguiente fórmula:

$$IP = P_{post} - P_{pre}$$

Reemplazando se obtiene:

$$IP = 6,10\%$$

A partir de los estadísticos observados podemos afirmar que hay un incremento de la precisión

Prueba de normalidad

Para hallar la distribución de los datos se utilizó el test de Shapiro-Wilk, porque el subgrupo es menor a 50. A continuación se muestran los resultados de la test para el pre-test y post-test.

Tabla 2: Prueba de normalidad incremento de la precisión

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
Precisión Pre-test	0,184	40	0,002	0,896	40	0,001
Precisión Post-test	0,274	40	0,000	0,814	40	0,000

En la tabla 2, se observa que después de aplicar la prueba de normalidad al pre-test el nivel de significancia es menor a 0.05, por esta razón este subgrupo del pre-test no se adecua a una distribución normal.

Además, se observa que luego de aplicar la prueba de normalidad al post-test se obtiene un nivel de significancia menor a 0.05, entonces la muestra post-test tampoco se adecua a una distribución normal. Cuando los datos no poseen una distribución normal, además la variable se cuantitativa y la escala razón se procede a aplicar la prueba de Wilcoxon.

En seguida se muestran los resultados de la prueba no paramétrica de Wilcoxon

Tabla 3: Prueba de Wilcoxon del incremento de la precisión

		N	Rango promedio	Suma de rangos
Precisión pre-test - Precisión post-test	Rangos negativos	40 ^a	20.50	820,00
	Rangos positivos	0 ^b	0,00	0,00
	Empates	0 ^c		
	Total	40		

- a. Precisión pre-test < Precisión post-test
- b. Precisión pre-test > Precisión post-test
- c. Precisión pre-test = Precisión post-test

En la tabla 4, se muestra la estadística de prueba Z sobre el incremento de la precisión.

Tabla 4: Prueba estadística Z incremento de la precisión

	Precisión pre-test - Precisión post-test
Z	-5,539 ^b
Sig. asin. (bilateral)	0,001

- a. Prueba de rangos con signo de Wilcoxon
- b. Se basa en rangos negativos.

En la tabla 4 se muestra los resultados del estadístico de contraste, se observa que en la zona Z el valor obtenido fue -5.359, el cual se encuentra en la región de rechazo y el valor $p = 0.000 < 0.05$, por lo tanto, se rechaza la H_{10} y se acepta la H_{11} ; esto significa que las medias entre el pre-test y post-test son significativamente diferentes, por esta razón se aceptó que el algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN incrementará la precisión.

4.2 Prueba de hipótesis específica 2

H_{20} : El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN no reducirá el tiempo de entrenamiento.

H_{21} : El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el tiempo de entrenamiento.

Datos descriptivos de la reducción del tiempo de entrenamiento

En la tabla 5 se detallan los estadísticos descriptivos de acuerdo a los datos del pre-test y del post-test que corresponde a una muestra de 40.

Tabla 5: Estadísticos descriptivos reducción del tiempo de entrenamiento

	N	Media	Desviación estándar	Mínimo	Máximo	Percentiles			
						25	50	75	90
Tiempo de entrenamiento pre-test	40	18,4392	0,73380	16,83	19,93	17,9225	18,4650	18,9950	19,4620
Tiempo de entrenamiento post-test	40	5,6475	0,45709	5,07	6,29	5,2625	5,47	6,15	6,186

A partir de los datos descriptivos observados se concluye que hay una reducción del tiempo de entrenamiento. Por razón de que en el pre-test el tiempo de entrenamiento media fue 18,4392 minutos y en el post-test la media fue 5,6475 minutos, esto quiere decir que el algoritmo para la estimación de la masa del ganado bovino redujo el tiempo de entrenamiento en 12,7917 minutos, que fue hallado mediante la siguiente fórmula:

$$RTE = E_{pre} - E_{post}$$

Reemplazando se obtiene:

$$RTE = 12,7917$$

Prueba de normalidad

La normalidad del subgrupo se calculó mediante el test de Shapiro-Wilk, porque la muestra es menor a 50. En la tabla conjunta se detallan los resultados del test tanto del pre-test y post-test.

Tabla 6: Prueba de normalidad reducción del tiempo de entrenamiento

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
Tiempo de entrenamiento Pre-test	0,112	40	0,200*	0,982	40	0,774
Tiempo de entrenamiento Post-test	0,256	40	<,001	0,808	40	<,001

*. Esto es un límite inferior de la significación verdadera.

a. corrección de significación de Lilliefors

Analizando los resultados de la tabla 6 se visualiza que después de aplicar la prueba de normalidad al pre-test, se obtiene un nivel de significancia mayor a 0.05, por lo tanto, no se ajusta a una distribución normal.

Además, se observa que luego de aplicar la prueba de normalidad al post-test el nivel de significancia fue menor a 0.05, entonces no se ajusta a una distribución normal. En casos que la distribución sea no normal, además la variable sea cuantitativa y la escala razón se procede a aplicar la prueba de Wilcoxon.

En la tabla 7 se muestra los resultados de la prueba no paramétrica

Tabla 7: Prueba de Wilcoxon de la reducción del tiempo de entrenamiento

		N	Rango promedio	Suma de rangos
Tiempo de entrenamiento Pre-test – Tiempo de entrenamiento Post-test	Rangos negativos	0 ^a	0,00	0,00
	Rangos positivos	40 ^b	20,50	820,00
	Empates	0 ^c		
	Total	40		

- a. Tiempo de entrenamiento pre-test < Tiempo de entrenamiento post-test
- b. Tiempo de entrenamiento pre-test > Tiempo de entrenamiento post-test
- c. Tiempo de entrenamiento pre-test = Tiempo de entrenamiento post-test

Tabla 8: Prueba estadística Z reducción del tiempo entrenamiento

	Tiempo de entrenamiento Pre-test – Tiempo de entrenamiento Post-test
Z	-5,511 ^b
Sig. asin. (bilateral)	<,001

- a. Prueba de rangos con signo de Wilcoxon
- b. Se basa en rangos negativos.

En la tabla 8 se observa que el valor de la zona Z fue -6.166, dicho valor se encuentra en la zona de rechazo y además el valor $p = 0.001 < 0.05$, lo que indica que se rechaza la H_0 y se acepta la H_1 ; esto significa que las medias entre el pre-test y post-test son significativamente diferentes, por lo tanto, se aceptó la hipótesis de que el algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el tiempo de entrenamiento.

4.3 Prueba de hipótesis específica 3

H_{3_0} : El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN no reducirá el tiempo de identificación.

H_{3_1} : El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el tiempo de identificación.

Datos descriptivos del incremento de la reducción del tiempo de identificación

En la tabla 9 se detallan los estadísticos descriptivos según los datos analizados del pre-test y del post-test que pertenecen a una muestra de 40 imágenes.

Tabla 9: Estadísticos descriptivos reducción del tiempo de identificación

	N	Media	Desviación estándar	Mínimo	Máximo	Percentiles			
						25	50	75	90
Tiempo de identificación Pre-test	40	5,3997	0,46664	5	6	5	5	6	6
Tiempo de identificación Post-test	40	2,4649	0,07265	2,34	2,63	2,41	2,46	2,55	2,57

A partir de los datos descriptivos observados se concluye que hay una reducción del tiempo de identificación debido a que en el pre-test el tiempo de identificación media fue 5,3997 minutos y en el post-test la media fue 2,4649 minutos, esto quiere decir que el algoritmo para la estimación de la masa del ganado bovino redujo el tiempo de identificación en 2,9348 minutos, que fue hallada mediante la siguiente fórmula:

$$RTI = TI_{pre} - TI_{post}$$

Reemplazando los valores respectivos se obtiene:

$$RTI = 2,9348$$

Prueba de normalidad

Para hallar la distribución del subgrupo de la población de estudio se recurrió al test de Shapiro-Wilk, debido a que la muestra es menor a 50. En la tabla conjunta

se muestran los resultados de las pruebas de normalidad del Pre-test y Post-test.

Tabla 10: Prueba de normalidad reducción del tiempo de identificación

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
Tiempo de identificación Pre-test	0,329	40	<,001	0,690	40	<,001
Tiempo de identificación Post-test	0,116	40	0,187	0,965	40	0,254

a. corrección de significación de Lilliefors

Analizando la tabla 10 se observa que luego de aplicar Shapiro Wilk al pre-test, el nivel de significancia fue menor a 0.05, por esta razón la muestra no se ajusta a una distribución normal.

Además, luego de aplicar la prueba de normalidad al post-test el nivel de significancia fue mayor a 0.05, entonces esta muestra si se ajusta a una distribución normal. En los casos que por lo menos uno de las muestra tenga una distribución no normal, la variable sea cuantitativa y la escala razón se procede a aplicar la prueba de Wilcoxon.

En la tabla 11 se muestran los resultados de la prueba no paramétrica aplicado al tiempo de identificación

Tabla 11: Prueba de Wilcoxon de la reducción del tiempo de identificación

		N	Rango promedio	Suma de rangos
Tiempo de identificación Pre-test - Tiempo de identificación Post-test	Rangos negativos	0 ^a	0,00	0,00
	Rangos positivos	40 ^b	20,50	820,00
	Empates	0 ^c		
	Total	40		

- a. Tiempo de identificación Pre-test < Tiempo de identificación Post-test
- b. Tiempo de identificación Pre-test > Tiempo de identificación Post-test
- c. Tiempo de identificación Pre-test = Tiempo de identificación Post-test

En la tabla 12 se muestra la estadística de prueba Z sobre la reducción del tiempo de identificación.

Tabla 12: Prueba estadística Z reducción del tiempo de identificación

	Tiempo de identificación Pre-test -Tiempo de identificación Post-test
Z	-5,511 ^b
Sig. asin. (bilateral)	<,001

c. Prueba de rangos con signo de Wilcoxon

d. Se basa en rangos negativos.

El valor de la zona Z fue -5.511, el cual se encuentra en la región de rechazo y el valor $p = 0.001 < 0.05$, en concordancia a esto resultados se desestima la H_{30} y se admite la H_{31} ; esto significa que las medias entre el pre-test y post-test son significativamente diferentes, por lo tanto, se aceptó que el algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el tiempo de identificación. En la investigación se disminuyó el tiempo de identificación en una media de 2,9348 minutos.

4.4 Prueba de hipótesis específica 4

H_{40} : El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN no reducirá el uso de CPU

H_{41} : El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el uso de CPU.

Datos descriptivos de la reducción del uso del CPU

En la tabla 13 se muestran los estadísticos descriptivos de acuerdo al análisis de datos de una primera y segunda prueba que pertenece a una muestra de 40.

Tabla 13: Estadístico descriptivos reducción del uso de CPU

	N	Media	Desviación estándar	Mínimo	Máximo	Percentiles			
						25	50	75	90
Uso de CPU primera prueba	40	5,87	0,46098	5,24	6,65	5,49	5,75	6,32	6,59

Uso de CPU segunda prueba	40	4,9075	0.50761	4,15	5,95	4,5425	4,8150	5,3275	5,72
---------------------------	----	--------	---------	------	------	--------	--------	--------	------

A partir de los datos descriptivos observados se concluye que hay una reducción del uso de CPU debido a que en la primera prueba el uso de CPU media fue 5,87% y en la segunda prueba se conseguido una media de 4,90%, esto quiere decir que el algoritmo para la estimación de la masa del ganado bovino redujo el uso de CPU en 0,9625%, que fue hallada mediante la siguiente fórmula:

$$RUCPU = P_{primera} - P_{segunda}$$

Reemplazando se obtiene:

$$RUCPU = 0,9625$$

Prueba de normalidad

Para encontrar la normalidad del subgrupo se utilizó el test de Shapiro-Wilk porque la muestra es menor a 50. En la tabla conjunta se muestran los resultados de la prueba realizada a la primera y segunda evaluación.

Tabla 14: Prueba de normalidad reducción del uso de CPU

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
Uso de CPU primera prueba	0,189	40	<,001	0,898	40	0,002
Uso de CPU segunda prueba	0,116	40	0,192	0,948	40	0,66

a. corrección de significación de Lilliefors

Se observa que después de aplicar el test a la primera muestra del uso de CPU, el nivel de significancia fue menor a 0.05, en consecuencia, estos datos no se ajustan a una distribución normal.

Además, se observa que cuando se aplicó la prueba de normalidad al segundo subconjunto de datos el nivel de significancia fue mayor a 0.05, entonces este subgrupo post-test si se adecua a una distribución normal. Según la teoría, si en

muestras relacionadas uno de ellos no posee una distribución normal, es una variable cuantitativa y la escala es razón se debe aplicar la prueba de Wilcoxon.

En la tabla 15 se detallan los resultados de la prueba no paramétrica

Tabla 15: Prueba de Wilcoxon de la reducción del uso de CPU

		N	Rango promedio	Suma de rangos
Uso de CPU primera prueba - Uso de CPU segunda prueba	Rangos negativos	0 ^a	0,00	0,00
	Rangos positivos	40 ^b	20,50	820,00
	Empates	0 ^c		
	Total	40		

- a. Uso de CPU primera prueba < Uso de CPU segunda prueba
- b. Uso de CPU primera prueba > Uso de CPU segunda prueba
- c. Uso de CPU primera prueba = Uso de CPU segunda prueba

En la tabla 16 se muestra la estadística de prueba Z sobre la reducción del uso de CPU.

Tabla 16: Prueba estadística Z reducción del uso de CPU

	Uso de CPU primera prueba - Uso de CPU segunda prueba
Z	--6,166
Sig. asin. (bilateral)	<,001

- a. Prueba de rangos con signo de Wilcoxon
- b. Se basa en rangos negativos.

En la tabla 16, el valor de la zona Z fue -6.166, dicho valor se encuentra en la zona de rechazo y el valor $p = 0.001 < 0.05$, de acuerdo a esto se desestima la H_{0} y se acepta la H_{1} ; esto significa que, las medias entre la primera y segunda prueba son significativamente diferentes, por lo tanto, se aceptó que el algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el uso de CPU.

4.5 Prueba de hipótesis específica 5

H_{5_0} : El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el uso de memoria RAM.

H5₁: El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el uso de memoria RAM.

Datos descriptivos de la reducción del uso de memoria RAM

En la tabla 17 se detallan los estadísticos descriptivos de acuerdo al planteamiento de una primera y segunda prueba que corresponde a una muestra de 40.

Tabla 17: Estadístico descriptivos reducción del uso de memoria RAM

	N	Media	Desviación estándar	Mínimo	Máximo	Percentiles			
						25	50	75	90
Uso de memoria RAM primera prueba	40	1,3750	0,9232	1,18	1,55	1,3050	1,3750	1,44	1,50
Uso de memoria RAM segunda prueba	40	0,55	0,14142	0,30	0,80	0,42	0,60	0,67	0,7

Se observa que la primera prueba el uso de memoria RAM media fue 1,3750 GB y en la segunda prueba la media fue 0,55 GB esto quiere decir que el algoritmo para la estimación de la masa del ganado bovino redujo el uso de memoria RAM en 0,825 GB que fue hallada mediante la siguiente fórmula:

$$RURAM = RAM_{primera} - RAM_{segunda}$$

Reemplazando se obtiene:

$$RURAM = 0,825$$

Prueba de normalidad

Para hallar la distribución de los datos se utilizó el test de Shapiro-Wilk, en virtud que el subgrupo estudiado es menor a 50. A continuación se presenta en una tabla conjunta de las pruebas normalidad tanto para la primera y segunda prueba.

Tabla 18: Prueba de normalidad reducción uso de memoria RAM

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
Uso de memoria RAM primera prueba	0,060	40	0,200*	0,985	40	0,852
Uso de memoria RAM segunda prueba	0,163	40	0,009	0,939	40	0,031

a. corrección de significación de Lilliefors

La tabla 18 muestra que cuando se aplicó el test a la primera prueba, el nivel de significancia fue mayor a 0.05, entonces esta muestra si se ajusta a una distribución normal.

Además, se observa que luego de aplicar el test de normalidad a la segunda prueba, el nivel de significancia fue menor a 0.05, por esta razón la segunda muestra no se ajusta a una distribución normal. En muestras relacionadas si uno de ellos no posee una distribución normal, además la variable sea cuantitativa y la escala una razón se procede a aplicar la prueba de Wilcoxon.

A continuación, se realiza la prueba no paramétrica

Tabla 19: Prueba de Wilcoxon de la reducción del uso de memoria RAM

		N	Rango promedio	Suma de rangos
Uso de memoria RAM primera prueba - Uso de memoria RAM segunda prueba	Rangos negativos	0 ^a	0,00	0,00
	Rangos positivos	40 ^b	20,50	820,00
	Empates	0 ^c		
	Total	40		

a. Uso de memoria RAM primera prueba < Uso de memoria RAM segunda prueba

b. Uso de memoria RAM primera prueba > Uso de memoria RAM segunda prueba

c. Uso de memoria RAM primera prueba = Uso de memoria RAM segunda prueba

En la tabla 20, se detalla la estadística de prueba Z sobre la reducción del uso de memoria RAM.

Tabla 20: Prueba estadística Z reducción del uso de memoria RAM

	Uso de memoria RAM primera prueba - Uso de memoria RAM segunda prueba
Z	-5,513 ^b
Sig. asin. (bilateral)	<,001

- a. Prueba de rangos con signo de Wilcoxon
- b. Se basa en rangos negativos.

En la tabla 20, el valor de la zona Z fue -5.513, dicho valor se encuentra en la región de no aceptación y el valor $p = 0.001 < 0.05$, por esta razón se descarta la H_{50} y se admite la H_{51} ; esto significa que las medias entre la primera y segunda prueba son significativamente diferentes, enseguida se aceptó que el algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el uso de la memoria RAM.

4.6 Prueba de la hipótesis general

Considerando que se comprobaron las hipótesis específicas 1, 2, 3, 4 y 5; se aceptó la hipótesis general: “El algoritmo mejora la estimación de la masa del ganado bovino mediante reconocimiento de imágenes”, debido a que incrementó la precisión, redujo el tiempo de entrenamiento, redujo el tiempo de identificación, redujo el uso de CPU y redujo el uso de memoria RAM.

4.7 Resumen

Para concluir la parte de los resultados se presenta una síntesis de aceptación y de rechazo de las hipótesis formuladas en la investigación:

Tabla 21: Resumen resultados de aceptación o rechazo de las hipótesis

Ord.	Hipótesis	Resultado (Aceptada o rechazada)
HE1	El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN incrementará la precisión	Aceptada

HE2	El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el tiempo de entrenamiento	Aceptada
HE3	El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el tiempo de identificación	Aceptada
HE4	El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el uso de CPU	Aceptada
HE5	El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el uso de memoria RAM	Aceptada
HG	El algoritmo mejora la estimación de la masa del ganado bovino mediante reconocimiento de imágenes	Aceptada

V. DISCUSIÓN

En este capítulo se relaciona y se contrasta la concordancia de los resultados obtenidos en la investigación con trabajos similares, con la teoría y la literatura previa ya que se requiere tomar postura ante hechos y la aplicación del pensamiento crítico para encontrar la solución de los problemas. De acuerdo a los resultados presentados se comprueba que el algoritmo mejoró la estimación de la masa del ganado bovino mediante reconocimiento de imágenes puesto que se logró un incremento de la precisión, una reducción del tiempo de entrenamiento, reducción del tiempo de identificación, reducción del uso de memoria RAM y reducción del uso de CPU. A continuación, se muestra detalladamente las relaciones existentes entre los hechos observados:

Se encontró que el algoritmo para la estimación de la masa de ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN tiene una media de 97,60% de precisión y se incrementó este indicador en un 6.10% resultado de la diferencia de medias del pre-test y post-test; siendo la muestra 40 pares de imágenes. De acuerdo a este resultado, se observó que fueron ligeramente mejores de lo que se logró en la investigación de Gómez y Castrillón (2019) que implementaron una aplicación de identificación automática de ganado bovino a partir de imágenes aéreas capturadas con drones en el que lograron una precisión del 82% (p. 32), este estudio se efectuó con una muestra de 13 000 fotografías. Pero también el resultado encontrado es ligeramente inferior a lo hallado por Khojastehkey et al (2018) que estimaron el peso de camellos Kalkohoohi mediante imágenes con un precisión del 99%, en esta investigación trabajaron con una muestra conformada por 124 camellos.

Respecto del indicador tiempo de entrenamiento se determinó que el algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN redujo el tiempo de entrenamiento; porque en el pre-test se obtiene un tiempo de entrenamiento media de 18,4392 minutos y en el post-test una media de 5,6475 minutos, esto quiere decir que el algoritmo para la estimación de la masa del ganado bovino redujo el tiempo de entrenamiento en 12,7917 minutos. En comparación con otras investigaciones similares, existe un ligera diferencia con los resultados encontrados en el trabajo de He, Ghioxari, Dollár y Girshick (2018) que implementaron una aplicación de detección y segmentación de características

de una imagen necesitaron aproximadamente 20 horas para entrenar Mask-RCNN en una sola instancia P3dn.24xlarge (8 GPU NVIDIA V100) en la plataforma de Amazon cabe recalcar que trabajaron con una base de datos enorme denominada COCO 2016. En este mismo sentido investigadores de Google (2021) mediante el entrenamiento del algoritmo Mask-RCNN para la convergencia con alrededor de 22,500 pasos demoraron aproximadamente 6 horas en una instancia TPU v3-8 también en este proyecto emplearon la base de datos publico COCO 2016.

En lo concerniente al indicador tiempo de identificación se comprobó que el algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN redujo el tiempo de identificación ya que en el pre-test se obtiene un tiempo de identificación media de 5,3997 minutos y en el post-test la media fue 2,4649 minutos esto quiere decir que el algoritmo para la estimación de la masa del ganado bovino redujo el tiempo de identificación en 2,9348 minutos. En comparación, se muestra una diferencia y desventaja con el trabajo de Song et al (2017) que en la predicción automatizada del peso corporal de vacas lecheras mediante visión tridimensional se logró la identificación en un tiempo de 0,001 s. En el mismo sentido en otra investigación de implementación de una aplicación utilizando el modelo Mask R-CNN para el reconocimiento de mala hierba en campos de cultivo mediante imágenes el tiempo de identificación fue 0,1ms (Bonnet et al., 2018).

De manera similar, se confirmó que el indicador reducción del uso de CPU mejoró significativamente luego de la implementación del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN, debido a que se demostró que en la primera prueba el uso de CPU alcanzó la media de 5,87 % de procesamiento total de la información y en la segunda prueba una media de 4,90% del procesamiento total de la información, esto quiere decir que el algoritmo para la estimación de la masa del ganado bovino redujo el uso de CPU en 0,9625%. En comparación con otro trabajo de investigación, hay una ligera diferencia con los resultados presentados en el trabajo desempeño de algoritmos de inteligencia artificial basados en CNN de (Menes et al, 2015, p. 108) que logró una reducción de 8%.

Por último, se confirmó que existe una reducción del uso de memoria RAM luego de la utilización de la aplicación de estimación de la masa mediante imágenes debido a que en la primera prueba el uso de memoria RAM media fue 1,3750 GB y en la segunda prueba la media fue 0,55 GB esto quiere decir que el algoritmo para la estimación de la masa del ganado bovino redujo el uso de memoria RAM en 0,825 GB. En comparación con otros resultados hay una ligera diferencia con la investigación de (González, 2020, p. 108) que evaluaron algoritmos de reconocimiento de objetos con inteligencia artificial del tipo convolucional para la identificación de patologías en las hojas de plantas de cultivo, en donde la reducción del uso de memoria RAM fue 2 GB.

VI. CONCLUSIONES

Las conclusiones de la investigación fueron las siguientes:

1. Acorde con los resultados encontrados en la investigación se infiere que el algoritmo para la estimación de la masa del ganado bovino mediante imágenes tuvo un efecto positivo en el incremento de la precisión. Dado que se mejoró en un 6.10% la precisión luego del uso de la aplicación.
2. El tiempo de entrenamiento del algoritmo para la estimación de la masa de ganado bovino mediante imágenes se redujo en 12.7917 minutos luego del uso de la aplicación, con esto se demuestra un efecto positivo en el tiempo de entrenamiento.
3. Los resultados de la investigación determinaron que la aplicación para la estimación de la masa del ganado bovino mediante imágenes basados en el algoritmo CNN y Mask-RCNN logró la reducción del tiempo de identificación hasta en 2.9348 minutos; lo que muestra un efecto positivo en el tiempo de identificación luego del uso de la aplicación.
4. Así mismo el algoritmo para la estimación de la masa del ganado bovino redujo el uso de CPU en 0.9625% del porcentaje total de procesamiento. Esto demuestra que la aplicación tuvo un efecto positivo en el uso de CPU.
5. Además, el algoritmo para la estimación de la masa del ganado bovino mediante imágenes redujo el uso de memoria RAM hasta en un valor de 0,825 GB, lo que demuestra que la aplicación tuvo un efecto positivo sobre el uso de memoria RAM.
6. Por último, sintetizando la información presentada se demuestra que el algoritmo para la estimación de la masa del ganado bovino mediante imágenes incrementó la precisión, redujo el tiempo de entrenamiento, redujo el tiempo de identificación, redujo el uso de memoria RAM y redujo el uso de CPU.

VII. RECOMENDACIONES

Las sugerencias para venideras investigaciones son las siguientes:

1. Se sugiere que para mejorar el rendimiento de la aplicación se puede incorporar otros algoritmos base de similar funcionalidad o características como Fast R-CNN, faster R-CNN, YOLO, CenterNet HourGlass, CenterNet Resnet50 V2; midiendo los mismos indicadores: incremento de la precisión, reducción del tiempo de entrenamiento, reducción del tiempo de identificación, reducción del uso de CPU y reducción del uso de memoria RAM. Con la finalidad de tener una aplicación que realice los procesos de estimación de la masa del ganado de manera más eficiente y eficaz.
2. Desarrollar la investigación científica considerando una población y muestra de mayor tamaño a la utilizada en el estudio, además se puede utilizar la investigación experimental puro que tiene como requisito la validez interna y el control del experimento.
3. Es importante tener una referencia cerca del animal cuando se realice la captura de las imágenes especialmente para encuadrar el animal en una especie de caja o marco que facilite la obtención el largo y ancho del ganado de manera automática.
4. Ampliar la cantidad de estudios previos utilizados para poder especificar o agregar más dimensiones e indicadores de estudio, ya que se pueden evaluar la velocidad, la exactitud, reducción del espacio en disco y el consumo de otros recursos que sea conveniente.
5. Evaluar los resultados del efecto del uso del algoritmo para la estimación de la masa del ganado bovino mediante imágenes en distintos sistemas operativos: Microsoft Windows, Android, etc. Para comprobar si hay una influencia del sistema operativo sobre la aplicación.
6. Aplicar este tipo de estudios en otras granjas ganaderas y con otras especies. Puesto que ayudaría a mejorar la productividad ganadera.

REFERENCIAS

ALEGRE, E., PAJARES, G. y DE LA ESCALERA, A. Conceptos y métodos en visión por computador. Grupo de visión del Comité Español de Automática CEA, 2016.

AMEIJEIRAS, D., GONZÁLES, H. E. y HERNÁNDEZ, Y. Algorithms for detection and tracking objects with deep networks for intelligent video surveillance: A review. Revista Cubana de Ciencias Informáticas, 2020, Vol. 14, N°.3, p. 165-195

ARIAS, José L., y COVINOS, Mitsuo. Diseño y Metodología de investigación. Enfoques Consulting E.I.R.L., 2021, (1.a ed., Vol. 1). <http://hdl.handle.net/20.500.12390/2260>

BABERA, F. D. La ganadería bovina en los chacos argentinos. Argentina: Universidad Nacional Austral, 2020, Vol.3, Num.8, p. 1-150.

BAENA, G. Metodología de investigación, serie integral por competencias. Editorial Patria, 2017, p. 1-144

BANCO INTERAMERICANO DE DESARROLLO. Informe Productividad y eficiencia en la producción ganadera pastoril en América Latina. Biblioteca Felipe Herrera del Banco Interamericano de Desarrollo, 2021, Vol. VI, pp. 1-450.

BISWAS, Avishek; CHANDRAKASAN, Anantha P. Conv-RAM: An energy-efficient SRAM with embedded convolution computation for low-power CNN-based machine learning applications. En 2018 IEEE International Solid-State Circuits Conference-(ISSCC). IEEE, 2018. p. 488-490.

BOLAÑOS, Freddy., ARANGO, Eliana I., y VALLEJO, Mónica A. Aplicación de Visión Artificial para la Calificación Automática de Pruebas Escritas. Revista Politécnica, 2018, Vol. 14(26), pp. 65–74. <https://doi.org/10.33571/rpolitec.v14n26a6>

BONNET, P., MATA, E., MORA, A., GOEAU, H. y JOLY, A. Segmentación de instancias para detección automática de malezas y cultivos en campos de cultivo. *Tecnología en Marcha*, 2020, vol. 33, no 1, p. 13-17.

CAMPOS, Guillermo y LULE, Nallely. Observation, a metody foring the estudio of reality. *Xinmai*, 2012, vol. VII, número 13, p. 45-60

CASA ROBLES, P. C. Desarrollo de aplicaciones móviles de clasificación y detección de objetos a partir de redes convolucionales ligeras. Universidad Autónoma de Madrid, 2020, p.1-72.

CASTILLO-VERGARA, Mauricio; ALVAREZ-MARIN, Alejandro y CABANA-VILLCA, Ricardo. Design Thinking: como guiar a estudiantes, emprendedores y empresarios en su aplicación. *Ing. Ind.* [online]. 2014, vol.35, n.3, pp.301-311.

CASTRO ALVAREZ, Gregorio Tomas. Aplicación de algoritmos inteligentes para reconocimiento automático de enfermedades foliares de cultivo de palta. 2019.

COREA, E.E., MONTOYA, J., MENDOZA, M.V, LOPEZ, F.M, MARTINEZ, A., ALVARADO, M.E., MORENO, C., BRODERICK, G.A. y DICKHOEFER, U. Effect of forage source and dietary rumen-undegradable protein on nutrient use and growth in dairy heifers *Animal. Feed Science and Technology*, 2020, Vol.269, N.114658. ISSN:0377-8401. <https://doi.org/10.1016/j.anifeedsci.2020.114658>.

CUEVAS, C. C. Acondicionamiento e implementación de algoritmo para la detección de ganadería vacuna. Universidad Nacional Abierta y a Distancia UNAD, 2019.

DEL CID, A., MÉNDEZ, R., & SANDOVAL, F. Investigación: Fundamentos y metodología. Pearson Educación, 2011, Vol. 232, 2.a ed.

DOMÍNGUEZ, Tomás. Visión artificial: Aplicaciones prácticas con OpenCV - Python (1.a ed.). Marcombo, 2021.

ESPINOZA, E. The Research problems. *Revista Conrado*. 2018, Vol.114, N.64 [fecha de consulta: 24 de julio del 2021].

FALCÓN, O.; PETERSSON, M.; BENAVIDES, S. y SARMENTEROS, I. Los métodos cuantitativos en la mejora de los procesos del catering. Ing. Ind. [online]. 2016, vol.37, n.1 [citado 2021-07-13], pp.70-77.

FAO. Producción animal. Fondo editorial de la Organización de las Naciones Unidas para Alimentación y la Agricultura, 2021.

FERNÁNDEZ-BEDOYA, V. H. Tipos de justificación en la investigación científica. Espíritu Emprendedor TES. 2020, Vol. 4(3) 65-76. <https://doi.org/10.33970/eetes.v4.n3.2020.207>

FLORES, P., MUÑOZ, L. y SÁNCHEZ, T. Estudio de potencia de pruebas de normalidad usando distribuciones desconocidas con distintos niveles de no normalidad. Revista PERFILES, 2019, Vol.1, Num. 21, pp. 4-11.

GALLEGO, Fernando. Aceleración en GPU del procesamiento de vóxeles en tiempo real. Universidad de Málaga, 2019.

GALICIA, L., BALDERRAMA, J. A. y NAVARRO, R. Validez de contenido por juicio de expertos: propuesta de una herramienta virtual. Apert. (Guadalaj., Jal.) [online]. 2017, vol.9, n.2 [citado 2021-08-04], pp.42-53. <https://doi.org/10.32870/ap.v9n2.993>.

GARCÍA-MONSALVES, José Carlos. Python como primer lenguaje de programación textual en la Enseñanza Secundaria. Education in the Knowledge Society [en línea]. 2017, 18(2), 147-162[fecha de Consulta 29 de Octubre de 2021].

GÓMEZ, D. I. y CASTRILLÓN, R. Reconocimiento automático de ganado bovino a partir de imágenes aéreas tomadas con drones: Un enfoque exploratorio. En Memorias de Congresos UTP. 2019. p. 32-39.

GONZÁLES, A., GUERRERO, C., OLVERA, C. A., LOPEZ, F. E., LOPEZ, D., GUTIERREZ, V., y VILLAGRANA, S. estudio y comparativa de algoritmos de detección de objetos con redes neuronales artificiales convolucionales para la

detección de enfermedades en hojas. Universidad Autónoma de Zacatecas, 2020.

GOOGLE. Primeros paso con TensorFlow Enterprise. Google Cloud, 2021. Recuperado de: <https://cloud.google.com/tensorflow-enterprise>

GONZALES, A., MARTINEZ DEL PISO, F.J, PERNIA, A.V., ALBA, F., CASTEJÓN, M., ORDIERES, J. y VERGARA, E. Técnicas y algoritmos básicos de visión artificial. Grupo de investigación EDMANS, 2006.

HAO, Z., LIN, L., POST, C. J., MIKHAILOVA, E. A., LI, M., CHEN, Y., YU, K., & LIU, J. Automated tree-crown and height detection in a young forest plantation using mask region-based convolutional neural network (Mask R-CNN). *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021, 178, 112–123. <https://doi.org/10.1016/j.isprsjprs.2021.06.003>

HE, K., GKIOXARI, G., DOLLÁR, P. AND GIRSHICK, R. Mask R-CNN. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. Academic Publisher Scientific Research. Vol. 42, 386-397. <https://doi.org/10.1109/TPAMI.2018.2844175>

HERNANDEZ-AVILA, C. E. y CARPIO, N. Introducción a los tipos de muestreo. *Revista Científica del Instituto Nacional de Salud*, 2019. <https://doi.org/10.5377/alerta.v2i1.7535>

HERNÁNDEZ, R. y MENDOZA, P. (2018). *Metodología De La Investigación: Las rutas cuantitativa, cualitativa y mixta* (1a ed.). McGraw-Hill.

HERRERA, M., CARIDAD, C., SARDUY, L., GARCIA, Y. y MARTINEZ, C. Diferentes métodos estadísticos para el análisis de variables discretas. Una aplicación en las ciencias agrícolas y técnicas. *Rev Cie Téc Agr [online]*. 2012, vol.21, n.1 [citado 2021-10-04], pp.58-62

INTERNATIONAL BUSINESS MACHINES. La visión por computadora y los campos de la aplicación. IBM, 2021. Recuperado de: <https://www.ibm.com/vision-por-computador/campos-de-aplicación>.

JANG, D.H., KIM, C., KO, YG. L. Estimation of Body Weight for Korean Cattle Using Three-Dimensional Image. *J. Biosyst. Eng.* **45**, 325–332 (2020). <https://doi.org/10.1007/s42853-020-00073-8>

JORNA, A. R., CASTAÑEDA, I. y VÉLIZ, P. L. Construcción y validación de instrumentos para directivos de salud desde la perspectiva de género. *Horizonte Sanitario* [en línea]. 2015, 14(3), 101-110. [fecha de Consulta 3 de mayo de 2021]. ISSN: 1665-3262.

JUANAZO PAUCAR, Freddy Alex. Desarrollo de una herramienta informática basada en visión artificial para el reconocimiento del banano para la exportación aplicando procesamiento de imágenes digitales y su simulación en Matlab mediante redes neuronales. 2019. Tesis de Licenciatura. Universidad de Guayaquil Facultad de Ciencias Matemáticas y Físicas Carrera de Ingeniería en Sistemas Computacionales.

KAMATH, C. (2019). Selecting Parameters for Image Processing Algorithms: A Case Study Using Retinal Image Segmentation. *Center for Applied Scientific Computing*, 1, 1–2. <https://www.osti.gov/servlets/purl/1573455>

KHOJASTEHEKEY, M.; KALANTAR, M.; ROODBARI, Z.; SADEGHIPANAH, H.; JAVAHERI, H. y AGHASHAHI, R. Feasibility of body weight estimation of Kalkoohi camels using digital image processing. *Iranian Journal of Applied Animal Science*, 2020, vol. 10, no 2, p. 333-340.

KERLINGER, F., Y LEE, H. (2001). Investigación del comportamiento. Métodos de investigación en las Ciencias Sociales (3ra edición ed.). México DF, España: McGraw-Hill.

KOVALYK, OLEKSANDR. Implementación de técnicas de segmentación de instancias basadas en aprendizaje máquina. Escuela Técnica Superior de Ingeniería de Telecomunicaciones, 2020.

KULKARNI, Kuldeep, et al. Reconnect: Non-iterative reconstruction of images from compressively sensed measurements. En Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016. p. 449-458.

LATORRE, C.; VAZQUEZ, S.; RODRIGUEZ, A. y LIESA, M. Design Thinking: creatividad y pensamiento crítico en la universidad. *REDIE* [online]. 2020, vol.22 [citado 2021-08-04]. <https://doi.org/10.24320/redie.2020.22.e28.2917>.

LI, L. J., TU, K. L., YANG, L. M., WANG, J. H., y SUN, Q. Selection for high quality pepper seeds by machine vision and classifiers. *Journal of Integrative Agriculture*, 2018, Vol. 17(9), 1999–2006. [https://doi.org/10.1016/s2095-3119\(18\)62031-3](https://doi.org/10.1016/s2095-3119(18)62031-3)

LIU, X., HU, C., & LI, P. Automatic segmentation of overlapped poplar seedling leaves combining Mask R-CNN and DBSCAN. *Computers and Electronics in Agriculture*, 2020, 178, 105753. <https://doi.org/10.1016/j.compag.2020.105753>

LOPEZ, PEDRO LUIS. POBLACIÓN MUESTRA Y MUESTREO. Punto Cero [online]. 2004, vol.09, n.08 [citado 2021-07-13], pp. 69-74. ISSN 1815-0276.

LUGO NOBOA, David Jonathan. Diseño de un sistema de visión artificial mediante una plataforma usando un dron para identificar la plaga lanchara (*Phytophthora Infestans*) en campos agrícolas de tomate riñón en romerillo bajo. 2021. Tesis de Licenciatura.

MANTEROLA, C., GRANDE, L., OTZEN, T., GARCIA, N., SALAZAR, P., y QUIROZ, G. Confiabilidad, precisión o reproducibilidad de las mediciones. Metodos de valoración, utilidad y aplicaciones en la práctica clínica. *Revista Chilena Infeccional*, 2018, Vol. 35, N° 6, pp. 680-688.

MENES, I., ARCOS, G., MORENO, P., & GALLEGOS, K. (2015). Desempeño de algoritmos de minería en indicadores académicos: Árbol de decisión y Regresión logística. *Revista Cubana de Ciencias Informáticas*, 9(4), 104–116. <http://rcci.uci.cu>

MERA, Leonel y OCHOA, John F. Redes neuronales convolucionales para la clasificación de componentes independientes de rs-fMRI. *Revista Tecnológicas*, 2021, Vol. 24(50), e1626. <https://doi.org/10.22430/22565337.1626>

MINISTERIO DE AGRICULTURA Y RIEGO DIRECCIÓN GENERAL DE POLÍTICAS AGRARIAS. Diagnóstico de crianzas Priorizadas para el Plan Ganadero 2017–2021. Dirección de Estudios Económicos e Información Agraria, (2017, enero), p. 1-60.

MOTA, C.; JUÁREZ, C.; OLGUÍN, J. C. Clasificación De Manzanas Utilizando visión Artificial Y Redes Neuronales Artificiales. *Ingeniería y Región* **2018**, 20, 52-57.

MUHAMMAD, A., ABBAS, F., BAJWA, M.A., BALOCH, M.H., NIZAMANI, A.H., WAHEED, A., AWAN, M.A., SHAH, S.S., AHMAD, Z., y JAN, S. Comparison of artificial neural network and decision tree algorithms used for predicting live weight at post weaning period from some biometrical characteristics in Harnai sheep. *Pakistan Journal of Zoology*, 2015, 47, 1579-1585.

NARANJO, Juan Fernando. Sobre algunos mitos y realidades de la ganadería bovina. *Ciencia & Tecnología Agropecuaria*, 2020, Vol. 21(3), p. 1–13. https://doi.org/10.21930/rcta.vol21_num3_art:1524

NIN-PRATT, Alejandro; FREIRÍA, Heber y MUÑOZ, Gonzalo. Productividad y eficiencia en la producción ganadera pastoril en América Latina: los casos de Uruguay y Paraguay. Biblioteca Felipe Herrera del Banco Interamericano de Desarrollo, 2019.

OIE - ORGANIZACIÓN MUNDIAL DE SANIDAD ANIMAL. Bienestar del ganado. Publicaciones OIE, (2021, 11 abril). Recuperado de: <https://www.oie.int/es/que-hacemos/sanidad-y-bienestar-animal/bienestar-animal-1.pdf/>

ORLANDONI, Giampaolo. Escalas de medición en Estadística. Telos [en línea]. 2010, 12(2), 243-247 [fecha de Consulta 29 de Octubre de 2021]. ISSN: 1317-0570.

ORTIZ, M. M. (13 de 04 de 2021). Procesamiento digital de imágenes. Puebla: Universidad Autónoma de Puebla.

OTZEN, T. y MANTEROLA, C. Técnicas de Muestreo sobre una Población a Estudio. Int. J. Morphol. [online]. 2017, vol.35, n.1 [citado 2021-10-03], pp.227-232. <http://dx.doi.org/10.4067/S0717-95022017000100037>.

PALOMINO, N. L., y CONCHA, U. R. (14 de 05 de 2021). Técnicas de Segmentación en Procesamiento Digital de Imágenes. Lima: Universidad Nacional Mayor de San Marcos. Obtenido de Biblioteca Central 'Pedro Zulen'.

PEDROSA, Ignacio; JUARROS-BASTERRETXEA, Joel; ROBLES-FERNÁNDEZ, Adán; BASTEIRO, Julia y GARCÍA-CUETO, Eduardo. Pruebas de bondad de ajuste en distribuciones simétricas, ¿qué estadístico utilizar? Universitas Psychologica [en línea]. 2015, 14(1), pp. 15-24. ISSN: 1657-9267.

PÉREZ, G., OCAMPO, F. y SÁNCHEZ, K. R. Aplicación de la metodología de la investigación para identificar las emociones. RIDE Revista Iberoamericana para la Investigación y el Desarrollo Educativo [en línea]. 2015, 6(11), [fecha de Consulta 3 de Agosto de 2021].

PÉREZ, Yasiel; GALLEGOS, Juan J.; ZAPATA, Sandra M. y CCAMA, Doris M. Design Thinking in software testing planning. Revista Innovación y Software, 2020, Vol.1, Núm. 2, pp. 40-51. ISSN: 2708-0935

REIDL-MARTINEZ, Lucy María. Confiabilidad en la medición. Investigación educ. médica [online]. 2013, vol.2, n.6 [citado 2021-10-04], pp.107-111.

ROMERO-SALDAÑA, M. Pruebas de bondad de ajuste a una distribución normal. Revista de Enfermería del Trabajo, 2016, Vol.6, N° 3, pp. 105-114

SALAS, Edwin. Pre-experimental designs in psychology and education: a conceptual review. Universidad San Martín de Porres, 2013, pp. 133-141. ISSN: 2223-7666.

SALINAS, A. M. Tips Bioestadísticos: Métodos de muestreo. Revista Ciencia UANL, 2004, Vol. VII, N° 1, pp. 121-123

SALINAS, P. y CARDENAS, M. Métodos de investigación social. Ediciones Intiyan-CIESPAL, 2009, 1ra. Ed., p. 1-55

SANTIAGO, A.D., VELAZQUEZ, L., MORENO, J.M y SALAZAR, V. Innovación e integración productiva en un sistema bovino con doble propósito del noroeste de México. *Región y sociedad* [online]. 2020, vol.32 [citado 2021-08-01], e1372. <https://doi.org/10.22198/rys2020/32/1372>.

SANTILLÁN, E. G. (11 de 05 de 2021). "Detección y clasificación de objetos dentro de un salón de clases empleando técnicas de procesamiento digital de imágenes. Azcapotzalco: Universidad Autónoma Metropolitana.

SANTILLÁN, I. D. (2008). Visión Artificial y Procesamiento Digital de Imágenes usando Matlab. Ibarra: Pontificia Universidad Católica del Ecuador sede Ibarra.

SENASA. (2021). SANIDAD ANIMAL PARA LA ASISTENCIA TÉCNICA EN LA PREVENCIÓN Y CONTROL DE ENFERMEDADES EN GANADERIA BOVINA (N° 1). (2021, abril). Dirección técnica de sanidad animal de SENASA. <https://senasa.gob.pe>

SONG, X., BOKKERS, E., VAN DER TOL, P., GROOT KOERKAMP, P., & VAN MOURIK, S. Automated body weight prediction of dairy cows using 3-dimensional vision. *Journal of Dairy Science*, 2018, Vol.101(5), 4448–4459. <https://doi.org/10.3168/jds.2017-13094>

SUÁREZ, P., & VILLAVICENCIO, M. (2017). Detección de Contornos utilizando el Algoritmo Canny en Imágenes Cross-Espectrales Fusionadas. *Enfoque UTE*, 8(1), 16–30. <https://doi.org/10.29019/enfoqueute.v8n1.127>

URRUTIA, M., BARRIOS, S., GUTIERREZ, M. y MAYORGA, M. Métodos óptimos para determinar validez de contenido. *Educ Med Super* [online]. 2014, vol.28, n.3 [citado 2021-12-03], pp.547-558.

VALLEJO, Henry; PAUCAR, Jorge y MARTINEZ, Oswaldo. Visión artificial mediante el coeficiente de correlación para exámenes de retinoscopía. *Maskay*

[online]. 2018, vol.8, n.2 [citado 2021-07-13], pp.75-80.
<https://doi.org/10.24133/maskay.v8i2.1059>.

VANACLOIG, V. A. (10 de 04 de 2021). El histograma de una imagen digital. Valencia: Universidad Politécnica de Valencia

VARGAS, Zoila Rosa. La Investigación aplicada: Una forma de conocer las realidades con evidencia científica. *Revista Educación*, 2009, Vol. 33(1), pp.155.
<https://doi.org/10.15517/revedu.v33i1.538>

VENTURA-LEON, José Luis. ¿Población o muestra?: Una diferencia necesaria. *Rev. Cubana Salud Pública* [online]. 2017, vol.43, n.4 [citado 2021-07-13].

VILLASÍS, M.A., MÁRQUEZ, H., ZURITA, J. N., MIRANDA, G. y ESCAMILLA, A. El protocolo de investigación VII. Validez y confiabilidad de las mediciones. *Revista Alergia México*, 2018, Vol. 65, N° 4, pp. 414-421.

WANGCHUK, K., WANGDI, J. Y MINDU, M. Comparison and reliability of techniques to estimate live cattle body weight, *Journal of Applied Animal Research*, 2018, Vol.46:1, pp. 349-352, DOI: 10.1080/09712119.2017.1302876

XU, Ling. The parameter estimation algorithms based on the dynamical response measurement data. *Advances in Mechanical Engineering*, 2017, vol. 9, no 11, p. 1687814017730003.

ZHANG, Qinghui; CHANG, Xianing; BIAN, Shanfeng Bian. Vehicle-damage-detection segmentation algorithm based on improved mask RCNN. *IEEE Access*, 2020, vol. 8, p. 6997-7004.

ZHAO, X. Y HU, C. Research on Pedestrian Detection Technology Based on MSR and Faster R-CNN. *Journal of Computer and Communications*, 2018, Vol. 6, p. 54-63. <https://doi.org/10.4236/jcc.2018.67006>.

ANEXOS

Anexo 1: Declaratoria de autenticidad

DECLARATORIA DE AUTENTICIDAD DE LOS AUTORES

Nosotros, **Gordillo Vásquez, Giomar y Vila Huaman, Percy**, estudiantes de la **Facultad de Ingeniería y Arquitectura** y Escuela Profesional de **Ingeniería de Sistemas** de la Universidad César Vallejo **Lima Este**. Declaramos bajo juramento que todos los datos e información que acompañan al Trabajo de Investigación / Tesis titulado “Algoritmo para la estimación de la masa del ganado bovino mediante imágenes” son:

1. De nuestra autoría
2. La presente Tesis no ha sido plagiada ni total, ni parcialmente.
3. La Tesis no ha sido publicada ni presentada anteriormente.
4. Los resultados presentados en la Tesis son reales, no han sido falseados, ni duplicados, ni copiados.

Lima, 27/11/2021

Apellidos y nombres del autor

Gordillo Vásquez, Giomar

DNI: 46028683

Firma

Apellidos y nombres del autor

Vila Huaman, Percy

DNI: 70431871

Firma

Anexo 2: Declaratoria de autenticidad del asesor

DECLARATORIA DE AUTENTICIDAD DEL ASESOR

Yo, **Gladys Jacqueline Amorós Chávez**, docente de la **Facultad de Ingeniería y Arquitectura y Escuela Profesional de Ingeniería de Sistemas de la Universidad César Vallejo Lima Este**, revisora de informe de investigación / tesis denominado: **“Algoritmo para la estimación de la masa del ganado bovino mediante imágenes”** del (de los) estudiantes **Gordillo Vásquez, Giomar y Vila Huaman, Percy** confirmo que el informe cuenta con un índice de similitud de 20% constatado en el reporte de originalidad de la aplicación Turnitin, el cual ha sido efectuado sin filtros, ni exclusiones.

He examinado el mencionado reporte y expreso que cada una de las coincidencias identificadas no constituyen plagio. En tal sentido acepto la responsabilidad que corresponda ante cualquier falsedad u omisión tanto de los documentos como de la información presentada, por lo cual me someto a lo considerado en las normas académicas vigentes de la Universidad César Vallejo.

Lima, 27/11/2021

.....
Amorós Chavez Gladys Jacqueline

DNI: 41481800

Anexo 3: Operacionalización de la variable

Tabla 22: Operacionalización de la variable

Variable	Definición conceptual	Definición operacional	Dimensiones	Indicadores	Instrumentos	Escala de medición
Efecto del uso de un algoritmo para estimar la masa del ganado bovino mediante imágenes	Un algoritmo que permita la estimación de la masa del ganado bovino puede ayudar a los ganaderos a obtener información sobre los cambios de una vaca a lo largo del tiempo, identificar anomalías en su estado de salud y tomar las medidas necesarias. (Song et al, 2018).	Medir el efecto del algoritmo para la estimación de la masa del ganado bovino incrementa la detección de anomalías, identificación de características y detección de similitudes corporales. (Song et al, 2018).	Precisión. (Aguilar y Campoverde, 2015, p. 6).	Incremento de la precisión (Gómez y Castrillón, 2019, p. 24)	ficha de observación (Campos y Lule 2012, p. 53)	Razón (Orlandoni, 2010, p. 246)
			Tiempo de entrenamiento. (Song et al, 2018, p. 4468)	Reducción del tiempo de entrenamiento (He, Ghioxari, Dollár y Girshick, 2018, p. 8)		
			Tiempo de identificación. (Ñauñay, Tipantuña, Raura y Gaulotuña, 2018, p. 15).	Reducción del tiempo de identificación (Casa, 2020, p. 64).		
			Uso de CPU. (Biswas y Chandrakasan, p. 110).	Reducción del uso de CPU (Hao et al., 2021, p.12)		
			Uso de memoria RAM. (Menes et al, 2015, p. 108).	Reducción del uso de memoria RAM (Liu, Hi y Li, p. 100).		

Anexo 4: Matriz de consistencia

Tabla 23: Matriz de consistencia

PROBLEMA GENERAL	OBJETIVO GENERAL	HIPÓTESIS GENERAL	VARIABLE	DIMENSIONES	INDICADORES
¿Cuál es el efecto del algoritmo en la estimación de la masa del ganado bovino mediante imágenes?	Determinar el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes.	El uso del algoritmo mejora la estimación de la masa del ganado bovino mediante reconocimiento de imágenes.			
Problemas específicos	Objetivos específicos	Hipótesis específicos			
PE1: ¿Cuál es el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN en la precisión?	OE1: Determinar el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN en la precisión.	HE1: El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN incrementará la precisión.	Efecto del uso de un algoritmo para estimar la masa del ganado bovino mediante imágenes	Precisión (Aguilar y Campoverde, 2015, p. 6).	Incremento de la precisión (Gómez y Castrillón, 2019, p. 24) $P = \left(\frac{Pschaafner}{Pbáscula} \right)$
PE2: ¿Cuál es el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN	OE2: Determinar el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN	HE2: El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el tiempo de entrenamiento.		Tiempo de entrenamiento (Song et al, 2018, p. 4468).	Reducción del tiempo de entrenamiento (He, Ghioxari, Dollár y Girshick, 2018, p. 8) $RT_{total} = T_{detector} + T_{extractor}$

en el tiempo de entrenamiento?	en el tiempo de entrenamiento.			
PE3: ¿Cuál es el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN en el tiempo de identificación?	OE3: Determinar el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN en el tiempo de identificación.	HE3: El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el tiempo de identificación.		<p>Tiempo de identificación (Ñauñay, Tipantuña, Raura y Gaulotuña, 2018, p. 15).</p> <p>Reducción del tiempo de identificación (Song et al, 2018, p. 4468).</p> $RT_{total} = T_{detector}$
PE4: ¿Cuál es el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN en el uso de CPU?	OE4: Determinar el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN en el uso de CPU.	HE4: El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el uso de CPU.	Uso de CPU (Menes et al, 2015, p. 108).	<p>Reducción del uso de CPU (Menes et al, 2015, p. 108).</p> $Uso_{CPU} = VT - VC$ <p>VC: Valor calculado VT: Valor total</p>
PE5: ¿Cuál es el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN en el uso de memoria RAM?	OE5: Determinar el efecto del algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Canny en el uso de memoria RAM.	HE5: El algoritmo para la estimación de la masa del ganado bovino mediante imágenes basados en los algoritmos CNN y Mask-RCNN reducirá el uso de memoria RAM.	Uso de memoria RAM (Menes et al, 2015, p. 108).	<p>Reducción del uso de memoria RAM (Menes et al, 2015, p. 108).</p> $RUso_{RAM} = MT - MC$

Anexo 5: Metodología de desarrollo

Se utilizó como metodología de trabajo el pensamiento de diseño que permite la resolución de cualquier tipo de problemas. Además, las soluciones se construyen teniendo como base la funcionalidad y las emociones de los clientes.

1. Las 5 etapas de la metodología design Thinking

a. Empatizar

En esta fase se registró las opiniones del ganadero (Hernán Gordillo Vásquez y otros ganaderos vecinos de la región de Cajamarca, Perú); estas opiniones se recopilaron mediante un mapa de empatía que contiene la formulación de preguntas y respuestas que serán utilizadas para el desarrollo de la investigación.

Se efectuaron la siguientes preguntas dirigidas a los interesados:

- ¿Qué es lo que observa el ganadero?
- ¿Qué piensa y siente el ganadero?
- ¿Qué escucha el ganadero?
- ¿Qué dice y hace el ganadero?
- ¿Qué le afecta al ganadero?
- ¿Qué quiere o que quiere lograr el ganadero?




Figura 1: Mapa de empatía

b. Definir

La identificación del problema se realizó mediante el diagrama de causa y efecto.




Figura 2:Diagrama de Ishikawa

c. Idear

Tabla 24: Requerimientos funcionales

Requerimientos funcionales	
RF_1	La aplicación permitirá el cálculo de la masa a partir de dos imágenes
RF_2	La aplicación permitirá cargar las imágenes laterales y frontales
RF_3	La aplicación permitirá trabajar con formatos de imágenes jpg, png
RF_4	La aplicación permitirá el cálculo automático a partir de una referencia
RF_5	La aplicación permitirá trabajar con distintas referencias de medida
RF_6	La aplicación debe ser web
RF_7	La aplicación debe ser funcionalmente rápida

d. Prototipar

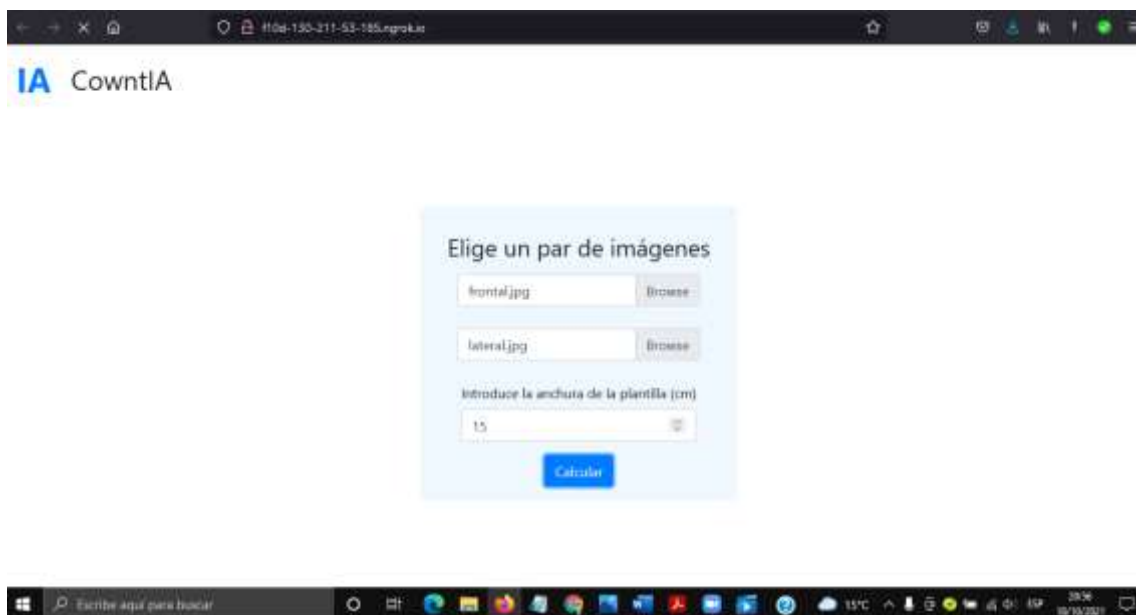


Figura 3: Prototipo interfaz

e. Evaluar




Figura 4: Validación de la aplicación

Anexo 6: Arquitectura tecnológica para el desarrollo del sistema

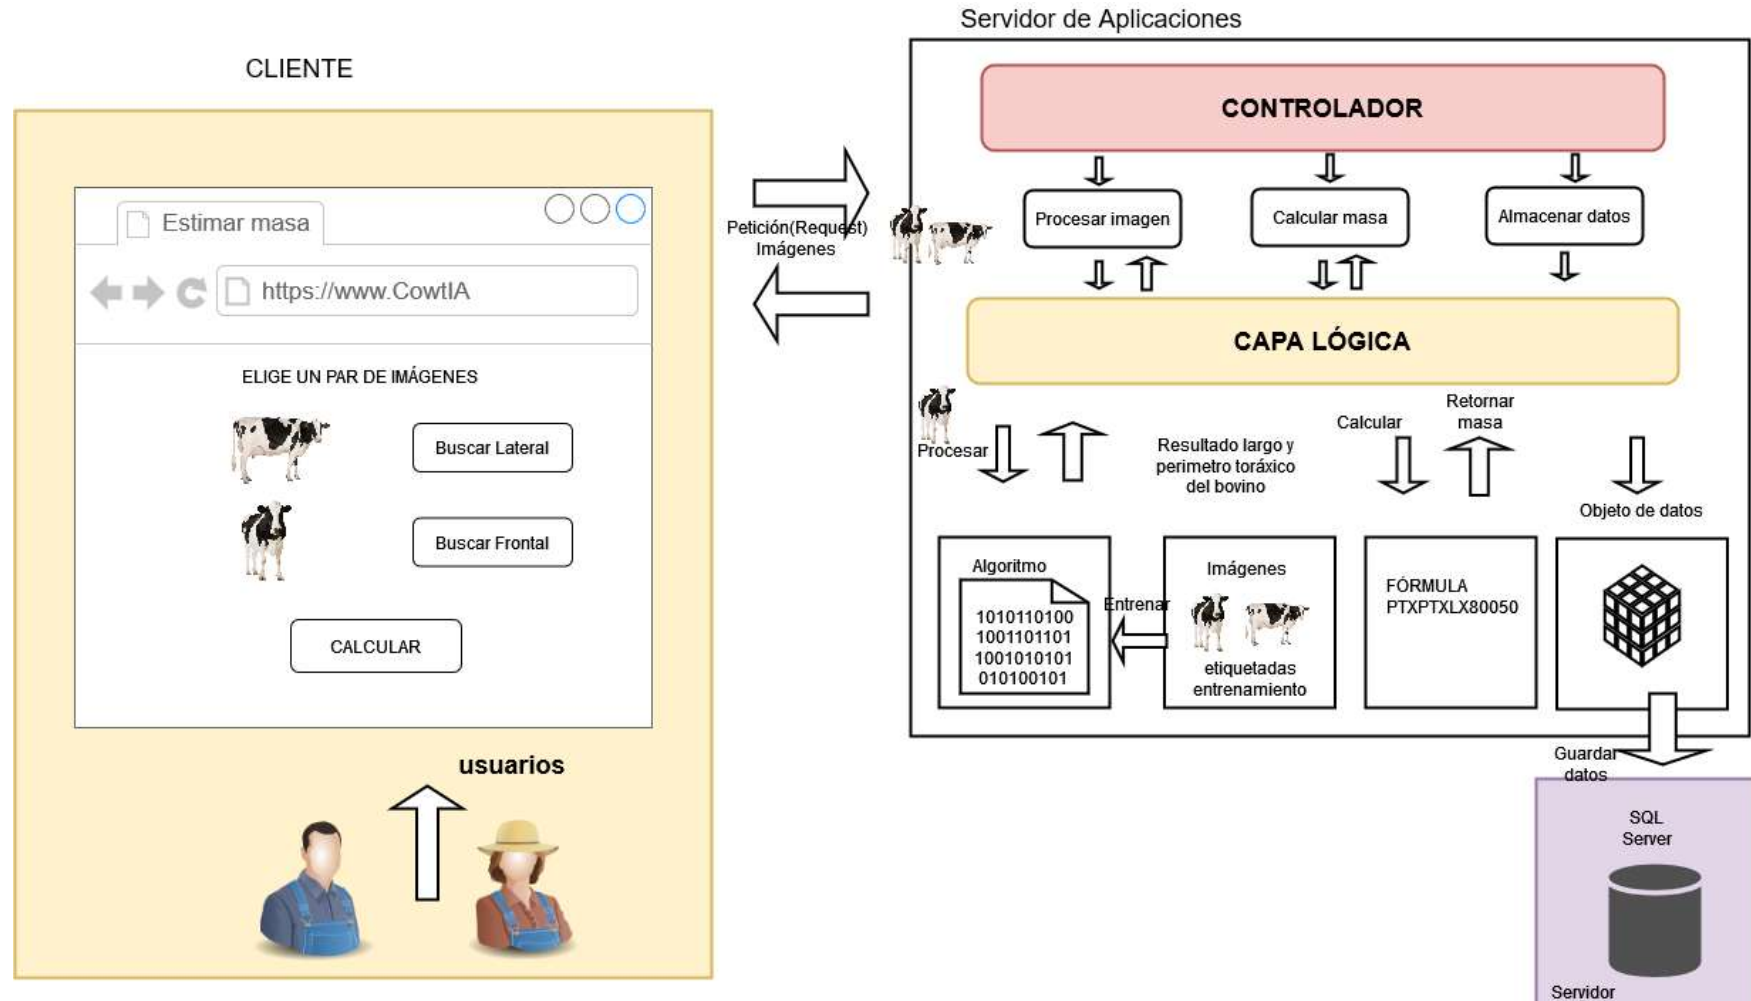
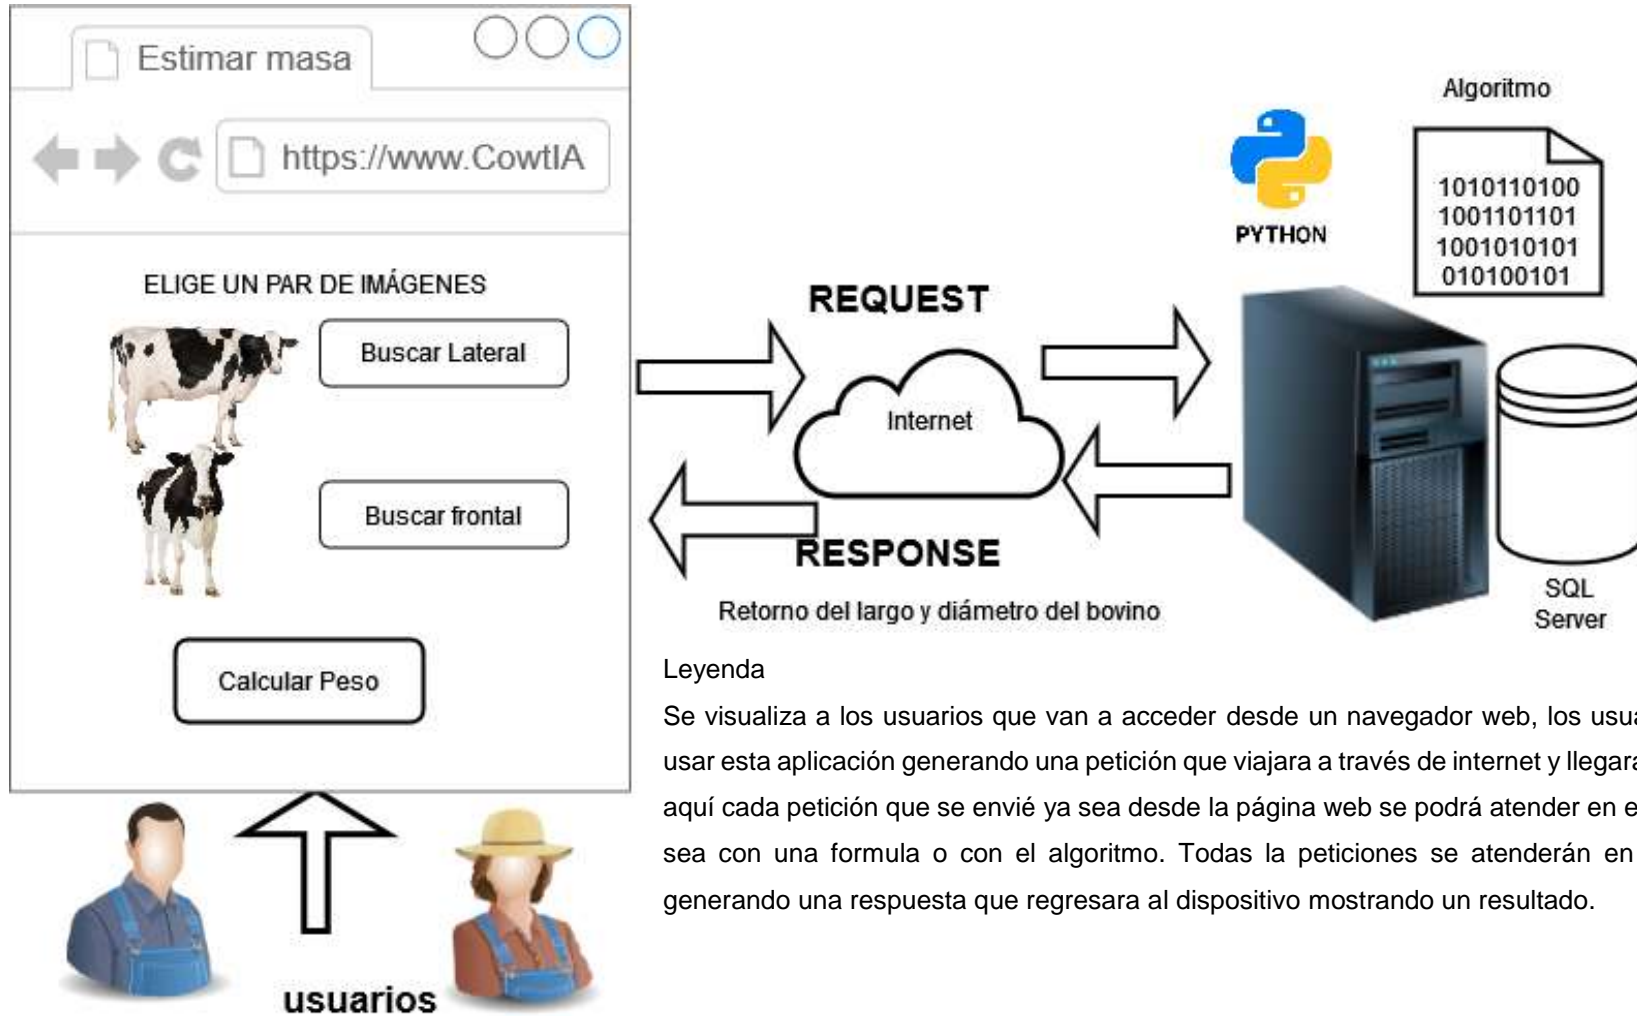


Figura 5: Arquitectura tecnológica para el desarrollo del sistema

Leyenda arquitectura del sistema

Se visualiza a los usuarios, los cuales usarán cualquier dispositivo a través de la aplicación se puede hacer peticiones al servidor, estas peticiones llegan al servidor, el cual está segmentado en varios métodos de acuerdo a lo que va a realizar cada petición, está el método de procesar imágenes y calcular masa, estos métodos se dirigirán a la capa lógica es la capa de negocios donde se realizar todos los procesos como cálculos y todo lo referente de negocios. Ejemplo si queremos calcular la masa vamos a tener que calcular una fórmula, esto se retorna al método o controlador y este se retorna a la página web como una respuesta. Si procesamos imágenes a la capa lógica se obtendría la utilización del algoritmo para predecir a qué imagen corresponde y cuáles son las medidas del bovino, esto sería la respuesta en la capa lógica la cual se retornaría al controlador y luego al dispositivo móvil las medidas del bovino, por ultimo para almacenar datos seria cuando está calculado la masa deseamos guardarla llegara al controlador luego al método almacenar datos y luego a la capa lógica de acá directamente a la capa de datos para almacenar en la base de datos.

Anexo 7: Arquitectura tecnológica para el usuario final



Leyenda

Se visualiza a los usuarios que van a acceder desde un navegador web, los usuarios podrán usar esta aplicación generando una petición que viajara a través de internet y llegará al servidor, aquí cada petición que se envié ya sea desde la página web se podrá atender en el servidor ya sea con una formula o con el algoritmo. Todas la peticiones se atenderán en el servidor, generando una respuesta que regresara al dispositivo mostrando un resultado.

Figura 6: Arquitectura tecnológica para el usuario final

Anexo 8: Pseudocódigo y flujograma del algoritmo principal

Se presenta el algoritmo original a ser desarrollado



Figura 7: Pseudocódigo del algoritmo principal

Anexo 9: Flujograma del algoritmo principal




Figura 8: Flujograma del algoritmo principal

Leyenda

Empieza con el registro del usuario para ingresar a la aplicación, tomará las imágenes, seleccionar las imágenes la cual serían dos, la parte frontal para calcular el diámetro del animal y la parte lateral para calcular el ancho y el largo, seguiría con el procesamiento de imágenes a partir de la misma aplicación devolviendo la medidas del bovino, si es que no me arroja un resultado adecuado hay un botón que me diga reprocesar y se realizará nuevamente el proceso, pero si el proceso fuera correcto le daremos al botón calcular arrojando las medidas del bovino que se mostrará, apareciendo botón que me indica que si quiero guardar o no la información.

Anexo 10: Pseudocódigo y flujograma de los algoritmos que sirvieron de base para la elaboración del algoritmo principal original (si aplica)




Figura 9: Flujograma algoritmo Mask-RCNN

Fuente: (Kovalyk, 2021, p. 11)




Figura 10: Diagrama de flujo algoritmo Mask-RCNN

- Residual net




Figura 11: Algoritmo CNN básico




Figura 12: Diagrama de flujo CNN básico

Anexo 11: Instrumentos de recolección de datos de la investigación

Tabla 25: Ficha de observación para medir la precisión

Variable	Efecto del uso de un algoritmo para estimar la masa del ganado bovino mediante imágenes	
Dimensión	Precisión. (Aguilar y Campoverde, 2015, p. 6).	
Indicador	Incremento de la precisión.	
Objetivo de la ficha de observación	Recolectar información sobre la precisión utilizando la fórmula de Schaeffer's, técnica empleada para estimar el peso vivo del ganado bovino	
Descripción de la herramienta de medición	Fórmula de Schaeffer: La ecuación utilizada para calcular el peso vivo fue: $W = \frac{LC \times PT^2}{10838}$, donde W es el peso corporal en kilogramos, LC es la longitud del animal desde el punto del hombro hasta el hueso del alfiler en centímetros, y PT es la circunferencia del pecho del animal en centímetros (Wangchuk, Wangdi & Mindu 2018, p. 24)	
Formula de la precisión	$P = \frac{W_s}{W_b} \times 100\%$	
Observación N° 1		
Lugar	Cajamarca	
Fecha	04/10/2021	
Participante	Hernán Gordillo Vásquez	
actividad	Estimación del peso del ganado empleando la fórmula de Schaeffer	
Animal medido	Toro macho con código de trazabilidad PG054 de 2 años de edad cuyo peso en bascula es 340 kilogramos fue registrado el 19/09/2021	
	Descripción	Resultado
	Para la medición se empleó una cuerda o soga delgada y cinta métrica también llamada flexómetro, el participante procedió a colocar la cuerda alrededor del perímetro torácico, zona del omoplato y pasarlo hasta la zona axilar del animal luego se comparó con la cinta métrica arrojando una medida de 170 centímetros, enseguida se midió el largo del cuerpo se colocó la cuerda desde la raíz de la cola hasta la base del cuello y arrojó 104 cm	Reemplazando en la fórmula de Schaeffer resulta: 277.32 kg. Luego empleando la fórmula de la precisión fue: 81.5% de precisión
Observación N° 2		
Lugar	Cajamarca	
Fecha	04/10/2021	
Participante	Hernán Gordillo Vásquez	
actividad	Estimación del peso del ganado empleando la fórmula de Schaeffer	
Animal medido	Toro macho con código de trazabilidad SENASA 001 de 2 años de edad cuyo peso en bascula es 340 kilogramos fue registrado el 09/09/2021	
	Descripción	Resultado
	Para la medición se empleó una cuerda o soga delgada y cinta métrica también llamada flexómetro, el participante procedió a colocar la cuerda alrededor del perímetro torácico, zona del omoplato y pasarlo hasta la zona axilar del animal luego se comparó con la cinta métrica arrojando una medida de 170 centímetros, enseguida se midió el largo del cuerpo se colocó la cuerda desde la raíz de la cola hasta la base del cuello y arrojó 104 cm	Los resultados se procesaron en Excel. Reemplazando en la fórmula de Schaeffer resulta 277.32 kg. Luego empleando la fórmula de la precisión arrojó un resultado de: 81.5% de precisión

Tabla 26: Ficha de observación para medir el tiempo de entrenamiento

Variable	Efecto del uso de un algoritmo para estimar la masa del ganado bovino mediante imágenes
Dimensión	Tiempo de entrenamiento (Song et al, 2018, p. 4468).

Indicador	Reducción del tiempo de entrenamiento	
Objetivo de la ficha de observación	Recolectar información sobre el tiempo de entrenamiento para estimar el peso vivo del ganado bovino	
Descripción de la técnica	<p>Mediante un cronómetro se registrará el tiempo que demora una persona sin experiencia realizar el proceso de la medición del ganado mediante la fórmula de Schaeffer.</p> <p>Condiciones:</p> <ul style="list-style-type: none"> • Se le explicará mediante una demostración la forma correcta de medir y los puntos donde debe situar la cuerda. • Luego de las demostración procede a medir sin la intervención del experto. • Podrá realizar 3 mediciones para hallar el tiempo promedio de entrenamiento. 	
Formula del tiempo de entrenamiento	$T_{pe} = T_d + T_{ex}$	
Observación N° 1		
Lugar	Cajamarca	
Fecha	04/10/2021	
Participante	Eler Vila Huaman	
actividad	Estimación del peso del ganado empleando la fórmula de Schaeffer	
Animal medido	Toro macho con código de trazabilidad SENASA 001 de 2 años de edad cuyo peso en báscula es 340 kilogramos fue registrado el 09/09/2021	
	Descripción	Resultado
	<p>La primera medición demoró 24 minutos.</p> <p>La segunda medición se logró en 20 minutos.</p> <p>La tercera medición señaló un tiempo de 18 minutos.</p>	$T_{pe} = \frac{24 + 20 + 18}{3}$ <p>El tiempo de entrenamiento total promedio es: 20.6 minutos</p>
Observación N° 2		
Lugar	Cajamarca	
Fecha	04/10/2021	
Participante	Javier Mendoza Diaz	
actividad	Estimación del peso del ganado empleando la fórmula de Schaeffer	
Animal medido	Toro macho con código de trazabilidad SENASA 001 de 2 años de edad cuyo peso en báscula es 340 kilogramos fue registrado el 09/09/2021	
	Descripción	Resultado
	<p>La primera medicion demoró 24 minutos.</p> <p>La segunda medición se logró en 20 minutos.</p> <p>La tercera medición indicó 18 minutos.</p>	$T_{tp} = \frac{24 + 20 + 18}{3}$ <p>El tiempo de entrenamiento total promedio es: 20.6 minutos</p>

Tabla 27: Ficha de observación para la medición del tiempo de identificación

Variable	Efecto del uso de un algoritmo para estimar la masa del ganado bovino mediante imágenes
Dimensión	Tiempo de identificación (Nauñay, Tipantuña, Raura y Gaulotuña, 2018, p. 15).
Indicador	Reducción del tiempo de identificación
Objetivo de la ficha de observación	Recolectar información sobre el tiempo de identificación para estimar el peso vivo del ganado bovino

Descripción de la técnica	Mediante un cronómetro se registrará el tiempo que demora una persona con o sin experiencia en identificar los puntos A, B y C para el proceso de medición del ganado mediante la fórmula de Schaeffer. Condiciones: <ul style="list-style-type: none"> • Se le explicará mediante una demostración la identificación de los puntos A, B y C en el cuerpo del ganado bovino. • Luego de las demostración procede a medir sin la intervención del experto. • Podrá realizar 3 mediciones para hallar el tiempo promedio de identificación
Formula del tiempo de entrenamiento	$T_{ip} = T_d$
Observación N° 1	
Lugar	Cajamarca
Fecha	04/10/2021
Participante	Eler Vila Huaman
actividad	Estimación del peso del ganado empleando la fórmula de Schaeffer
Animal medido	Toro macho con código de trazabilidad SENASA 001 de 2 años de edad cuyo peso en báscula es 340 kilogramos fue registrado el 09/09/2021
Descripción	Resultado
En la primera identificación demoró 12 minutos. La segunda identificación se logró en 10 minutos. La tercera identificación en 8 minutos.	$T_{ip} = \frac{12 + 10 + 8}{3}$ El tiempo de identificación total promedio es: 10 minutos
Observación N° 2	
Lugar	Cajamarca
Fecha	04/10/2021
Participante	Javier Mendoza Diaz
actividad	Estimación del peso del ganado empleando la fórmula de Schaeffer
Animal medido	Toro macho con código de trazabilidad SENASA 001 de 2 años de edad cuyo peso en báscula es 340 kilogramos fue registrado el 09/09/2021
Descripción	Resultado
En la primera identificación demoró 12 minutos. La segunda identificación se logró en 10 minutos. La tercera identificación en 8 minutos.	$T_{ip} = \frac{12 + 10 + 8}{3}$ El tiempo de identificación total promedio es: 10 minutos

Anexo 12: Consentimiento informado

CONSENTIMIENTO INFORMADO

Yo **Gordillo Vásquez Hernán** identificado con el número de **DNI 46028683** he sido informado sobre el procedimiento de la investigación titulada "**Aplicación móvil para la estimación de la masa del ganado bovino mediante imágenes**", desarrollado por los autores **Gordillo Vásquez, Giomar y Vila Huaman, Percy**. Recibí un duplicado de este **consentimiento informado, fechado y firmado**. Los resultados obtenidos se recopilarán de forma que no se revele mi identidad ni la de los otros participantes.

Mi consentimiento lo concedo de modo voluntario y estoy informado que me puedo retirar de la investigación en cualquier momento del mismo, por cualesquiera razones que se presenten, sin que ello implique alguna consecuencia desfavorable para mí. Por consiguiente, en pleno uso de mis facultades y capacidades entrego mi consentimiento para ser parte de este proyecto de investigación.

Lima, 01 de julio de 2021

Hernán Gordillo Vásquez



Apellidos y Nombres

Firma del Participante

DNI: 42988091

Huella Dactilar