



UNIVERSIDAD NACIONAL DE CHIMBORAZO
FACULTAD DE INGENIERÍA
CARRERA DE TELECOMUNICACIONES

Sistema de monitoreo del comportamiento de los pollos de engorde,
empleando algoritmos de reconocimiento de imágenes, para reducir la tasa de
mortalidad en la producción avícola.

Trabajo de titulación - modalidad proyecto técnico previo a la obtención del
título de ingeniero en telecomunicaciones

Autor:
Jimenez Ruiz, Willigton Washington

Tutor:
PhD. Rentarías Bustamante, Leonardo Fabián

Riobamba, Ecuador. 2026

DECLARATORIA DE AUTORÍA

Yo, Willigton Washington Jimenez Ruiz, con cédula de identidad 0605673375, autor del trabajo de investigación titulación titulado: **Sistema de monitoreo del comportamiento de los pollos de engorde, empleando algoritmos de reconocimiento de imágenes, para reducir la tasa de mortalidad en la producción avícola**, certifico que la producción, ideas, opiniones, criterios, contenidos y conclusiones expuestas son de mí exclusiva responsabilidad.

Asimismo, cedo a la Universidad Nacional de Chimborazo, en forma no exclusiva, los derechos para su uso, comunicación pública, distribución, divulgación y/o reproducción total o parcial, por medio físico o digital; en esta cesión se entiende que el cesionario no podrá obtener beneficios económicos. La posible reclamación de terceros respecto de los derechos de autor (a) de la obra referida, será de mi entera responsabilidad; librando a la Universidad Nacional de Chimborazo de posibles obligaciones.

En Riobamba, 22 de junio de 2026.



Willigton Washington Jimenez Ruiz

C.I: 0605673375

DICTAMEN FAVORABLE DEL PROFESOR TUTOR

Quien suscribe, PhD. Leonardo Fabián Rentería Bustamante catedrático adscrito a la Facultad de Ingeniería, por medio del presente documento certifico haber asesorado y revisado el desarrollo del trabajo de titulación titulado: “Sistema de monitoreo del comportamiento de los pollos de engorde, empleando algoritmos de reconocimiento de imágenes, para reducir la tasa de mortalidad en la producción avícola”, bajo la autoría de Willigton Washington Jimenez Ruiz; por lo que se autoriza ejecutar los trámites legales para su sustentación.

Es todo cuanto informar en honor a la verdad; en Riobamba, a los 22 días del mes de junio de 2026

A handwritten signature in blue ink, appearing to read 'Leonardo Rentería', is written over a horizontal line. The signature is stylized and fluid.

PhD. Rentería Bustamante, Leonardo Fabián

C.I: 1104064132

CERTIFICADO DE LOS MIEMBROS DEL TRIBUNAL

Quienes suscribimos, catedráticos designados Miembros del Tribunal de Grado para la evaluación del trabajo de titulación **SISTEMA DE MONITOREO DEL COMPORTAMIENTO DE LOS POLLOS DE ENGORDE, EMPLEANDO ALGORITMOS DE RECONOCIMIENTO DE IMÁGENES, PARA REDUCIR LA TASA DE MORTALIDAD EN LA PRODUCCIÓN AVÍCOLA** por **Willigton Washington Jimenez Ruiz**, con cédula de identidad número 0605673375, bajo la tutoría de **PhD. Leonardo Fabían Rentería Bustamante**; certificamos que recomendamos la **APROBACIÓN** de este con fines de titulación. Previamente se ha evaluado el trabajo de titulación y escuchada la sustentación por parte de su autor; no teniendo más nada que observar.

De conformidad a la normativa aplicable firmamos, en Riobamba a la fecha 30 de junio de 2026.

Ing. Giovanni Cuzco.
PRESIDENTE DEL TRIBUNAL DE GRADO



Ing. Yesenia Cevallos, PhD.
MIEMBRO DEL TRIBUNAL DE GRADO



Dr. Antonio Meneces, PhD.
MIEMBRO DEL TRIBUNAL DE GRADO





CERTIFICACIÓN

Que, **WILLIGTON JIMENEZ** con CC: **0605673375**, estudiante de la Carrera **TELECOMUNICACIONES**, Facultad de **INGENIERÍA**; ha trabajado bajo mi tutoría el trabajo de investigación titulado " **Sistema de monitoreo del comportamiento de los pollos de engorde, empleando algoritmos de reconocimiento de imágenes, para reducir la tasa de mortalidad en la producción avícola.**", cumple con el 10 %, de acuerdo al reporte del sistema Anti plagio **COMPILATION**, porcentaje aceptado de acuerdo a la reglamentación institucional, por consiguiente autorizo continuar con el proceso.

Riobamba, 29 de junio de 2026



Validar únicamente en FirmaEC.
Firmado electrónicamente por:
**LEONARDO FABIAN
RENTERIA BUSTAMANTE**

PhD. Leonardo Fabian Rentería Bustamante
TUTOR(A)

DEDICATORIA

Dedico el siguiente trabajo de investigación a mis padres, por la confianza al no rendirse y apoyarme en mis ideas, A los docentes que guiaron en mi etapa de aprendizaje y a mis amigos Darwin Naula, Jeferson Santy, Kevin Valentin con quienes hemos atravesado un sin número de dificultades y nos hemos apoyado para terminar nuestros estudios universitarios.

AGRADECIMIENTO

Quiero agradecer principalmente a Dios por acompañarme a lo largo de mi carrera, por consiguiente, a mi padre Anibal Luis Jimenez y a mi madre María Luizmila Ruiz agradezco profundamente los sacrificios que hicieron para hacer posible este logro. Además, a mis hermanos Mayvelin Jimenez y Sylver Jimenez por ser el apoyo incondicional en los buenos momentos y en los difíciles.

Agradecer a mi tutor de tesis que me oriento en el desarrollo de trabajo de investigación y por inculcarme la pasión por la programación.

De antemano agradezco al Sr. Nestor que me permitió realizar la investigación en sus galponeras. Y finalmente, agradezco a mis amigos Darwin Naula, Jefferson Santi, Kevin Medina que me apoyaron en los momentos difíciles de la carrera y por todas las alegrías que hemos compartido.

ÍNDICE GENERAL

DERECHOS DE AUTRÍA

DICTAMEN FAVORABLE DEL PROFESOR TUTOR

CERTIFICADO DE LOS MIEMBROS DEL TRIBUNAL

CERTIFICADO ANTIPLAGIO

DEDICATORIA

AGRADECIMIENTO

ÍNDICE GENERAL

ÍNDICE DE TABLAS

INDICE DE FIGURAS

RESUMEN

ABSTRACT

CAPÍTULO I.....	16
1. INTRODUCCION.....	16
1.1 PLANTEAMIENTO DEL PROBLEMA	17
1.2 JUSTIFICACIÓN.....	18
1.3 OBJETIVOS.....	19
1.3.1 General.....	19
1.3.2 Específicos.....	19
CAPÍTULO II.....	20
2. MARCO REFERENCIAL.....	20
2.1 MARCO TEÓRICO	20
2.1.1 Sector avícola	20
2.1.2 Bioseguridad y bienestar	21
2.1.3 Enfermedades que rodean al sector avícola.....	22
2.1.4 Manejo en la producción avícola.....	23
2.1.5 Internet de las cosas	23
2.1.6 Industria 4.0.....	24
2.2 MARCO CONCEPTUAL	24
2.2.1 Visión artificial procesamiento de imágenes	24
2.2.2 Etología de los pollos de engorde.....	25
2.2.3 Hipertermia.....	26
2.2.4 Hipotermia	27
2.2.5 Protocolos de comunicación.....	27
2.2.6 Sistemas de seguridad electrónica	28

2.2.7	Cámaras ip	28
2.2.8	YOLO	29
2.2.9	Métricas	36
CAPÍTULO III.		38
3.	METODOLOGÍA.....	38
3.1.1	Tipo de investigación.....	38
3.2	MÉTODO DE INVESTIGACIÓN.....	38
3.2.1	Método experimental	38
3.2.2	Investigación cuantitativa	38
3.2.3	Investigación cualitativa	39
3.3	PROCEDIMIENTO.....	39
3.3.1	Descripción de fases	39
3.4	POBLACIÓN DE ESTUDIO	40
3.5	OPERACIÓN DE VARIABLES	41
3.6	TÉCNICAS DE RECOLECCIÓN DE DATOS	41
3.6.1	Fuentes de información	41
3.6.2	Componentes del prototipo.....	42
3.7	DISEÑO E IMPLEMENTACIÓN DEL PROTOTIPO.....	48
3.7.1	Preparación y selección de tecnologías	48
3.7.2	Requisitos funcionales y entorno.....	48
3.8	DESARROLLO DEL PROTOTIPO	49
3.8.1	Diseño de la estructura	49
3.8.2	Simulación y evaluación de los modelos.....	52
3.8.3	Selección de modelos y sus características.....	56
3.8.4	Arquitectura de software	59
3.9	IMPLEMENTACIÓN Y EVALUACIÓN	61
3.9.1	Diseño final del prototipo	61
CAPÍTULO IV.....		62
4.	RESULTADOS Y DISCUSIÓN	62
4.1.1	Evaluación de la implementación de software	68
CAPÍTULO V.....		75
5.	CONCLUSIONES y RECOMENDACIONES	75
5.1	CONCLUSIONES.....	75

5.2	RECOMENDACIONES	76
	BIBLIOGRAFÍA.....	77
	ANEXOS.....	80

ÍNDICE DE TABLAS

Tabla 1: Hipertermia vs Hipotermia	27
Tabla 2: Tareas y modos compatibles del modelo YOLOvX	30
Tabla 3: Etapas de funcionamiento del modelo YOLOv8	30
Tabla 4: Métricas del modelo YOLOv11n por Ultralytics	35
Tabla 5: Flujo típico de trabajo del modelo	35
Tabla 6: Variables independientes	41
Tabla 7: Variables dependientes.....	41
Tabla 8: Características de la Raspberry Pi 5	43
Tabla 9: Especificaciones técnicas del módulo OV5647.....	43
Tabla 10: Características de la Pantalla LCD TFT Touch 3.5	44
Tabla 11: Características del módulo Raspberry Pi 5 PCIe a M.2 NVMe SSD HAT	45
Tabla 12: Características de la fuente de alimentación 45W-USB-C.....	46
Tabla 13: Especificaciones Técnicas de la Cámara Ezviz H6c Pro.....	47
Tabla 14: Especificaciones Técnicas de la Cámara Dahua DH-H5B	48
Tabla 15: Comparativa de Métricas.....	57
Tabla 16: Especificaciones del prototipo.....	62
Tabla 17: Prueba de normalidad a las métricas de cada modelo	63
Tabla 18: Resumen de contraste de hipótesis de la prueba de Kruskal-Wallis.....	63
Tabla 19: Estadísticos de la prueba de agrupación YOLOv8n vs YOLOv11n y comparación	67
Tabla 20: Estadísticos de la prueba de agrupación YOLOv8n vs YOLOv26n y comparación	67
Tabla 21: Estadísticos de la prueba de agrupación YOLOv11n vs YOLOv26n y comparación	67
Tabla 22: Comparativa al cruzar los tres modelos analizados.....	68
Tabla 23: Especificaciones del modelo YOLOv8n	69
Tabla 24: Resultados interpretados del documento “Protocolo de validación técnica”	71
Tabla 25: Tablas de frecuencia de las variables Cuenta y Asignación	71
Tabla 26: Tabla de frecuencia de la variable Detecta	72
Tabla 27: Prueba de Chi-Cuadrado.....	73
Tabla 28: Detección de los pollos muertos.....	74

INDIE DE ILUSTRACIONES

Ilustración 1: Producción avícola	20
Ilustración 2: Evolución del consumo de carne de pollo (Kg / persona /año)[8]	21
Ilustración 3: Comparación entre modelos YOLO	29
Ilustración 4: Estructura del modelo de detección YOLOv8.....	31
Ilustración 5: Diagrama de arquitectura simplificado de Ultralytics YOLOv26	34
Ilustración 6: Arquitectura del modelo YOLOv11n	35
Ilustración 7: Fases de trabajo de investigación	39
Ilustración 8: Diagrama del funcionamiento de prototipo	40
Ilustración 9: Piezas para ensamblar el prototipo	42
Ilustración 10: Módulo Raspberry Pi 5.....	42
Ilustración 11: Módulo cámara OV5647	43
Ilustración 12: Pantalla LCD TFT Touch Raspberry Pi4 Pi 3.5 320×480 3.5	44
Ilustración 13: Raspberry Pi 5 PCIE to M.2 NVME SSD Hat	45
Ilustración 14: UT01C Probador USB, voltímetro, amperímetro.....	45
Ilustración 15: Probador USB Multifunción UT01C.....	46
Ilustración 16: Fuente de alimentación 45W USB-C	46
Ilustración 17: Cámara Ezviz H6c Pro	47
Ilustración 18: Cámara Dahua DH-H5B.....	48
Ilustración 19: Diseños paramétricos de la estructura.	50
Ilustración 20: Diseño de la estructura base	50
Ilustración 21: Integración de Hardware de procesamiento y Refrigeración	51
Ilustración 22: Integración de periféricos pantalla, sensor OV5647	51
Ilustración 23: Prototipado y Manufactura	52
Ilustración 24: Revisión de videos y obtención de fotogramas	53
Ilustración 25: Filtrado de los fotogramas	53
Ilustración 26: Etiquetado de categorías.....	54
Ilustración 27: Datos procesados con los identificadores.....	54
Ilustración 28: División - Augmentation de los datos	55
Ilustración 29: Código para importar dataset.....	55
Ilustración 30: Google Colab - Entrenamiento	56
Ilustración 31: Imagen analizada con el modelo YOLOv26n	57
Ilustración 32: Imagen analizada con el modelo YOLOv11n.....	58
Ilustración 33: Imagen analizada con el modelo YOLOv8n	58
Ilustración 34: Comparativa de Métricas: YOLOv26n vs YOLOv8n vs YOLOv11n.....	59
Ilustración 35: Interfaz gráfica de Usuario	60
Ilustración 36: Integración del prototipo en la Galponera	61
Ilustración 37: Sistema de cámaras y red en la galponera	61
Ilustración 38: Diagrama de cajas de la métrica precisión	64
Ilustración 39: Diagrama de cajas de la métrica Recall.....	64
Ilustración 40: Diagrama de cajas de la métrica F1-Score	65
Ilustración 41: Diagrama de cajas de la métrica mAP50.....	65
Ilustración 42: Diagrama de cajas de la métrica mAP50-95	66

Ilustración 43: Prototipo en funcionamiento	68
Ilustración 44: Frecuencia de las variables Cuenta y Asignación.....	72
Ilustración 45: Frecuencia de la variable Detecta.....	72
Ilustración 46: Bitácora de mortalidad en la crianza de pollos.....	80
Ilustración 47: Firma del documento “Protocolo de validación técnica” que avala el diagnóstico visual y la capacidad de detección del modelo de 35 imágenes	80

RESUMEN

El sector avícola ecuatoriano se enfrenta a pérdidas económicas significativas en el proceso de crianza de pollos de engorde. Debido a que la observación manual es costosa y propensa al error humano. Para abordar esta problemática, la investigación busca implementar un sistema de monitoreo basado en reconocimiento de imágenes y aprendizaje autónomo para detectar patrones de comportamiento anormal en pollos de engorde y contribuir a la reducción de la tasa de mortalidad.

La investigación adopto un enfoque mixto, al contar con datos cuantitativos y cualitativos enfocados en un desarrollo experimental. Se entrenaron tres diferentes modelos YOLOv8n, YOLOv11n, YOLOv26n en las mismas condiciones, de tal manera se establecen tres categorías de clasificación: “Good”, “Warning” y “Bad”. La selección del modelo se fundamentó en un análisis estadístico no paramétrico y mediante la prueba de Kruskal-Wallis y U-Mann-Whitney con corrección de Bonferroni, se logró determinar el modelo óptimo y adecuado para la integración en el prototipo basado en la Raspberry Pi 5.

YOLOv8n fue seleccionado por su eficiencia computacional en hardware embebido, operando establemente a 5.69 FPS. La validación demostró que el sistema contabiliza correctamente el 65.7% de las aves y detecta anomalías en el 54.3%. Aunque es una herramienta funcional para la supervisión automatizada, la detección de mortalidad alcanzó apenas el 26.67%. Esta efectividad moderada representa su principal limitación, orientando futuras investigaciones a perfeccionar el entrenamiento del modelo para mejorar dicha precisión.

Palabras claves: Visión artificial, YOLOv8n, Sector avícola, Hardware embebido.

ABSTRACT

The Ecuadorian poultry sector faces significant economic losses in the broiler rearing process. This is because manual observation is costly and prone to human error. To address this problem, the research seeks to implement a monitoring system based on image recognition and machine learning to detect abnormal behavior patterns in broilers and contribute to the reduction of the mortality rate. The research adopted a mixed-methods approach, relying on quantitative and qualitative data focused on experimental development. Three different models (YOLOv8n, YOLOv11n, and YOLOv26n) were trained under the same conditions, thus establishing three classification categories: “Good”, “Warning”, and “Bad”. Model selection was based on a non-parametric statistical analysis; through the Kruskal-Wallis and Mann-Whitney U tests with Bonferroni correction, it was possible to determine the optimal and appropriate model for integration into the Raspberry Pi 5-based prototype. YOLOv8n was selected for its computational efficiency on embedded hardware, operating stably at 5.69 FPS. Validation showed the system accurately counts 65.7% of the birds and detects anomalies in 54.3% of cases. Although it is a functional tool for automated supervision, mortality detection reached only 26.67%. This moderate effectiveness represents its main limitation, directing future research toward perfecting model training to improve this accuracy.

Keywords: Computer vision, YOLOv8n, Poultry sector, Embedded hardware.

Approved by Jacqueline Armijos



CAPÍTULO I.

1. INTRODUCCION.

La cría de aves en el Ecuador es un sector económicamente significativo, involucrando a más de un millón de individuos y generando ingresos anuales que superan los 800 millones de dólares en carne de pollo y huevos. Esta cifra representa aproximadamente en 24% de la producción agropecuaria total en el Ecuador [1]. Es importante destacar que la producción de huevos y carne de pollo son alimentos importantes en una dieta saludable además de ser un producto asequible para la población ecuatoriana.

Con dichos antecedentes es importante resaltar que la avicultura se encuentra dividida en dos partes, tanto la producción de carne de pollos y la producción de huevos para el consumo humano, ambas, con características organizacionales distintas. Con respecto a la primera, en la cual se centra la presente investigación, puesto que se caracteriza por la relación de subordinación que existe entre una empresa y el propietario de granjas de engorde [2].

En la industria avícola, una de las problemáticas más representativas es la alta tasa de mortalidad de los pollos de engorde, la misma que afecta a la rentabilidad y el bienestar animal [3]. La mortalidad de los pollos se relaciona con diversos factores como enfermedades, estrés y condiciones ambientales inadecuadas, por ejemplo, el control de temperatura es uno de los factores importantes, puesto que los pollos son vulnerables a morir de hipertermia si las condiciones son demasiado cálidas y húmedas, o hipotermia si las condiciones son demasiado frías y un ambiente muy húmedo [4]. Estos factores afectan en la calidad del producto final.

Por lo antes mencionado, la presente investigación propone una alternativa que acompaña al avicultor en el proceso de crianza. Un sistema que monitorea el comportamiento de los pollos de engorde, permitiendo identificar patrones anormales en las aves. De tal manera se facilita la intervención oportuna, influyendo en la tasa de mortalidad de las aves.

La revisión del estado del arte en el campo de la producción avícola revela un espacio de investigación en evolución, donde los avances tecnológicos recientes, como el reconocimiento de imágenes, la teledetección, ofrecen nuevas perspectivas para abordar desafíos complejos relacionados con el monitoreo y control, una de las investigaciones es la robótica de enjambres, esta tecnología brinda la capacidad de monitorear y analizar entornos de la granja como humedad, temperatura y niveles de luz adecuados [5], por lo cual orientarlo al sector avícola generar un impacto significativo.

Con el fin de brindar una herramienta útil para el sector avícola se busca comprender cual es la aplicabilidad del reconocimiento de imágenes aplicado al sector avícola. Teniendo en cuenta los procesos de producción y la sostenibilidad que generar el aplicar un sistema de sensores de imagen capaz de detectar patrones de conducta anormales, permitiendo de esta

manera una intervención oportuna por parte de productores avícolas, y como consecuencia disminuyendo la tasa de mortalidad de la producción de pollos de engorde.

1.1 PLANTEAMIENTO DEL PROBLEMA

La industria avícola desempeña un papel fundamental en la seguridad alimentaria y la economía de muchos países. En el Ecuador está vinculado a la cadena de producción del maíz y alimentos balanceados, destacando como componente fundamental del sector agropecuario [5]. Esta cadena productiva es vital para la economía del país y juega un papel crucial en la lucha contra la pobreza y la desnutrición, beneficiando a miles de pequeños y grandes productores agrícolas y avícolas que participan activamente [6].

Sin embargo, uno de los problemas que enfrenta a la industria es la alta tasa de mortalidad, la misma que afecta la rentabilidad de la producción, y esto representa un riesgo para el bienestar animal. Si bien para contrarrestar esta situación los productores avícolas se ven en la necesidad de estar pendiente de la producción por periodos largos de tiempo, esta situación mejoraría con el acompañamiento de un sistema de monitoreo automatizado en las granjas avícolas.

En efecto, estos sistemas automatizados permiten regular condiciones ambientales como la temperatura, la humedad y la ventilación, optimizando así el entorno para el crecimiento saludable de las aves. De esta manera se puede controlar el ambiente de crianza y reducir pérdidas en la producción.

Por otro lado, existen ciertas enfermedades o trastornos que afectan los sistemas respiratorios y digestivos de las aves producen un impacto económico en la producción avícola. Esto se debe a que las aves se encuentran sometidas a sistemas de manejo y producción intensivos, lo cual genera estrés, modificaciones en sus comportamientos y alteraciones en la microflora natural [3]. Estas condiciones perturban la fisiología normal de las aves, comprometiendo el sistema de producción, como consecuencia incrementando la tasa de mortalidad avícola.

Así mismo, la observación manual de cada ave en una granja avícola es costosa y laboriosa [6]. Y sobre todo no existen soluciones a nivel local que permitan el monitoreo del comportamiento de las aves de manera continua y automatizada para identificar patrones anormales que indiquen problemas en el bienestar de las aves y alerten al avicultor para tomar medidas correctivas de manera oportuna.

Debido a los antecedentes mencionados la presente investigación busca recabar suficiente información en la comunidad de Penipe, específicamente en la Granja Avícola del señor Don Nestor, cuya infraestructura cuenta con dos galpones de ciento veinte metros cuadrados, con la capacidad de dos mil ejemplares en cada galpón.

Los datos históricos que maneja la granja avícola se organizan en ciclos de ocho semanas, durante este período, se lleva a cabo el proceso de crianza y cuidado, comenzando cuando los pollos tienen entre 5 y 21 días de nacidos, hasta la etapa de engorde y acabado. Esta última etapa varía según los objetivos del avicultor, los cuales están determinados por el peso y el tamaño deseado para las aves.

En lo que respecta a la tasa de mortalidad que se han manejado en cada ciclo de producción, existe constancia que el periodo de mayo a julio un registro de 152 pollos fallecidos y en el periodo de septiembre a noviembre una tasa de mortalidad de 74 pollos, de un total de 1800 ejemplares.

1.2 JUSTIFICACIÓN

La implementación de sensores de temperatura convencionales es funcional la mayoría del tiempo dado que ofrecen una medición limitada del entorno físico, pero al no enfocarse en el estado fisiológico de los pollos la visión artificial es un gran apoyo para crear un sistema más robusto. Esto se debe a que, al analizar las imágenes en tiempo real, el sistema realiza intervenciones oportunas que los sensores térmicos tradicionales no pueden considerar, teniendo en cuenta que solo reportar los síntomas ambientales, debido a que un sensor de temperatura convencional mide el aire circundante y no refleja las relaciones de estrés presente en las aves. La visión artificial actúa como un sensor biológico, capaz de capturar el comportamiento etológico de los pollos de engorde y facilitando una detección más precisa de su estado. La distinción de estos patrones de comportamiento es esencial en la granja avícola de puesto que las condiciones térmicas son muy variantes tanto al interior por la presencia de microclimas que un sensor estático no detecta, como también al exterior de las galponeras al exponerse a un clima demasiado frío.

De acuerdo con el razonamiento mencionado, la posibilidad que brinda la visión artificial para identificar las situaciones que afectan a la producción, mismas que son causadas por fenómenos como la hipertermia o la hipotermia que generan respuestas conductuales específicas. En el caso de la hipertermia se observa el jadeo y la extensión de las alas ante altas temperaturas; mientras que en la hipotermia se presenta un amontonamiento para conservar el calor. Si un sistema basado en aprendizaje autónomo es capaz detectar dichos patrones brindara una ayuda a la observación manual que resulta costosa, laboriosa y la gran mayoría de las veces propensa al error humano.

Se considera que el uso de cámaras y algoritmos de procesamiento de imágenes se ajustan con las exigencias de la Industria 4.0 y los protocolos de bioseguridad necesarios en el sector avícola ecuatoriano. Puesto que los procesos de monitoreo no invasivos son fundamentales para evitar que los cuidadores transporten infecciones al galpón, un riesgo continuo al manejar de manera tradicional la producción. Al centralizar el monitoreo en una placa de desarrollo como la Raspberry Pi5, se logra una supervisión sin perturbaciones físicas, reduciendo la tasa y mortalidad que afecta la rentabilidad de granjas locales.

1.3 OBJETIVOS

1.3.1 General

- Implementar un sistema de monitoreo basado en técnicas de reconocimiento de imágenes y aprendizaje autónomo, para detectar patrones de comportamiento anormal en pollos de engorde, y reducir la tasa de mortalidad en la producción avícola.

1.3.2 Específicos

- Estudiar el comportamiento de los pollos de engorde para comprender su relación con la tasa de mortalidad en la producción avícola.
- Estudiar diferentes algoritmos de reconocimiento de imágenes, con el fin de identificar y seleccionar el enfoque más preciso y eficiente para monitorear el comportamiento de pollos de engorde en granjas avícolas.
- Implementar un prototipo para el monitoreo del comportamiento de pollos de engorde aplicando diferentes algoritmos de reconocimiento de imágenes y evaluar la diferencia de los algoritmos aplicados.
- Evaluar la efectividad del sistema de monitoreo en un ambiente controlado mediante la comparación de observaciones manuales y los resultados que arroja el sistema de monitoreo.

CAPÍTULO II.

2. MARCO REFERENCIAL.

2.1 MARCO TEÓRICO

Principales teorías, modelos y conceptos relacionados se debe cubrir el fenómeno comportamiento animal y la tecnología visión artificial

2.1.1 Sector avícola

El sector avícola tiene una alta tasa de crecimiento, si bien el consumo a nivel mundial es significativo, a nivel nacional se considera una de las principales fuentes de ingresos al impulsar el desarrollo económico de familias vinculadas a la cadena agroalimentaria, pues la producción garantiza el abastecimiento interno de proteína animal. Se tiene en cuenta que la producción genera más de 4.000 millones de dólares al año en el Ecuador aportando el 4% del PIB nacional y constituye el 24% del PIB agropecuario [7].



Ilustración 1: Producción avícola

Uno de los principales ejes de la producción avícola es el consumo de carne de pollo, actualmente dicho consumo se ha incrementado en la última década, el consumo de pollo por persona ha alcanzado desde 25,15 kg en el 2016 a una tendencia de 31 Kg en el 2025, de tal manera esto indica un incremento significativo en la preferencia por incluir la carne de pollo en la dieta diaria de los ecuatorianos [8]. Los datos sugieren que el pollo es la proteína principal frente a otro tipo de cárnicos.




Ilustración 2: Evolución del consumo de carne de pollo (Kg / persona /año)[8]

Los desafíos que enfrenta el Ecuador al ser un país atado a la producción de maíz amarillo, siendo este el principal alimento de aves, convierte al maíz ecuatoriano en el más caro del mundo, estos valores se ven ligados a la sustentación de la producción lo que provoca incrementos considerables en sus costos [9].

2.1.2 Bioseguridad y bienestar

La bioseguridad y el bienestar animal es uno de los principales pilares en la producción de pollos de engorde destinados al consumo humano en el Ecuador, no solo por su impacto directo en la inocuidad alimentaria, sino que también por su relación con la mortalidad, la productividad y la calidad de la carne. Así mismo la producción ecuatoriana sigue con rigor las pautas de bienestar animal establecidas por la OMSA (Organización Mundial de Sanidad Animal), así como las leyes ecuatorianas pertinentes y las resoluciones de AGROCALIDAD en su calidad de autoridad veterinaria [9].

De acuerdo con la Agencia de Regulación y Control Fito y Zoosanitario que considera el artículo 13 de la constitución de la Republica Ecuador, el cual establece, “Las personas y colectivos tienen derecho al acceso seguro y permanente a alimentos sanos, suficientes y nutritivos: preferentemente producidos a nivel local y en correspondencia con sus diversas identidades y tradiciones culturales. El estado ecuatoriano promoverá la soberanía alimentaria [10]”. Estos lineamientos se refuerzan con instrumentos como: “Manuales de Buenas Prácticas Avícolas (BPA)”, los programas oficiales de bioseguridad y vigilancia epidemiológica, la Normativa de control sanitario, vacunación y movilización de aves y los Protocolos de notificación obligatoria de enfermedades (Newcastle, Influenza Aviar, Salmonela).

En lo que respecta a los estándares de bioseguridad en la producción de pollos de engorde se estructura en medidas físicas, operativas y sanitarias. Si bien la bioseguridad es el conjunto de medidas sanitarias y preventivas que si se aplican de forma permanente, estas evitan la entrada y salida de agentes infectocontagiosos que afectan la salud de las aves en las granjas avícolas [11]. Las mismas permiten evitar la entrada y la transmisión de enfermedades a la graja, además de mejorar la productividad, la rentabilidad para el avicultor y garantizar la inocuidad de los alimentos para el consumo.

Si bien las BPA garantizan el bienestar animal, solo cubren lo relacionado a sanidad y la inocuidad y a pesar de que es un estándar importante dentro de la producción, las pautas existentes no son aplicadas en su totalidad especialmente en pequeñas y medianas granjas, esto por falta de fiscalización o la falta de adopción tecnológica en la producción, lo que deja una brecha que el Sistema de Monitoreo pretende cubrir, debido a que el sistema controla procesos relacionados al bienestar de forma cuantitativa.

2.1.3 Enfermedades que rodean al sector avícola

Las enfermedades de los aparatos respiratorios y digestivos son consideradas la mayor preocupación económica en la avicultura por el sometimiento a condiciones de manejo intensivo lo cual provoca variaciones en la microflora de las aves por el estrés, por tal motivo es importante controlar dichas enfermedades.

En lo que respecta a las enfermedades respiratorias que causan gran impacto en la salud de las aves, la enfermedad de Newcastle destaca por ser de tipo viral y su transmisión es a través del aire, heces o cualquier elemento que se contamine. Se caracteriza por la dificultad respiratoria (jadeo), la secreción nasal, diarrea verdosa y en casos severos los signos nerviosos se ven afectados por temblores. Por lo general los indicadores conductuales es la disminución de la actividad, el aislamiento del grupo, la postura anormal del cuello y la posición del animal tumbado horizontalmente sobre el suelo. Se debe agregar también la bronquitis infecciosa aviar, la misma es de tipo viral, que se caracteriza por estornudos, sonidos respiratorios audibles, el retraso del crecimiento. Los indicadores conductuales, se percibe el menor acceso a los comederos, además de presenciar aves agrupadas buscando calor y la actividad irregular durante el día.

En lo que respecta a las enfermedades digestivas son indicadoras de mortalidad temprana, por ejemplo, la Coccidiosis, la misma es de tipo parasitaria con las características de diarrea con manchas de sangre, deshidratación y la pérdida de peso, lo que provoca alta mortalidad si no se controla a tiempo. Si se consideran las conductas que provoca, como el letargo, el menor desplazamiento, la permanencia cerca de los bebederos y el plumaje erizado. Así mismo la Salmonelosis, que se caracteriza por ser de tipo bacteriana y presenta síntomas como diarrea acuosa, decaimiento, lo que provoca aislamiento, menor interacción grupal, e incluso se observa la inactividad prolongada del ave.

En la clasificación de las enfermedades, las metabólicas y de manejo frecuentemente son subestimadas, por ejemplo, el estrés térmico (hipertermia / hipotermia) son de carácter ambiental y producen jadeo excesivo por los golpes de calor o por el contrario la aglomeración por las bajas temperaturas, lo que si no se percata a tiempo pueden ocasionar muerte instantánea. Los indicadores clave son la distribución espacial de las aves no es uniforme y su concentración es cerca de las paredes o las fuentes de ventilación.

Existen enfermedades locomotoras el cual genera un impacto directo en el comportamiento de las aves, la cojera o incluso la genética generan incapacidades para caminar normalmente y la reducción drástica del movimiento, de tal manera el acceso a los comederos se ve limitado.

Al conocer los indicadores conductuales de la enfermedad, existe la posibilidad de identificar patrones como la reducción de movilidad, el incremento de aves inmóviles, la postura corporal, el congestionamiento espacial anormal en la galponera, la reducción de tiempos en la alimentación. Si bien no es necesario que el sistema identifique la enfermedad específica, lo que sí es metodológicamente sólido es la detección de patrones de comportamiento, permitiendo asociar los patrones con riesgos sanitarios de tal forma exista una intervención temprana, evitando pérdidas en la producción avícola.

2.1.4 Manejo en la producción avícola

En la búsqueda de mejoras para la crianza de pollos de engorde se desarrollan procesos que buscan no ser invasivos al tratar con el animal, debido a su extrema fragilidad; podrían enfermarse si se encuentran en contacto constante con los cuidadores, quienes desconocen la cantidad de infecciones que puede llevar consigo al galpón.

Hay una gran cantidad de enfermedades aviares producidas por virus, bacterias, hongos y parásitos, de tipo infeccioso cuya prevención y medidas de control están fuertemente relacionadas con la bioseguridad que se maneje en la granja, las cuales pueden llegar a través de visitantes, asesores técnicos, comercializadores de huevos y aves, proveedores de insumos veterinarios, trabajadores, que son los principales agentes de transmisión, los vehículos que ingresan o salen de la granja, equipos contaminados que se intercambian entre los galpones e incluso el alimento o el agua puede llegar a contaminarse [12]. Además los agentes externos como insectos, roedores, pájaros o depredadores, el polvo y el aire contaminado, pueden afectar fuertemente la producción.

Para tratar los problemas sanitarios se deben cumplir las siguientes normas, mantener aves de una sola edad y finalidad productiva, respetar la distancia entre galpones y entre granjas. Además, es importante aplicar recomendaciones sanitarias, productivas y de manejo de desechos, al implementar programas de prevención y vacunación se están tomando en cuenta las buenas prácticas de producción avícola.

2.1.5 Internet de las cosas

Las investigaciones en esta área están influenciadas por diferentes aspectos como monitoreo, control, costo, innovación, equipamiento, almacenamiento de datos. Como resultado, las industrias de todo el mundo han adoptado la tecnología Internet de las Cosas (IoT), para mejorar los sectores de la avicultura, haciéndolos inteligentes, eficientes y productivos, reduciendo así las tareas manuales, optimizando el tiempo y los recursos económicos.

La pila de tecnologías en IoT incluyen sensores (para medir la humedad, temperatura, gases, entre otros), actuadores, sistemas de navegación, drones y servicios de datos basados en la nube que respaldan análisis innovadores que podrían cambiar significativamente estos sectores primordiales.

En la investigación titulada “Implementación de un sistema de monitoreo y control con tecnología IoT para determinar el comportamiento de las variables ambientales en la avicultura” busca mejorar en el Ecuador, la mayoría de las granjas avícolas no cuentan con sistemas capaces de monitorear las variaciones de temperatura, humedad, y concentración

de gases provocadas por la generación de gallinaza en ambientes cerrado, lo que genera un ambiente estresante que afecta a la salud de los pollos de engorde durante la etapa de crianza; por lo tanto, existe una pérdida evidente de capital económico y en la producción avícola.

El proceso de integración de dispositivos y sensores con tecnologías emergentes facilita la automatización avícola, permitiendo el registro y la visualización de comportamientos de las condiciones ambientales, lo que permite centralizar la información, de esta manera se logra una supervisión de tal manera se puede reducir los costos de mantenimiento y la supervisión de la salud de los animales [6].

Al recopilar los datos de las imágenes, proporciona un punto de vista diferente de las condiciones de crianza de pollos de engorde, lo que permite tomar medidas adecuadas para evitar la propagación de posibles infecciones de tal manera se logra proteger la salud de las aves, garantizando una mejor productividad y reduciendo la tasa de mortalidad en los pollos de engorde.

2.1.6 Industria 4.0

El crecimiento de la industria 4.0 avanza a velocidades variables en diferentes partes del mundo. A pesar de ello la transición hacia una industria inteligente se ve limitada por la infraestructura existente y la capacidad de adaptarnos a la tecnología instalada, lo que genera una brecha que dificulta la adopción plena de la industria 4.0, en el caso específico de Ecuador, aún no se evidencia una política pública clara o un interés significativo del sector privado para impulsar este salto hacia la nueva revolución industrial que apoyen a las pequeñas y medianas empresas [13]

2.2 MARCO CONCEPTUAL

2.2.1 Visión artificial procesamiento de imágenes

La visión artificial es un área de estudio dedicada al desarrollo de sistemas informáticos capaces de procesar, analizar y comprender imágenes o videos de manera análoga a la percepción humana [14]. El objetivo es dotar a las máquinas de la capacidad de observar e interpretar y reconocer objetos y formas visuales [14]. Como se aplica esto al desarrollo del proyecto en la producción avícola, puesto que los sistemas de visión por computadora basados en redes neuronales convolucionales han demostrado ser herramientas eficaces para evaluar las actividades de las aves [15]. Aplicada a la etología de los pollos de engorde permite estudiar de forma continua y no invasiva el comportamiento de las aves de tal manera brinda la posibilidad de analizar el bienestar y el manejo de las granjas productoras. Si bien existen estudios que se centran en monitorear la actividad y el nivel de movimiento basados en el flujo óptico y la distancia recorrida, las mismas variables se usan para estimar patrones de actividad y bienestar del lote.

Para lograr que un sistema identifique patrones tales como el comportamiento de los pollos de engorde dentro de un ambiente que contemple el proceso de visión artificial se estructuran una serie de etapas:

La captura constituye la fase inicial cuyo propósito es proporcionar varias imágenes digitales al sistema a través de componentes de adquisición externos como cámaras de video [14].

El procesamiento, en esta etapa se aplican técnicas para realzar detalles de la imagen, reducir el ruido y mejorar el contraste, adecuando la calidad visual para el análisis posterior [14].

La segmentación, es la parte dividida en regiones o grupos de píxeles que representan un interés de estudios específicos, esta separación es un paso crucial para el funcionamiento del sistema de detección [14].

La extracción de características determina los rasgos relevantes que permiten diferenciar un objeto de otro, extrayendo características únicas como la forma, el color y los patrones de textura [14].

El reconocimiento, es el proceso clasifica los objetos detectados según los descriptores obtenidos en la etapa previa, agrupando aquellos que presentan características similares dentro de una misma categoría [14].

Los métodos clásicos de visión artificial se enfocaban en resaltar elementos distintivos manuales, como los bordes y contornos. Sin embargo, el avance tecnológico ha dado lugar a la implementación de redes neuronales convolucionales y algoritmos de aprendizaje profundo que automatizan de forma altamente eficiente los procesos de extracción de características y el reconocimiento de imágenes cumpliendo con el objetivo dos de esta investigación.

2.2.2 Etología de los pollos de engorde

La etología en los pollos de engorde analiza patrones de comportamiento y resulta fundamental para evaluar su estado de bienestar y salud dentro de los sistemas de producción. El comportamiento animal actúa como un indicador directo de confort; las desviaciones de los patrones normales de actividad pueden señalar la presencia de estrés o problemas de salud, que de no ser atendidos incrementan el riesgo de mortalidad en los galpones [15].

En el contexto de la visión artificial y el monitoreo automatizado, las actividades conductuales de las aves suelen clasificarse en tres niveles de intensidad, los cuales reflejan su estado físico y requerimientos energéticos:

Actividad baja

Comprende comportamientos pasivos que no requieren un movimiento corporal significativo, tales como sentarse, echarse y dormir [16]. Si bien son actividades naturales de descanso, una inactividad prolongada o un aumento excesivo de este nivel puede ser perjudicial, incrementando la probabilidad que las aves desarrollen cojera o problemas locomotores [15], [16].

Actividad media

Indica movimientos regulares y rutinas tales como las acciones de caminar, estirarse, picotear suavemente, acicalarse, alimentarse y beber [16].

Actividad alta

Indica movimientos más enérgicos, tales como correr, saltar, aletear, presentar agresividad o asociado a los baños de polvo [16].

El comportamiento de las aves se ve influenciado por factores ambientales y biológicos, uno de los factores más críticos es el estrés calórico. Cuando los pollos se exponen a temperaturas que superan su zona de confort termoneutral, experimentan alteraciones conductuales orientadas a la termorregulación. Para disipar el calor, las aves tienden a agruparse cerca de los bebederos, jadear, separar las alas del cuerpo y permanecer sentadas [16],[17]. Adicionalmente, el estrés por calor reduce el consumo de alimento y la ingesta de líquidos, lo que fuerza a las aves a conservar energía disminuyendo drásticamente sus actividades físicas [16]. Las temperaturas por encima de los treinta grados deprimen significativamente la actividad conductual general, sirviendo como un indicador temprano de alerta [16].

Otro factor determinante en etología de pollo de engorde es la edad. A medida que el ciclo de producción avanza y el ave envejece, se observa una disminución natural en los niveles de actividad [16]. Esto se debe a un declive en la fuerza muscular y ósea frente a un aumento rápido de la masa corporal, lo que, sumado a la reducción del espacio libre en el ambiente controlado, restringe la frecuencia de actividades como el desplazamiento hacia los comederos. Debido al desarrollo genético enfocado en el crecimiento rápido de pechuga, la estructura ósea de estas aves a menudo no acompaña dicho desarrollo, lo que desencadena desórdenes en las patas y pérdidas de movilidad [17].

El monitoreo continuo de los parámetros conductuales en un ambiente controlado permite identificar transiciones anómalas entre los estados de actividad. La detección oportuna de inactividad extrema o alteraciones en los hábitos de alimentación y bebida es crucial, ya que estos cambios conductuales preceden a las caídas en el rendimiento productivo y a los picos de mortalidad [15].

2.2.3 Hipertermia

Desde la perspectiva de la producción de pollos de engorde la hipertermia debe analizarse como un fenómeno que afecta en gran medida a la producción y es un inconveniente en la rentabilidad si no se controla. Generando un estado de estrés severo en el cual el pollo no puede mantener su equilibrio térmico frente a condiciones ambientales adversas, comprometiendo su fisiología y supervivencia.

Para comprender lo dicho, se conoce que los pollos de engorde son animales homeotermos que dependen de un control neurofisiológico preciso para mantener su temperatura corporal interna en un rango óptimo de aproximadamente 40.5 grados Celsius a 41.5 grados Celsius [18]. Este equilibrio térmico es el resultado de un balance dinámico entre la termogénesis (producción de calor) y la termólisis (disipación de calor). En las aves, este proceso es particularmente desafiante debido a características anatómicas y filogenéticas específicas, por lo que la ausencia de glándulas sudoríparas funcionales y el aislamiento térmico proporcionado por el plumaje, que si bien es ventajoso en climas fríos, se convierte en una barrera crítica durante episodios de calor [19].

2.2.4 Hipotermia

La hipotermia en pollos de engorde ocurre cuando la temperatura ambiental desciende por debajo del límite crítico inferior de la zona termo-neutra, lo que obliga al ave a activar mecanismos autónomos para la conservación y producción adicional de calor corporal. A diferencia de la hipertermia, donde el desafío es eliminar el calor, en la hipotermia el ave debe maximizar su tasa metabólica para contrarrestar la pérdida de energía térmica hacia el ambiente.

Ante la exposición al frío, el sistema nervioso simpático activa la liberación de catecolaminas (adrenalina y noradrenalina), aumentando la frecuencia cardíaca y la presión sanguínea para movilizar recursos energéticos [18]. El pollo recurre a la termogénesis dependiente del temblor (shivering) y a la vasoconstricción cutánea periférica para reducir el flujo sanguíneo hacia la piel y conservar el calor en el núcleo corporal [19]. Este aumento en la actividad metabólica demanda un incremento masivo en el consumo de oxígeno; por ejemplo, una reducción de la temperatura ambiental de 20 grados centígrados a 2 grados centígrados puede duplicar el requerimiento de oxígeno en las aves [19].

El impacto más crítico de la hipotermia en la producción de pollos de engorde es su papel como principal factor desencadenante del síndrome ascítico (ascitis). La alta demanda de oxígeno inducida por el frío obliga al corazón a aumentar drásticamente el gasto cardíaco y el flujo sanguíneo pulmonar [18], [20]. Esto genera una hipertensión pulmonar primaria que sobrecarga el ventrículo derecho, provocando su hipertrofia y, eventualmente, una insuficiencia cardíaca congestiva que resulta en la acumulación de líquido en la cavidad abdominal (ascitis) [20]. Se ha documentado que el estrés por frío durante las primeras tres semanas de vida aumenta significativamente la predisposición a esta patología, elevando la mortalidad por ascitis de niveles normales cercanos al 1.90% hasta un 9.52% [20].

Indicador	Efecto de la Hipertermia	Efecto de la Hipotermia
Consumo de Alimento	Disminuye (anorexia térmica)	Aumenta (demanda energética)
Consumo de Agua	Aumenta drásticamente	Puede disminuir si el agua está muy fría
Conversión (FCR)	Deterioro (calor metabólico)	Deterioro (termogénesis)
Patología Crítica	Alcalosis y estrés oxidativo	Síndrome ascítico y fallo cardíaco

Tabla 1: Hipertermia vs Hipotermia

2.2.5 Protocolos de comunicación

Cuando se habla de transmisión de video o “streaming” en tiempo real, se debe tener en cuenta que se busca minimizar el tiempo de espera en la transferencia de archivos multimedia desde la red, esto permite ver y escuchar los archivos mientras se hace la transferencia sin que sea necesaria la descarga completa del archivo [21].

Los protocolos de transporte en tiempo real que conduce la entrega de paquetes coordinada por RTSP y RTP. La utilización del protocolo RTP no asegura que la transmisión sea en tiempo real, pero sí que aumenta la sincronización y el control sobre los contenidos en tiempo real (audio y video). Es decir, que puedes enviar el audio y el video por flujos separados y mediante este protocolo, sincronizarlos posteriormente en el destino [21]. El protocolo de transporte en tiempo real (RTCP) es el que se encarga de las tareas de comunicación e información para el correcto control de flujo de datos de RTP, los paquetes del protocolo

RTCP no transportan datos multimedia, si no que trabajan con RTP en el transporte y empaquetamiento de los datos. Se usa para transmitir los parámetros de una sesión multimedia, y su función principal es informar acerca de la calidad de servicio (QoS), esto gracias a que, durante una sesión, RTCP transmite periódicamente paquetes de control a todos los participantes de esta para controlar el estado de conexión en todo momento.

El protocolo RTSP define diferentes tipos de conexión y diferentes conjuntos de requisitos, para intentar conseguir siempre un envío de flujo de datos a través de redes IP. Es independiente de los protocolos de transporte por lo que puede funcionar sobre UDP, RDP o TCP, sin embargo, se utiliza TCP para el control del reproductor y UDP para la transmisión de datos con RTP.

Posee las propiedades de ser extensible al poder añadir nuevos parámetros a RTSP, es seguro al compartir mecanismos de seguridad de la web como la autenticación de http y cuando es posible RSTP reutiliza los conceptos de http, además presenta la capacidad de multi-servidor, es decir que el contenido de una misma presentación puede residir en diferentes servidores. También la separación de control de stream y la inicialización. Esto permite brindar contenido multimedia desde cualquier servidor dedicado, un servidor de steaming puede ser invitado a unirse a una conferencia ya existente, esto es útil para la distribución de aplicaciones educativas y particularmente su funcionalidad puede añadir contenido multimedia si el servidor avisa sobre estos nuevos contenidos.

Es un protocolo de red diseñado para controlar la transmisión de audio y video en tiempo real, permite funciones como iniciar, pausar o detener transmisiones, siendo una herramienta importante para los sistemas de videovigilancia IP, NVR y cámaras de red.

2.2.6 Sistemas de seguridad electrónica

Los sistemas de seguridad están formados por la interconexión de dispositivos, tecnologías y software diseñado para vigilancia de bienes e infraestructura [22]. Estos sistemas de seguridad se pueden implementar en diferentes entornos, como residencial, empresarial o industrial con el objetivo de reducir vulnerabilidades y garantizar la integridad del entorno. En el caso del presente proyecto se implementa un sistema de seguridad básico en una galponera de pollos la cual se monitorea las 24 horas del día. La importancia de un sistema de seguridad es que actúe de manera preventiva y reactiva [22].

2.2.7 Cámaras ip

Las cámaras de video vigilancia se utilizan para transmitir imágenes o videos en tiempo real de lo que sucede en una determinada área. Estos dispositivos trabajan con tecnología TCP/IP para la visualización mediante internet (WAN) o desde una red local (LAN), existen cámaras que se conectan a través de cable UTP o a través de wifi, lo que permite supervisar en tiempo real desde cualquier navegador web estándar o utilizando un software de gestión de video [22]. Estos sistemas son importantes debido a su capacidad de ofrecer vigilancia continua, respuestas rápidas y el control de acceso y movimientos en un espacio determinado [23].

2.2.8 YOLO

El primer YOLO fue propuesto por Redmon et al. en el 2016 como un detector de un solo paso que procesa una imagen completa con una sola red neuronal, logrando una alta velocidad aproximadamente 45 FPS mediante regresión directa de bounding boxes y clases [24]. YOLOv2 se introdujo un backbone más profundo (Darknet-19), usa un anchor boxes y un entreno simultáneamente en detección y clasificación [25]. YOLOv3 se introdujo en el 2018, este modelo adoptó Darknet-53 y detección de múltiples escalas, mejorando la sensibilidad en objetos pequeños. En el 2020, se incorpora YOLOv4 por Bochkovskiy et al. en este punto se incorporan conceptos avanzados como CSP, aumento de datos y pérdidas IoU, de esta manera alcanzando un 43,5% AP en COCO a 65 FPS [26]. Tiempo después YOLOv5 se popularizó con las versiones ligeras en Pytorch, y YOLOv7 en el 2022 siguió optimizando el rendimiento gracias a Wang et al., hasta llegar a YOLOv8 en el 2023 combinada con las mejoras previas con nuevas arquitecturas de cuello y un cabezal sin anclajes, ofreciendo detección en tiempo real con mejor precisión.




Ilustración 3: Comparación entre modelos YOLO

En la arquitectura que maneja YOLO se presenta varios modelos los cuales se clasifican según la necesidad, es decir que se delimita la situación en la que se desea emplear el modelo. Esto se permite elegir desde modelos destinados a la detección específica de superficies hasta modelos más complejos que siguen patrones de postura donde detecta puntos clave en el cuerpo.

Modelo	Nombres asignados dependiendo el tamaño	Tareas
YOLOvX	yolovXn.pt, yolovXs.pt, yolovXm.pt, yolovXl.pt, yolovXx.pt	Detección
YOLOvX-seg	yolovXn-seg.pt, yolovXs-seg.pt, yolovXm-seg.pt, yolovXl-seg.pt, yolovXx-seg.pt	Segmentación
YOLOvX-pose	yolovXn-pose.pt, yolovXs-pose.pt,	Pose

	yolovXm-pose.pt, yolovXl-pose.pt, yolovXx-pose.pt	
YOLOvX-obb	yolovXn-obb.pt, yolovXs-obb.pt, yolovXm-obb.pt, yolovXl-obb.pt, yolovXx-obb.pt	Orientación y Detección
YOLOvX-cls	yolovXn-cls.pt, yolovXs-cls.pt, yolovXm-cls.pt, yolovXl-cls.pt, yolovXx-cls.pt	Clasificación

Tabla 2: Tareas y modos compatibles del modelo YOLOvX

Hay que destacar que cada capa de complejidad como segmentación y pose exige muchísimo más esfuerzo por parte del procesador. Ahora para cumplir el objetivo de correr un modelo en la Raspberry Pi 5 que no represente un sobre esfuerzo para su unidad de procesamiento y que este logre identificar y ubicar a los pollos, se recurre al modelo estándar de detección YOLOvXn.pt, independiente de la versión que se seleccione sin sufijos, sigue siendo la mejor opción para mantener un equilibrio entre rendimiento y utilidad.

YOLOv8

Ultralytics YOLOv8 es una arquitectura de detección y clasificación de objetos desarrollada por Ultralytics basada en la familia YOLO (“You Only Look Once”). Está diseñada para tareas de visión por computadora en tiempo real [27]. Hereda la filosofía de procesamiento unificado de YOLO (identificar cuadros delimitadores y clases en una sola pasada) introducida por Redmon et al. En el 2015 [24], pero incorpora innovaciones clave: un backbone y neck de nueva generación (CSP mejorado con módulos C2f), un cabezal de detección Split completamente sin anclajes (anchor-free) y soporte integrado para tareas adicionales como precisión y estimación de pose [27]. A partir de estas mejoras YOLOv8 optimiza el equilibrio entre precisión y velocidad [28]. Su diseño escalable de nano a extra-grande lo hace adecuado tanto para servidores potentes como para dispositivos de borde con recursos limitados, complementando con optimizadores como exportación a ONNX/TensorRT para cuantización INT8 [29].



Tabla 3: Etapas de funcionamiento del modelo YOLOv8

La arquitectura general de YOLOv8 retiene la estructura de tres bloques: backbone, neck y head. El backbone emplea una variante optimizada de CSPDarknet53 con módulos C2f (Cross Stage Partial con 2 convoluciones), que mejora la extracción jerárquica de características reduciendo parámetros [28]. Tras un stem inicial de convoluciones 3x3 sucesivas, las capas C2f extraen características a diferentes escalas. El neck combina un módulo Spatial Pyramid Pooling Fast (FPPF) para fusionar contextos de distintos tamaños con una

versión mejorada de PANet que propaga características entre escalas. Según Muhammad Yaseen, este cuello potenciado permite manejar mejor objetos pequeños y variados [28]. El head de YOLOv8 es un cabezal Split ancla-free, separado en ramas independientes para objeto, clase y bounding box. A diferencia de versiones previas con anclas fijas, en YOLOv8 este head predice directamente el centro y dimensiones de cada caja delimitadora sin plantillas predefinidas [27]. Este diseño sin anclajes simplifica el modelo y mejora la eficiencia computacional [30] y YOLOv8 combina un backbone CSP/C2f moderno, un neck con SPPF+PAN mejorados y un head desacoplado (ancla-free), lo que difiere de anteriores YOLO [31].




Ilustración 4: Estructura del modelo de detección YOLOv8

Para el desarrollo de la investigación de monitoreo de pollos de engorde YOLOv8 representa una alternativa técnica viable debido a la alta velocidad de inferencia, la compatibilidad con GPU y dispositivos embebidos, la facilidad de entrenamiento personalizado junto con

la integración sencilla de Python junto con la Raspberry Pi 5, brinda la capacidad de detectar múltiples aves simultáneamente con las características como inmovilidad, aislamiento y poca actividad.

En el manejo del modelo existe la suposición que YOLOv8 por sí solo no detectará el comportamiento anormal de los pollos, por lo que se aclara que YOLOv8 detecta que aparece en la imagen y donde se ubica, pero no comprende el comportamiento complejo directamente. Por ejemplo, si analizamos el modelo puede detectar la silueta, el dónde se encuentra, cuantos existen y puede seguir movimientos entre frames. Pero no entiende automáticamente estrés, o enfermedad, no interpreta conducta social sin lógica adicional.

Para comprender lo dicho anteriormente, se debe entender el proceso de entrenamiento de YOLOv8, el mismo sigue el esquema típico de detectores basados en CNN. Se parte de un dataset anotado, por ejemplo, un conjunto de datos a gran escala diseñado para entrenar y evaluar, estos datos siguen un formato YOLO donde cada imagen tiene un archivo de texto con clase centro_x, centro_y ancho y alto, estos datos son normalizados, además Ultralytics proporciona guías para convertir varios formatos como COCO, VOC a YOLO [28]. Es común usar transfer learning, es decir cargar pesos pre-entrenados en COCO y luego afinar el propio dataset [27]. Durante el fine-tuning, se aplican sólidas técnicas de aumento de datos para mejorar el entrenamiento. La técnica de MixUp fusiona pares de imágenes, y CutMix intercambia regiones rectangulares; además de transformaciones geométricas como el volteo, el recorte, la escala y el cambio de color [32]. El loss de entrenamiento incorpora varias componentes: una pérdida focal binaria para clasificación de clases, una pérdida basada en IoU para ajustar mejor las cajas, y una pérdida de “objectness” que guía la detección de presencia de objeto [28]. En el archivo con la extensión YAML se especifica la configuración de hiperparámetros importantes para el aprendizaje inicial ($\text{lr} = 1\text{e-}3$), el tamaño de batch, momentum, peso de decaimiento, número de épocas, así como los coeficientes de cada parte de la pérdida, además, se tiene las métricas de validación como mAP sobre el conjunto de validación, pero típicamente se comienzan con valores por defecto [33].

YOLOv8 tiene limitaciones, por ejemplo, asume que los objetivos que detecta corresponden a las clases vistas en entrenamiento; no realiza detección abierta de objetos no entrenados ni entiende semánticamente la escena [24], [28]. Tampoco maneja por sí solo perspectivas extrañas ni cambios drásticos en iluminación: requiere datos balanceados, si bien YOLOv8 procesa cada imagen de forma estática, asume entornos donde las imágenes de entrada tienen resoluciones y contenidos similares a su entrenamiento. En el contexto de la investigación de vigilancia avícola, esto implicaría colocar cámaras fijas y con condiciones similares; el modelo no “comprende” comportamiento animal, solo detecta objetos predefinidos. Finalmente, aunque es muy preciso, puede cometer falsos positivos/negativos en entornos desafiantes, por lo que se recomienda validar su desempeño con métricas adecuadas (mAP, recall) y calibrar el sistema en el dominio de aplicación.

Para cuantificar el desempeño de YOLOv8 se emplean métricas estándar en visión por computadora, la más común es la Precisión Media Promedio (mAP) [28]. También se registran los indicadores de velocidad como los FPS expresados en ms por imagen y el

consumo de recursos en la CPU o GPU. En comparación con versiones anteriores, YOLOv8 mejora tanto en precisión como la velocidad, se reporta 55,2% mAP@05 para YOLOv8 frente a 50,5% mAP05 de YOLOv5, reduciendo el tiempo de inferencia de 30ms a 25ms por imagen [28].

YOLOv26

La versión YOLOv26 representa familias de detectores de objetos en tiempo real con diferencias clave. YOLOv8 emplea una arquitectura CSP mejorada con cuello FPN+PAN y una cabeza de detección ancla-libre (anchor-free) que ofrece un buen balance precisión/velocidad [27]. En contrate, YOLOv26 redefine el enfoque hacia despliegue en el borde: elimina la supresión de no máximos (NMS) mediante una cabeza one-to-one, retira la pérdida DFL de versiones previas, e introduce un optimizador MuSGD y nuevas pérdidas para mejorar la detección de objetos pequeños [34]. Ambos modelos requieren conjuntos de datos anotados (cajas delimitadoras + clases), pero YOLOv26 facilita la interferencia en hardware con recursos limitados. A continuación, se detallan estos puntos: arquitectura, canalización de detección, funciones de pérdida, entrenamiento, variantes de modelo, mejoras de YOLOv26 y consideraciones de implementación en dispositivos de borde, así como recomendaciones prácticas para su uso en un sistema de monitoreo avícola.

YOLOv26 lanzado en el 2026 fue diseñado explícitamente para entornos de baja potencia [34]. Sus mejoras presentan la detección end-to-end sin NMS que genera directamente un conjunto fijo de detecciones. También suprime la Distribución Focal Loss usada en YOLOv8 para simplificar la regresión de cajas. Si bien Ultralytics especifica que al eliminar el DFL no afecta la precisión, pero logra generar una mejora en la compatibilidad con cuantización e implantaciones ligeras [34], [35]. Además, se introduce MuSGD el mismo es un optimizador híbrido inspirado en avances de modelos de lenguaje, que combina la estabilidad de SGD con la rapidez de convergencia tipo Muon [36]. Esto permite entrenamiento más estable y rápido en datasets grandes [34], [35]. Otra implementación es el añadir mecanismos como ProgLoss (pondera dinámicamente las pérdidas) y STAL (asignación de etiquetas consiente de pequeños objetivos) para mejorar el recall de objetos pequeños sin aumentar el tamaño de modelo [36]. Al igual que YOLOv8, es multi-tarea (detecta, segmenta, estima pose) [36]. Cada variante nano a x-large existe en versiones para detección, segmentación y pose.




Ilustración 5: Diagrama de arquitectura simplificado de Ultralytics YOLOv26

Estas mejoras hacen de YOLOv26 un modelo aún más práctico para escenarios de IoT/robótica: Ultralytics reporta hasta 43% de inferencia más rápida en CPU que modelos previos [34], [35]. Independientemente, la precisión base en GPU de YOLOv26 es comparable a la de YOLOv8, por lo que la principal ganancia es operativa (latencia y facilidad de despliegue). Esto refleja que YOLOv26 se enfoca en la eficiencia de despliegue sin sacrificar las tareas clave, esto implica reubicar componentes pesados (NMS, DFL) por alternativas ligeras y agrega avances de optimización para el dispositivos de borde [37] .

A pesar de sus mejoras, ambos modelos requieren evaluación cuidadosa antes del despliegue. Los modelos más grandes requieren GPUs potentes para lograr detección en tiempo real. En dispositivos que solo cuentan con CPU pueden presentar alta latencia y generación de calor. Es por ello que YOLOv26 mejora la ejecución en CPU, la variante YOLOv8n reporta 39ms en CPU vs 80ms en relación a YOLOv8n [34], [36]. En relación con el proyecto de investigación que se busca usar una Raspberry Pi conviene modelar térmicamente el sistema y limitar FPS. Se recomienda usar modelos nano/small para bajar la carga y posiblemente alimentar el procesamiento desde múltiples cámaras.

En escenarios académicos se deben monitorear métricas de rendimiento (FPS real, consumo de CPU/GPU, temperatura) junto a la precisión de detección (mAP, tasa de error) Además, hay que tener en cuenta limitaciones inherentes como, ningún modelo aprenderá por sí solo comportamientos complejos (estrés térmico, enfermedad) sin lógica adicional. En la práctica, YOLO actúa como capa de percepción visual, posteriormente luego se necesita análisis o reglas para traducir las detecciones en alertas útiles. Se debe de tener en cuenta que tanto YOLOv8 como YOLOv26 son compatibles con TensorRT, ONNX y cuantización (FP16/INT8), pero la verificación posterior es necesaria

YOLOv11

YOLOv11 es un modelo lanzado por ultralytics en octubre de 2024 como la undécima generación de la familia YOLO, si bien las versiones anteriores tuvieron colaboraciones de la comunidad open source, YOLOv11 fue diseñado personalmente por Ultralytics, lo que

garantiza la integración nativa con su ecosistema de herramientas [38]. Ahora bien, la variante nano es la más ligera, esta variante fue diseñada específicamente para realizar despliegues en dispositivos que tienen recursos limitados o no cuentan con un módulo de aceleración de hardware (GPU).

En lo que respecta a arquitectura, YOLOv11 introduce mejoras estructurales como el C3K2 block, esta mejora reemplaza el bloque C2f de YOLOv8, de tal forma permite la extracción de características con menos parámetros, pero que cuenten mayor capacidad para transmitir volumen y distancia. Así también se agrega C2PSA block, este bloque agrega un mecanismo de atención espacial en el cuello de la red, lo que mejora la localización de objetos pequeños o solapados [38].

Parámetro	YOLOv11n
Tamaño del modelo	5.4 MB
Parámetros	2,6 M
GFLOPs	6.5
mAP50-95 (COCO)	39.5%

Tabla 4: Métricas del modelo YOLOv11n por Ultralytics




Ilustración 6: Arquitectura del modelo YOLOv11n

YOLOv11n se basa en un archivo cuya configuración topológica YAML determina la composición jerárquica de la red [39]. Teóricamente, la red neuronal se abstrae en tres subredes funcionales interconectadas, la columna principal Backbone es la responsable de la extracción interactiva de representaciones, el cuello Neck es el encargado de la fusión y agregación de rutas semánticas multiescala y el cabezal Head es el encargado de traducir los mapas de características funcionando en predicciones bajo conceptos matemáticos e inferencias geométricas [40].



Tabla 5: Flujo típico de trabajo del modelo

El preprocesamiento de las imágenes se redimensiona a un tamaño de 640x640px con letterboxing. Se aplican aumentaciones mejoradas en YOLOv11 con una serie de procesos optimizados conectados en secuencia que requieren menos épocas de entrenamiento. Esto es

útil porque el sistema es más robusto con menos datos. El paso siguiente es Backbone, al aplicar el módulo C3k2, este es un CSP con kernel 3x3. Estos mismos bloques son más compactos, los cuales reducen la redundancia y mejoran el “ratio” FLOPs-to-mAP. Un aspecto para destacar en este punto del proceso es la multi escala al retener SPPF. El tercer bloque Neck, mantiene PAN-FPN pero introduce C2PSA, un módulo de atención que refuerza las características importantes y suprime el ruido. Esto mejora significativamente la detección de objetos pequeños y escenas densas. La fusión de multiescala es más eficiente con la eliminación de redundancia en la técnica stride harmonization. En el bloque Head, mantiene la separación entre clasificación, regresión y anchor-free de YOLOv8. Sin embargo, la función de pérdida mejorada y el nuevo sistema de supervisión híbrido permiten que converja más rápido y sea más estable. Esto genera que las predicciones finales sean más limpias y exista menos duplicados mejorando la métrica “IoU”, la misma mide que tan preciso es el cuadro delimitador que el modelo predice en comparación con el cuadro delimitador real. Al final el bloque de salida retiene el postproceso NMS, introduce refinamiento de bounding boxes y se aplica un ajuste fino iterativo en las coordenadas para mejorar aún más el IoU. Esto da como resultado que el sistema genera predicciones más concentradas, con la presencia de menos falsos positivos duplicados y mayor precisión en objetos muy cercanos entre sí.

2.2.9 Métricas

Para evaluar el desempeño de los modelos de aprendizaje en las tareas de detección y clasificación de objetos, se utilizan métricas estandarizadas en la matriz de confusión y el concepto geométrico de intersección sobre la Unión (IoU).

Para comprender el análisis de las métricas es necesario comprender las clasificaciones que interactúan en el entorno de análisis, por ejemplo, los verdaderos positivos “VP” que son objetos correctamente detectados y clasificados por el modelo. También los Falsos positivos “FP” que son las detecciones erróneas donde el modelo identifica un objeto inexistente o lo clasifica de forma incorrecta, se las conoce como alarmas falsas. Y los falsos negativos “FN”, son objetos reales que se encuentran en la escena analizada que el modelo fue incapaz de detectar, es decir omite la detección del objeto.

Precisión

Es la proporción que existe entre las detecciones positivas que fueron estadísticamente correctas sobre las detecciones positivas más los falsos positivos.

$$Precision = \frac{VP}{VP + FP}$$

Esta relación permite medir la calidad junto con la fiabilidad del modelo al momento de emitir una predicción, evaluando su capacidad para evitar falsas alarmas. La manera en que se integra en el análisis del proyecto es que refleja la certeza del sistema cuando etiqueta un comportamiento o pollo. Así el modelo garantiza que las cajas delimitadoras para cada categoría corresponden verdaderamente a un pollo que se encuentra en el estado detectado. Además, esto garantiza que existe un mínimo de riesgo de confundir elementos del entorno como comederos o bebederos.

Recall

Es la proporción de objetos reales que el modelo logra identificar correctamente. Se calcula con la siguiente ecuación

$$Recall = \frac{VP}{VP + FN}$$

Esta métrica mide la capacidad del algoritmo para localizar todos los elementos u objetos presentes en el conjunto de datos, de esta manera se evalúa la precisión o la omisión de los elementos detectados.

F1-Score

Es la medida entre la precisión y el Recall. Se calcula de la siguiente manera:

$$F1 - Score = 2 \times \frac{Precisión \times Recall}{Precisión + Recall}$$

Esta métrica es un indicador global y equilibrado del rendimiento del modelo, es un indicador cuando existe un desbalance en la clasificación, el mismo es un indicador cuando se desea encontrar la mayor cantidad de aves posibles sin perder la rigurosidad de la clasificación correcta junto con la identificación individual.

mAP50

Es un promedio de la precisión del modelo que se rige a un umbral fijo de intersección sobre Union del 50% IoU =0.50, este valor se representa:

$$IoU = \frac{\text{Área de la Intersección}}{\text{Área de la Unión}}$$

Además, evalúa de manera integral la exactitud del algoritmo tanto en la clasificación como en la localización inicial de los elementos. La importancia que tienen en el proyecto es que permite representar la tasa de aciertos generales. Esto valida si el modelo es capaz de ubicar espacialmente a los pollos de manera aceptable para el ojo humano, de tal manera se permite un seguimiento de la densidad y la distribución de las aves en la zona de captura del dispositivo.

mAP50-90

Esta métrica representa el promedio del mAP calculado en un rango de diez umbrales de IoU que va desde los 0.50 hasta el 0.95 con incrementos constantes del 5%, si bien se evalúa la robustez, estabilidad y la calidad de la regresión matemática de las cajas delimitadoras. Es conveniente resaltar que un valor elevado en esta métrica exige que el modelo ajuste los bordes de la caja de forma casi perfecta al contorno del ave real. Un mAP50-95 adecuado garantiza que incluso si los pollos se encuentran en constante movimiento a cuando existe una gran densidad de aves el sistema puede aislar computacionalmente el cuerpo de cada pollo de manera precisa.

CAPÍTULO III.

3. METODOLOGÍA

3.1.1 Tipo de investigación

En la presente investigación tiene un enfoque mixto con predominancia cuantitativa y diseño experimental aplicado, con alcance explicativo y comparativo, el cual busca evaluar el impacto del sistema de monitoreo de comportamiento de pollos de engorde basado en un reconocimiento de imágenes, sobre la tasa de mortalidad.

Se menciona que es de carácter aplicativo ya que busca resolver un problema concreto del sector productivo avícola: la tasa de mortalidad en ciclos de producción de pollos de engorde. El estudio no se limita a generar conocimiento teórico, si no que desarrolla e implementa un prototipo funcional basado en tecnología de industria 4.0 (IoT, visión artificial y procesamiento), con impacto directo en la eficiencia productiva de la Granja Avícola.

Se establece el análisis de un diseño comparativo entre la producción tradicional sin utilizar el sistema catalogándolo grupo control (GC) y un grupo experimental (GE) el cual se enfoca en la producción con el sistema implementado. El análisis se centra en la prima de evaluar el impacto en la tasa de mortalidad y la precisión del sistema.

Se determina un alcance explicativo, puesto que la investigación no solo describe el comportamiento de las aves, si no que busca explicar la relación que existe entre la detección temprana de anomalías conductuales y la disminución de la mortalidad.

3.2 MÉTODO DE INVESTIGACIÓN

3.2.1 Método experimental

Con respecto al proceso se divide en etapas que se definen en fases de trabajo, dichas fases se presentan en actividades, un enfoque que permite un control riguroso sobre las variables y escenarios implicados en el desarrollo del prototipo del Sistema de Monitoreo de Comportamiento de Pollos de Engorde. La elección del diseño metodológico facilita la manipulación precisa de las condiciones de prueba, garantizando así la obtención de resultados confiables y reproducibles. El carácter experimental de la investigación brinda la posibilidad de evaluar el rendimiento del prototipo, esto permite ajustes y optimizaciones para mejorar el rendimiento. Si bien la comparación que se realiza al grupo de pollos antes de aplicar el monitoreo y después de evaluarlos en los videos aplicando el algoritmo, brinda la posibilidad de cuantificar con precisión el impacto del sistema en la tasa de mortalidad de las aves. Esta lógica asegura la validez de los hallazgos, además, proporciona una base para futuras mejoras y aplicaciones prácticas del sistema en granjas avícolas.

3.2.2 Investigación cuantitativa

La investigación tiene un enfoque cuantitativo debido a que se fundamenta en la recopilación y el análisis datos numéricos relacionados a la tasa de mortalidad la misma que se expresa en porcentaje, la frecuencia de comportamientos detectados, además de la precisión del algoritmo. Los datos obtenidos serán sometidos a análisis estadísticos con el propósito de determinar si existen diferencias significativas entre el grupo control y el grupo

experimental. Este enfoque permite establecer relaciones causa-efecto entre la implementación del sistema de monitoreo y la reducción de la mortalidad.

3.2.3 Investigación cualitativa

En la investigación se integra el componente cualitativo mediante la observación directa del comportamiento de las aves además de la consulta a expertos en zootécnica y producción avícola, y la identificación etológica de patrones conductuales relevantes (alimentación, descanso, actividad, aglomeración, letargo), al observar y documentar el comportamiento de los pollos en diferentes etapas de crecimiento, permitirá identificar patrones importantes para posteriormente modelarlos y cuantificarlos por el sistema de reconocimiento de imágenes.

3.3 PROCEDIMIENTO

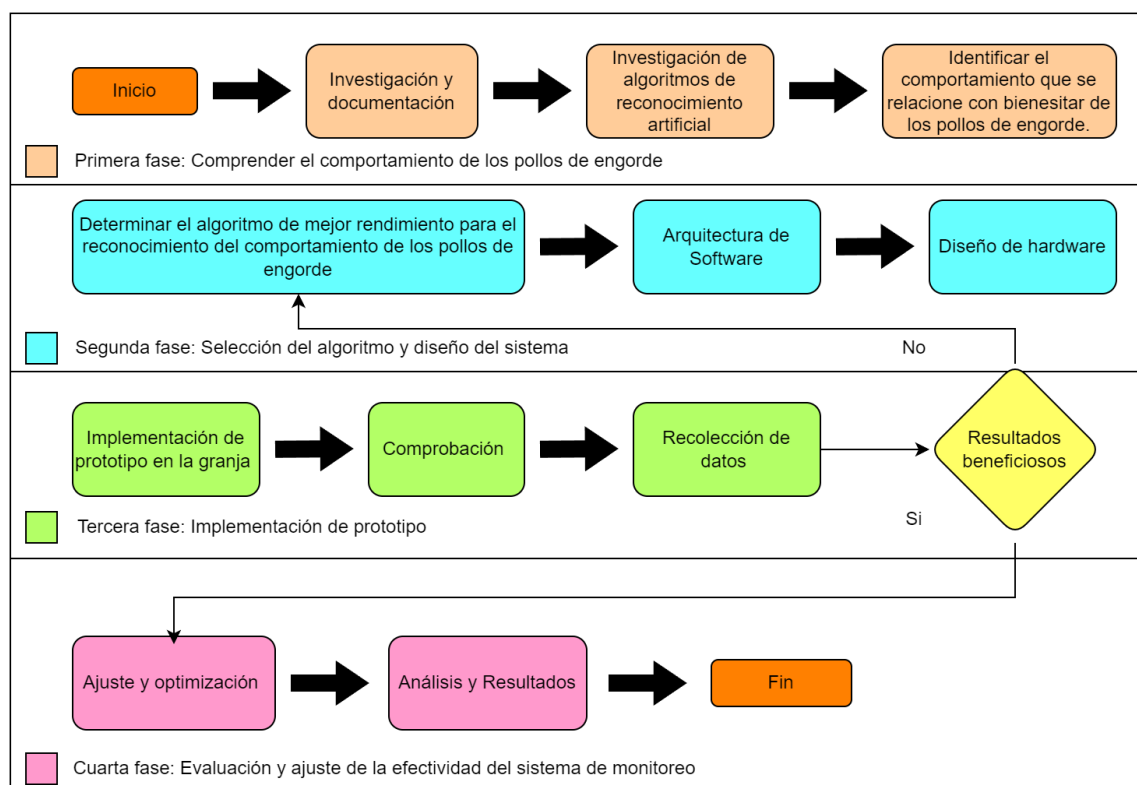


Ilustración 7: Fases de trabajo de investigación

3.3.1 Descripción de fases

3.3.1.1 Primera fase

Comprender el comportamiento de los pollos de engorde, en esta etapa se busca establecer una base de conocimiento sobre la relación entre el comportamiento de los pollos de engorde y su tasa de mortalidad, lo cual es crucial para reducir las pérdidas en la producción avícola. Para lo cual se recopila información teórica y práctica sobre los factores que afectan el bienestar de las aves, los patrones de comportamiento, así como los impactos en la salud. Además, se investiga algoritmos de reconocimiento de imágenes con el objetivo de determinar su aplicabilidad en el monitoreo de animal. Finalmente, se busca identificar los patrones de comportamiento más relevantes, tales como el movimiento, el descanso, la alimentación y la socialización, que puedan tener influencia directa en la tasa de mortalidad.

3.3.1.2 Segunda fase

En la sección de algoritmos y diseño el sistema se tiene en cuenta la exploración y la selección de algoritmos de reconocimiento de imágenes que permiten un monitoreo eficiente y preciso del comportamiento de los pollos de engorde. Se analiza el rendimiento de diferentes algoritmos considerando su precisión y efectividad. Además, se diseña el hardware, seleccionando componentes como cámaras y la placa de desarrollo que permita ejecutar el procesamiento de datos.




Ilustración 8: Diagrama del funcionamiento de prototipo

3.3.1.3 Tercera fase

La implementación de prototipo se centra en la construcción y prueba funcional en un entorno real. Inicialmente se instala el sistema en la granja avícola para capturar los datos del comportamiento de pollos. Luego, se verifica el correcto funcionamiento de prototipo, asegurándose de que los algoritmos seleccionados estén integrados y operen de manera efectiva en el entorno real. Finalmente, se recopilan datos del comportamiento, los cuales servirán como base para el análisis y validaciones del sistema.

3.3.1.4 Cuarta fase

Para evaluar la efectividad y realizar la optimización del sistema se analiza los resultados de los datos obtenidos en la fase de implementación del prototipo, de tal manera se puede realizar ajustes para maximizar la precisión y la utilidad del sistema. Finalmente, se analizan los resultados comparando las observaciones manuales con los datos generados por el sistema, con el fin de validar su eficiencia, identificar áreas de mejora y garantizar su utilidad para reducir la tasa de mortalidad en la producción avícola.

3.4 POBLACIÓN DE ESTUDIO

Población

La población de estudio estará confirmada por los datos de las variables dependientes obtenidas en la producción de pollos de engorde, como lo son: el número de pollos descartados (presentan síntomas graves de enfermedad o murieron en el proceso de crianza),

la observación de características que demuestren que un pollo debe ser descartado y la precisión del sistema de monitoreo de comportamiento.

Muestra

La muestra se tomará de manera aleatoria de los datos obtenidos de la población de pollos que se encuentre en análisis en el periodo de crianza, dichas muestras serán comparadas y validadas por un experto.

3.5 OPERACIÓN DE VARIABLES

Variables independientes

Independiente			
Variable	Concepto	Indicadores	Técnicas e Instrumentos
Tipos de algoritmos de reconocimiento de imágenes.	Los algoritmos de reconocimiento de imágenes son un subconjunto específico dentro del campo de la IA, enfocados en identificar patrones, objetos, o características dentro de imágenes.	Nominal Tipo n	Comparación, Informe de validaciones entre los distintos tipos de algoritmos de reconocimiento de imágenes.

Tabla 6: Variables independientes

Variables dependientes

Dependiente			
Variable	Concepto	Indicadores	Técnicas e Instrumentos
Tasa de mortalidad	La tasa de mortalidad es una variable que permite medir el porcentaje de animales que mueren durante un periodo de tiempo determinado en relación con el número total de animales que inicio el grupo.	Porcentaje	Comparación entre la cantidad de aves fallecidas en un periodo de tiempo.

Tabla 7: Variables dependientes

3.6 TÉCNICAS DE RECOLECCIÓN DE DATOS

3.6.1 Fuentes de información

Para la obtención de información relevante sobre técnicas, procesos y algoritmos utilizados en la detección y clasificación de patrones para el desarrollo del prototipo del sistema de monitoreo del comportamiento de pollos autónomo, se lleva a cabo una investigación bibliográfica, donde se fundamentará en diversas fuentes académicas, artículos científicos, tesis y otros trabajos de investigación relacionados con la visión artificial y el aprendizaje autónomo orientado al estudio del comportamiento e identificación de patrones. Adicionalmente, se consulta a expertos especializados en el área de zootecnia o veterinaria para enriquecer la comprensión del comportamiento de pollos de engorde en las granjas avícolas.

3.6.2 Componentes del prototipo

Para el desarrollo del proyecto se utilizaron sensores que ayudan a capturar los datos visuales en tiempo real, los componentes incluyen Raspberry Pi 5, cámaras IP, cámara integrada en la en prototipo OV5647 5MP, un sistema de almacenamiento local en el prototipo. Con el fin de capturar las variables: patrones de desplazamiento, tiempo de permanencia y frecuencia de interacción con los comederos.




Ilustración 9: Piezas para ensamblar el prototipo

Unidad central de Procesamiento

La Raspberry Pi 5 es el microordenador principal en el desarrollo del prototipo, el mismo fue seleccionado por su notable rendimiento gráfico y capacidad de cómputo, además esta versión facilita la integración de tareas de visión artificial y procesamiento de datos en tiempo real.




Ilustración 10: Módulo Raspberry Pi 5

Componente	Parámetro	Detalle Técnico
Raspberry Pi 5	Procesador	Broadcom BCM2712 (Quad-core Arm Cortex-A76 a 2.4GHz)
	Memoria RAM	8GB LPDDR4X-4267 SDRAM
	GPU	VideoCore VII (soporte OpenGL ES 3.1, Vulkan 1.2)
	Conectividad	Wi-Fi 2.4/5.0 GHz, Bluetooth 5.0, Gigabit Ethernet
	Puertos	2 × USB 3.0, 2 × USB 2.0, 2 × micro-HDMI (4Kp60)
	Interfaz Extra	PCIe 2.0 para periféricos de alta velocidad
Tarjeta MicroSD	Capacidad	64 GB
	Uso Principal	Sistema Operativo (OS), Librerías y Logs de datos
	Compatibilidad	Interfaz de alta velocidad SDR104

Tabla 8: Características de la Raspberry Pi 5

Cámara OV5647

El módulo de cámara OV5647 es un sensor CMOS de alta definición diseñado específicamente para su integración en prototipos a través del bus CSI. Este dispositivo permite la captura de imágenes fijas y video con un bajo consumo energético. Su arquitectura facilita la adquisición de fotogramas que posteriormente son procesados por algoritmos de detección, el mismo brinda un equilibrio eficiente entre resolución y velocidad de transferencia de datos.



Ilustración 11: Módulo cámara OV5647

Parámetro	Detalle Técnico
Modelo	OmniVision OV5647 (Color CMOS QXGA)
Resolución	5 megapíxeles (2592 × 1944 píxeles)
Tamaño del Sensor	1/4 de pulgada
Enfoque	Fijo
Apertura (f)	2.9
Distancia Focal	3.6 mm
Modos de Captura	1080px 30fps / 720px 60fps / 640x480px 90fps
Tipo de Conexión	CSI de 15 pines
Bus de Datos	MIPI de 2 carriles
Tamaño del Módulo	25 mm × 24 mm × 9 mm
Peso	Aproximadamente 3g

Tabla 9: Especificaciones técnicas del módulo OV5647

Es importante mencionar que este módulo se conecta directamente al puerto CSI de la Raspberry Pi 5, utilizando conectores MIPI de 22 pines.

Pantalla LCD TFT Touch

La pantalla permite la interacción directa con el sistema sin necesidad de periféricos externos como monitores o teclados. Se trata de una pantalla de cristal líquido (LCD) con tecnología de transistores de película fina que integra un panel táctil resistivo. Su diseño está optimizado para acoplarse directamente sobre el puerto GPIO de la Raspberry Pi. Esta característica permite crear una interfaz gráfica compacta y portátil para el monitoreo de variables en tiempo real.



Ilustración 12: Pantalla LCD TFT Touch Raspberry Pi4 Pi 3.5 320×480 3.5

Parámetro	Detalle Técnico
Tipo de Pantalla	TFT LCD
Tamaño de Diagonal	3.5 pulgadas
Resolución Nativa	480 x 320 píxeles
Panel Táctil	Resistivo de 4 hilos
Interfaz de Comunicación	SPI (Serial Peripheral Interface)
Frecuencia de Reloj SPI	32 MHz - 125 MHz
Conectividad	Header hembra de 26/40 pines para puerto GPIO
Consumo de Corriente	Aproximadamente 120 mA - 250 mA

Tabla 10: Características de la Pantalla LCD TFT Touch 3.5

Dado que el prototipo utiliza una Raspberry Pi 5, es importante mencionar en la documentación que la comunicación se realiza mediante el bus SPI a través de los pines GPIO. Para realizar la configuración en el sistema (instalación de los drivers) se hace uso de la guía y el repositorio en GitHub, en este apartado existe la posibilidad de cargar un sistema preconfigurado basado en Linux que optimiza el tiempo de configuración.

Raspberry Pi 5 PCIe to M.2 NVME SSD Hat

Este módulo de expansión permite aprovechar la interfaz PCIe 2.0 nativa de la Raspberry Pi 5 para conectar unidades de estado sólido (SSD) de alta velocidad. Al utilizar este adaptador, el prototipo supera las limitaciones de velocidad de lectura/escritura de las tarjetas MicroSD convencionales, proporcionando un acceso a datos significativamente más rápido. Esta implementación es fundamental para el proyecto, puesto que requiere el manejo de grandes volúmenes de datos, bases de datos locales o procesos de intercambio (swap) intensivos durante la ejecución de modelos de aprendizaje profundo.




Ilustración 13: Raspberry Pi 5 PCIe to M.2 NVME SSD Hat

Parámetro	Detalle Técnico
Interfaz de Host	PCIe 2.0 x1 (vía cable FPC de 16 pines)
Interfaz de Unidad	M.2 Key-M
Tamaños de SSD Compatibles	2230 / 2242 (según modelo de HAT)
Protocolo de Almacenamiento	NVMe (No compatible con M.2 SATA)
Velocidad de Transferencia	Hasta 500 MB/s (PCIe 2.0) / 800 MB/s (PCIe 3.0 habilitado)
Alimentación	Integrada a través del bus PCIe y pines GPIO
Indicadores LED	LED de encendido y LED de actividad de datos
Compatibilidad de Arranque	Soporta arranque del sistema (NVMe Boot)

Tabla 11: Características del módulo Raspberry Pi 5 PCIe a M.2 NVMe SSD HAT

Para el proyecto se le integra una unidad de almacenamiento de 256GB, además se conoce que las unidades NVMe pueden generar calor durante operaciones de escritura intensiva, es recomendable que este HAT se utilice en conjunto con el Active Cooler de la Raspberry Pi 5 para mantener la integridad térmica del prototipo.

Dispositivo de Monitoreo Energético: Probador USB Multifunción UT01C

Este instrumento de medición de precisión se integra en el prototipo para supervisar y validar el suministro eléctrico del sistema en tiempo real. Su función principal es garantizar que la Raspberry Pi 5 y sus periféricos reciban un flujo de energía estable, permitiendo detectar caídas de tensión o consumos excesivos que podrían comprometer la integridad del hardware. Gracias a su compatibilidad con protocolos avanzados de carga rápida, el dispositivo puede identificar la negociación de energía entre la fuente de alimentación y el procesador, asegurando que se entreguen los 5V/5A necesarios para el funcionamiento óptimo del sistema.



Ilustración 14: UT01C Probador USB, voltímetro, amperímetro.

Parámetro	Detalle Técnico
Rango de Tensión de Entrada	DC 4.0 V – 30.0 V
Rango de Corriente de Medición	0.0 A – 12.0 A
Rango de Potencia	0 W – 240 W
Protocolos de Carga Soportados	PD 3.1, QC 4.0, PPS, Apple 2.4A
Resolución de Medición	0.001V / 0.001A
Tipo de Pantalla	LCD TFT a color con rotación de interfaz
Interfaz de Conexión	USB Tipo-C (Entrada/Salida)
Funciones de Registro	Medición de capacidad (mAh) y energía acumulada (Wh)
Protecciones	Monitoreo de temperatura y alarmas de sobrevoltaje/sobrecorriente

Ilustración 15: Probador USB Multifunción UT01C

Unidad de Alimentación: Fuente de Poder CanaKit 45W USB-C PD

Para garantizar la estabilidad operativa de la Raspberry Pi 5, especialmente bajo cargas de procesamiento intensivas y con múltiples periféricos conectados, se utiliza una fuente de alimentación de alta capacidad con protocolo *Power Delivery*. Esta unidad está diseñada para negociar perfiles de energía específicos que permiten a la placa entregar hasta 1.6 A de corriente combinada a los puertos USB, asegurando que componentes como el SSD NVMe y la cámara funcionen sin caídas de tensión. Su arquitectura interna incluye filtros de ruido eléctrico para proteger los componentes sensibles del prototipo.



Ilustración 16: Fuente de alimentación 45W USB-C

Parámetro	Detalle Técnico
Potencia Total	45 W
Protocolo de Carga	USB-C Power Delivery (PD)
Tensión de Entrada	100 V – 240 V AC (50/60 Hz)
Perfiles de Salida (Salida Variable)	5.1V / 5A, 9V / 3A, 12V / 3A, 15V / 3A, 20V / 2.25A
Conector de Salida	USB Tipo-C
Longitud del Cable	1.5 metros
Protecciones Integradas	Cortocircuito, corriente y temperatura

Tabla 12: Características de la fuente de alimentación 45W-USB-C

A diferencia de los cargadores USB-C estándar, esta fuente brinda 5.1V / 5A, esto permite que la Raspberry Pi 5 se quede sin suministro suficiente de corriente para los puertos USB y la interfaz PCIe, lo que podría afectar el rendimiento del SSD NVMe, afectando en funcionamiento del sistema.

Camara Ezviz H6c Pro 1080P

La cámara Ezviz H6c Pro es un nodo de monitoreo de video inteligente capaz de realizar seguimientos y proporcionar una vista panorámica del entorno del prototipo. A diferencia

del módulo de cámara directo, este dispositivo opera de forma independiente o conectada a la red, Su capacidad de rotación motorizada permite ampliar el campo visual del sistema de monitoreo, facilitando la supervisión remota y el registro de eventos en alta definición.



Ilustración 17: Cámara Ezviz H6c Pro

Parámetro	Detalle Técnico
Resolución de Video	Full HD 1080p (1920 × 1080)
Ángulo de Rotación	Pan: 340°, Tilt: 55°
Lente	4mm @ F1.6 (Ángulo de visión diagonal 90°)
Visión Nocturna	Infrarroja (IR) inteligente hasta 10 metros
Compresión de Video	H.265 / H.264
Conectividad	Wi-Fi 2.4 GHz y puerto Ethernet RJ45
Almacenamiento Local	Ranura para tarjeta MicroSD de hasta 256 GB
Funciones Inteligentes	Detección de movimiento humano, seguimiento automático y comunicación bidireccional
Alimentación	DC 5V / 1A (vía puerto Micro USB)

Tabla 13: Especificaciones Técnicas de la Cámara Ezviz H6c Pro

Para el desarrollo del prototipo, esta cámara puede configurarse mediante el protocolo RTSP (Real Time Streaming Protocol), lo que permite que la Raspberry Pi 5 acceda al flujo de video de manera inalámbrica para procesar imágenes de un área más extensa que la cubierta por la cámara OV5647. Además, el uso del códec H.265 es una ventaja técnica clave, ya que reduce significativamente el ancho de banda necesario para la transmisión de video y optimiza el espacio en la memoria interna del dispositivo.

Camara @jhua Hero B1

La cámara Dahua DH-H5B representa una unidad de captura de video de ultra alta definición dentro del ecosistema del prototipo. A diferencia de los modelos estándar, este dispositivo cuenta con una resolución de 5 megapíxeles, lo que permite obtener un nivel de detalle significativamente superior para tareas de reconocimiento y análisis visual. Su arquitectura incluye funciones de inteligencia artificial avanzada directamente en el borde (Edge AI), capaces de distinguir entre humanos y mascotas, optimizando así las alertas y el seguimiento automático. Es un componente clave para el monitoreo de alta fidelidad, integrándose mediante conectividad inalámbrica y permitiendo una gestión eficiente del ancho de banda gracias a sus algoritmos de compresión.



Ilustración 18: Cámara Dahua DH-H5B

Parámetro	Detalle Técnico
Resolución	5 megapíxeles (2880 × 1620)
Sensor de Imagen	1/3" CMOS progresivo
Visión Nocturna	Iluminación IR hasta 10 metros
Rango de Movimiento	Pan: 0° a 355°; Tilt: -5° a 80°
Compresión de Video	H.265 / H.264
Tasa de Cuadros	Hasta 25/30 fps
Audio	Bidireccional (Micrófono y altavoz integrados)
Conectividad	Wi-Fi (2.4 GHz) y puerto Ethernet RJ-45
Almacenamiento	Ranura para MicroSD de hasta 256 GB
Funciones de IA	Detección humana, detección de mascotas y seguimiento inteligente
Alimentación	DC 5V / 1A (Puerto Micro USB)

Tabla 14: Especificaciones Técnicas de la Cámara Dahua DH-H5B

3.7 DISEÑO E IMPLEMENTACIÓN DEL PROTOTIPO

En este apartado se detalla la infraestructura tecnológica junto al proceso completo de diseño e implementación del prototipo, empleadas para ejecutar modelos de reconocimiento de imágenes para la detección de comportamientos en los pollos de engorde, el mismo está basado en la Raspberry Pi 5, integrando los modelos de detección (YOLOv8n, YOLOv26n, YOLOv11n), almacenamiento NVMe y visualización en pantalla táctil.

3.7.1 Preparación y selección de tecnologías

Para el desarrollo del prototipo se requiere que el dispositivo capture imágenes donde se identifiquen patrones anormales del comportamiento de los pollos de engorde

3.7.2 Requisitos funcionales y entorno

3.7.2.1 Entorno de desarrollo

Para la construcción del sistema y la integración de los modelos de visión por computador, se optó por un flujo de trabajo basado en acceso remoto, esto permitió una gestión eficiente de los recursos del hardware embebido sin necesidad de periféricos locales. La programación se realizó mediante el protocolo SSH desde un computador externo, de esta manera se facilitó la ejecución de comandos en tiempo real al momento de realizar las pruebas. Además, se utilizó la herramienta WinSCP para la gestión, transferencia y revisión de ficheros, esto permitió revisar los scripts y activos del proyecto de manera más cómoda.

En lo que respecta a la edición de código, se emplearon los editores nano en para el entorno de Linux y Visual Code. El control de versiones y la integridad del código fuente se gestionaron mediante Git, permitiendo mantener un historial de cambios y facilitar la reversión de errores durante la fase de experimentación. Además, en el SO de la Raspberry para evitar conflictos entre dependencias, se implementó un entorno virtual de Python (venv) alojado en la ruta crítica “/mnt/taberna/entorno_yolo/”, donde se instalaron todas las librerías necesarias para la ejecución de los modelos YOLO.

3.7.2.2 ENTORNO DE PRUEBAS Y DESPLIEGUE

El despliegue final del sistema se centraliza en una computadora de placa única Raspberry Pi 5, la cual fue seleccionada por su capacidad de procesamiento para ejecutar modelos nano de reconocimiento de imágenes. Así mismo, se puede derivar la carga de trabajo al conectarse a un servidor local. Todo el hardware del prototipo se encuentra protegido por una carcasa diseñada e impresa en tecnología 3D. Hay que mencionar, no sólo la alta demanda energética del sistema, sino también el uso de la unidad NVMe para almacenamiento de alta velocidad y la integración de una pantalla táctil, es necesario el uso de la fuente de alimentación oficial de 5V/5A vía USB-C. Este componente es crítico para prevenir caídas de tensión que podrían comprometer la estabilidad del sistema durante procesos intensivos de detección. Y para la gestión térmica, se implementó un sistema de refrigeración activa complementado con disipadores de calor de dimensiones optimizadas, medida indispensable para mitigar el incremento de temperatura generado por el procesamiento continuo de modelos de visión artificial. En términos de conectividad, se prioriza el uso de una interfaz Ethernet para asegurar la estabilidad del flujo de datos mediante el protocolo RTSP, pero también se permite la conexión vía WiFi en la banda de 2,4GHz, garantizando así el ancho de banda necesario para la transmisión de datos de video desde la galponera.

3.8 DESARROLLO DEL PROTOTIPO

3.8.1 Diseño de la estructura

Para la viabilidad del proyecto, la protección y organización del hardware es un aspecto crítico, por lo que se desarrolló con cuidado la carcasa en 3D.

Desarrollo y modelado 3D de la Carcasa




Ilustración 19: Diseños paramétricos de la estructura.

Previo al diseño en 3D, se realizó un estudio dimensional, para lo cual se utilizó el software AutoCAD. En esta etapa se cuidan los detalles para que los componentes calcen de manera adecuada en el prototipo, si bien se considera la dimensión general de la Raspberry, también se deben considerar los puertos y conectores.

En el diseño se establecieron las dimensiones nominales de 85.00 mm de longitud por 56.00 mm de ancho. Durante este proceso, se aplicaron los siguientes criterios de diseño:

- **Distribución de Periféricos:** Se proyectaron las aperturas para los puertos USB (2.0 y 3.0) y el puerto Ethernet, respetando las distancias de separación de 14.50 mm y 16.00 mm respectivamente, para asegurar un acoplamiento mecánico sin interferencias.
- **Posicionamiento de Puntos de Anclaje:** Se definieron cuatro orificios de montaje con un diámetro de 2.70 mm y 3.00 mm que se muestra en la imagen diseños paramétricos de la estructura, alineados con los orificios de fábrica de la placa base para permitir una fijación rígida mediante tornillería M2.5 o M3.
- **Gestión de Interfaces de Video y Energía:** Se delimitaron las zonas críticas para los conectores micro-HDMI y la entrada de alimentación USB-C, facilitando la accesibilidad externa.




Ilustración 20: Diseño de la estructura base

Posteriormente el diseño de la carcasa se asegura que el contenedor físico no solo brindara protección mecánica a los componentes electrónicos, sino que también facilitara la ventilación y el acceso a los puertos de comunicación necesarios para el despliegue del modelo YOLO. Para esto se utilizó el software Autodesk Inventor, se inició el modelado de la estructura base. En esta etapa se definieron las dimensiones internas considerando las tolerancias necesarias para la inserción de la placa de procesamiento. Se incluyeron cuatro bases de montaje ubicados para asegurar la placa base mediante tornillería, evitando desplazamientos por vibraciones.

Integración de Hardware de Procesamiento y Refrigeración




Ilustración 21: Integración de Hardware de procesamiento y Refrigeración

Para validar el diseño, se realizó un ensamblaje virtual incorporando el modelo tridimensional de la Raspberry Pi 5. Como se observa en la **Ilustración 21: Integración de Hardware de procesamiento y Refrigeración**, además se verificó la alineación exacta de los puertos USB, Ethernet y micro-HDMI con las aperturas laterales de la carcasa. Posteriormente, se añadió la placa de expansión de memoria superior para gestionar la alimentación o sensores adicionales requeridos por el sistema de monitoreo.




Ilustración 22: Integración de periféricos pantalla, sensor OV5647

El sistema requiere una interfaz de usuario local y un sensor óptico para la detección de aves. Por ello, el diseño evolucionó para integrar un soporte frontal para la pantalla táctil y un módulo lateral para la cámara como se muestra en la **Ilustración 22: Integración de periféricos pantalla, sensor OV5647**. Esta disposición permite un ángulo de visión óptimo

mientras mantiene la compacidad del dispositivo. Para facilitar el entendimiento de la estructura se trabajan con vistas transparentes del modelo CAD facilitaron la detección de posibles interferencias entre los cables flex y las paredes internas de la estructura.

Prototipado Físico y Manufactura




Ilustración 23: Prototipado y Manufactura

Como resultado el diseño fue exportado para su fabricación mediante impresión 3D. Considerando las condiciones ambientales de la granja, se seleccionaron materiales con resistencia térmica y mecánica como el PLA. En la Ilustración 23: Prototipado y Manufactura se aprecia el prototipo funcional final, confirmando que el ajuste físico coincide con las especificaciones del modelo digital y permitiendo la ejecución fluida del software de monitoreo en un entorno real.

3.8.2 Simulación y evaluación de los modelos

Adquisición y Extracción de Fotogramas

Una vez seleccionado el modelo estándar de YOLOv8, es necesario preparar el conjunto de datos para realizar el entrenamiento junto a la evaluación del modelo. Para ello revisamos las grabaciones que se realizaron en el proceso de crianza, específicamente las últimas cuatro semanas de crianza, cuando se observa un desarrollo suficientemente grande del ave para que el modelo puede inferir sus predicciones. Se toman capturas de los frames importantes que destaquen gran cantidad de datos, por ejemplo, pollos en pie, recostados, aislados o en grupo.




Ilustración 24: Revisión de videos y obtención de fotogramas

Tomando como punto de partida la recopilación de los registros en video del interior del galpón, capturados durante las últimas 4 semanas del ciclo de crianza de los pollos de engorde. Dado que los videos se encontraban en formatos de videovigilancia (archivos.dav), se utilizó el software reproductor multimedia VLC para visualizar las grabaciones y extraer fotogramas clave. Se seleccionaron momentos específicos que representaran diversas condiciones de iluminación, densidad de aves y niveles de estrés térmico para garantizar la variabilidad del conjunto de datos.

Curación y filtrado de los datos




Ilustración 25: Filtrado de los fotogramas

Una vez extraídas las imágenes, se realizó una inspección manual para descartar fotogramas borrosos, redundantes o con oclusiones severas que no aportaran información útil al modelo. Esto garantizó que el modelo aprendiera de ejemplos claros y representativos del entorno real. Posteriormente se guardan las imágenes clasificadas del proceso de crianza, estas

imágenes se caracterizan por presentar una densidad importante de pollos de engorde en buen estado, pollos que presenten características anormales, pollos en estado de reposo e incluso imágenes de pollos fallecidos.

Etiquetado de los datos




Ilustración 26: Etiquetado de categorías

Las imágenes seleccionadas fueron importadas a una herramienta de anotación Roboflow. En esta fase, se trazaron cuadros delimitadores (*bounding boxes*) sobre cada ave visible. A cada detección se le asignó una clase específica correspondiente a su estado y comportamiento observado, categorizándolos principalmente en tres estados críticos para el monitoreo: GOOD (bueno), WARNING (advertencia) y BAD (malo).

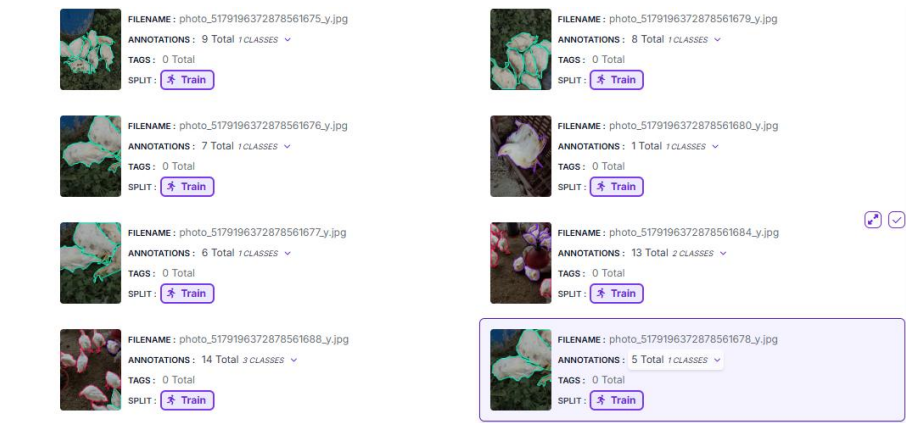


Ilustración 27: Datos procesados con los identificadores

División para el preprocesamiento de los datos

El conjunto de datos etiquetado se dividió en tres subconjuntos:

Entrenamiento (Train)

En este apartado el 70% de las imágenes es utilizado para que el algoritmo aprenda las características.

Validación (Valid)

Alrededor del 20%, utilizado para ajustar los hiperparámetros durante el entrenamiento y evitar el sobreajuste “overfitting”.

Prueba (Test)

Y el 10% restante, reservado como un conjunto de datos nunca visto por el modelo, con el fin de evaluar el rendimiento final.

Adicionalmente, se aplicaron técnicas de aumento de datos “Data Augmentation”, como rotaciones leves, cambios en la exposición y recortes, para robustecer el modelo frente a las variables del entorno del galpón.




Ilustración 28: División - Augmentation de los datos

Importación del Dataset

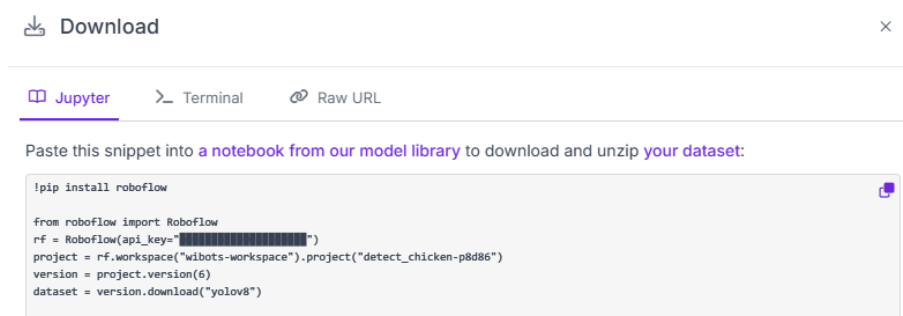


Ilustración 29: Código para importar dataset

Para la fase de entrenamiento se importó el conjunto de datos etiquetado y preprocesado desde la plataforma Roboflow, haciendo uso de su API se conectó al entorno de desarrollo preparado en Google Colab. Se optó por esta herramienta basada en la nube gracias a que cuenta con la opción de aceleración por hardware (GPU), de esta manera se redujo los tiempos de cómputo y se logró aislar las dependencias en un solo lugar.

Configuración y Entrenamiento en Google Colab

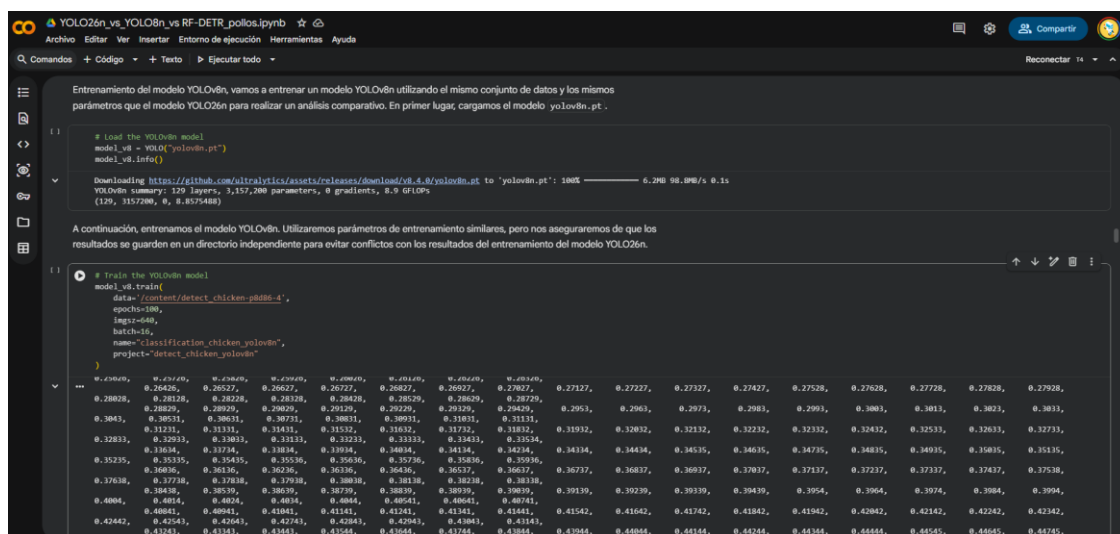


Ilustración 30: Google Colab - Entrenamiento

Dentro de este entorno, se estructuró el flujo de trabajo para llevar a cabo el entrenamiento y un análisis comparativo exhaustivo entre diferentes arquitecturas de detección de objetos, destacando YOLOv8n, YOLOv26n y YOLOv11n. Para estandarizar las pruebas, se definieron hiperparámetros específicos, el entrenamiento se configuró para ejecutarse durante 100 épocas (epochs), con un tamaño de imagen de 640x640 píxeles (imgsz=640) y un tamaño de lote de 16 (batch size=16).

El uso de la interfaz de Google Colab fue fundamental para la validación del proceso, ya que permitió observar los resultados iteración tras iteración, visualizar en tiempo real el comportamiento de la función de pérdida y analizar los estadísticos de los parámetros del modelo. Finalmente, esta plataforma facilitó la extracción y descarga directa de los pesos finales del modelo entrenado (yolov8n.pt). La obtención de estos pesos optimizados fue un paso crítico, ya que garantiza que el modelo resultante sea lo suficientemente ligero y eficiente para ser integrado y ejecutado sin problemas dentro de los recursos limitados de la Raspberry Pi 5, la cual operará como el sistema embebido para la inferencia en tiempo real dentro del galpón.

3.8.3 Selección de modelos y sus características

Al realizar el entrenamiento de los tres modelos se obtienen las siguientes métricas, precisión, Recall, F1-score, mAP50, mAP50-95 estas métricas se compran con la finalidad de elegir el mejor modelo que se ejecutara en el dispositivo, Raspberry Pi 5. Se recalca que se busca un modelo que mantenga un equilibrio entre rendimiento analítico y la eficiencia computacional.

Métrica	YOLOv8n	YOLOv11n	YOLOv26n
Precisión	0.436	0.415	0.496
Recall	0.399	0.381	0.329
F1-score	0.417	0.397	0.395
mAP50	0.368	0.380	0.348
mAP50-90	0.312	0.324	0.299

Tabla 15: Comparativa de Métricas

La tabla muestra las métricas tiempo después de que cada modelo fue entrenado, a partir de ello se procede a realizar una evaluación con una imagen de prueba, la misma nos permite comparar vialmente como se comporta cada modelo entrenado.

YOLOv26n



Ilustración 31: Imagen analizada con el modelo YOLOv26n

En primer lugar, el modelo YOLOv26n queda descartado para esta aplicación específica. Aunque presenta una alta Precisión (0.496) que garantiza un bajo nivel de falsos positivos, su baja Sensibilidad o Recall (0.329) indica que omite una cantidad significativa de pollos presentes en la escena. Y para el análisis es necesario mapear correctamente la distribución espacial y la densidad de agrupación del galpón; un modelo que "ignora" a gran parte de los individuos invalida la recolección de datos estadísticos del comportamiento.

YOLOv11n



Ilustración 32: Imagen analizada con el modelo YOLOv11n

Por otro lado, el modelo YOLOv11n, al analizar la evaluación que se realiza después del entrenamiento se observa que existe una gran cantidad de aves al fondo que no contienen una caja asignada. El modelo ignora una gran cantidad considerable esto justifica el valor de Recall, por otra parte, el modelo experimenta dificultades para segmentar las aves individuales cuando están juntas. Se puede apreciar que al solaparse las aves las fronteras corporales se vuelven difusas, lo que genera cajas superpuestas con niveles de confianza bajos. Además, el modelo es capaz de diferenciar estados conductuales automáticamente bajo las etiquetas, comprobando con el propósito de monitoreo conductual.

YOLOv8n



Ilustración 33: Imagen analizada con el modelo YOLOv8n

Por consiguiente, el modelo YOLOv8n se establece como una solución. Representa el "punto de equilibrio" entre el rendimiento analítico y la eficiencia computacional que ofrecer la

Raspberry Pi 5. Sus métricas (Recall de 0.399 y F1-score de 0.417) proporcionan la justificación necesaria para registrar de manera confiable la distribución de los pollos de engorde. Se observa que el modelo hace un esfuerzo para encontrar objetos, logrando capturar más individuos que antes pensaban desapercibidos. A pesar de ubicar más pollos, las cajas se amontonan de una forma caótica.

Al poseer una arquitectura convolucional altamente optimizada para inferencia rápida, YOLOv8n garantiza un flujo de trabajo en tiempo real, latencias mínimas y, sobre todo, la estabilidad térmica e integridad operativa del hardware, cumpliendo a cabalidad con los requerimientos funcionales del prototipo.




Ilustración 34: Comparativa de Métricas: YOLOv26n vs YOLOv8n vs YOLOv11n

Como se observa en la Ilustración 34: Comparativa de Métricas: YOLOv26n vs YOLOv8n vs YOLOv11n se puede apreciar que el modelo YOLOv8n presenta equilibrio en sus métricas, un punto intermedio que lo convierte en el modelo adecuado para el prototipo de reconocimiento del comportamiento de los pollos de engorde.

3.8.4 Arquitectura de software

La arquitectura del software ha sido diseñada bajo principios de modularidad y concurrencia, garantizando una ejecución eficiente de los modelos de inteligencia artificial sin comprometer la fluidez de la interfaz gráfica de usuario (GUI).




Ilustración 35: Interfaz gráfica de Usuario

Resultados de la implementación en hardware

La validación empírica de la arquitectura asíncrona en el entorno físico de la granja avícola arrojó resultados confirmando la viabilidad técnica del diseño para operaciones ininterrumpidas durante un periodo extenso de tiempo.

Fluidez de la inferencia y tasa de cuadros (FPS)

Durante las pruebas experimentales nativas sobre el procesador ARM del dispositivo, el sistema estabilizó la tasa de inferencia en 5.8 FPS. Esta es una frecuencia de muestreo óptima para el alcance del proyecto. La etología de los pollos de engorde se caracteriza por transiciones conductuales lentas, tales como periodos prolongados de letargo, alimentación o procesos de agrupamiento por estrés térmico. Capturar un promedio de 6 imágenes por segundo permite una observación continua de alta fidelidad para estos fenómenos, validando que no es necesario incurrir en la adquisición de costosos aceleradores neuronales físicos para el despliegue del sistema.

Consumo de Recursos (RAM y CPU)

El diseño asíncrono demostró una eficiencia sustancial en la retención de memoria y la distribución de carga de procesamiento. El sistema en ejecución registró un consumo promedio de memoria RAM del 28% (229 MB). Este valor reducido certifica la ligereza estructural de YOLOv8n y confirma la ausencia de fugas de memoria. Por su parte, la carga del procesador se mantuvo en un promedio del 46.2%. Conservar más de la mitad de la capacidad de cómputo libre, esto permite al sistema operativo Linux disponer del ancho de banda necesario para gestionar procesos subyacentes sin competir por los recursos que demanda el software.

3.9 IMPLEMENTACIÓN Y EVALUACIÓN

3.9.1 Diseño final del prototipo



Ilustración 36: Integración del prototipo en la Galponera

La implementación final del sistema se ha consolidado como una unidad de procesamiento y visualización robusta, diseñada específicamente para el entorno avícola. Como se aprecia en la Ilustración 36: Integración del prototipo en la Galponera, el núcleo tecnológico consiste en una Raspberry Pi 5 integrada en una carcasa protectora fabricada en PLA+. Este material fue seleccionado por su equilibrio entre facilidad de impresión y resistencia mecánica para soportar la pantalla táctil LCD, la cual permite la interacción directa del usuario y el monitoreo de las detecciones en tiempo real sin necesidad de periféricos externos.



Ilustración 37: Sistema de cámaras y red en la galponera

Para la captura de datos en el campo, el prototipo emplea cámaras posicionadas de forma estratégica en la estructura de la galponera, logrando un ángulo de visión cenital sobre el lote de aves como muestra la Ilustración 37: Sistema de cámaras y red en la galponera, esta configuración facilita la detección automática de pollos de engorde mediante visión artificial, garantizando un monitoreo constante y no invasivo. Además, al no encontrarse cerca de las aves, está capturar mejor las características de los pollos de engorde. La infraestructura se complementa con un sistema de red local, cuyo router y punto de acceso están montados en soportes personalizados de PLA+ anclados a la estructura de la galponera,

lo que asegura la estabilidad en la conexión y la organización del cableado en el techo de la instalación.

Respecto al modelo del dispositivo, este ejecuta de forma nativa el modelo YOLOv8n aprovechando eficientemente los recursos de hardware de la unidad de procesamiento central. Esta configuración de computación en el borde (Edge Computing) permite realizar el conteo, seguimiento y monitoreo de las aves en tiempo real directamente en la galponera, garantizando la continuidad operativa del prototipo sin depender de una conexión a internet.

Componente	Especificación Técnica
Cerebro del Sistema	Raspberry Pi 5 (8GB RAM), Model B Rev 1.0 con procesador Quad-core de 2.400GHz.
Modelos de IA	YOLOv8n optimizado para Edge Computing,
Sistema Operativo	Debian GNU/Linux 12 (bookworm) con arquitectura de 64 bits (aarch64) incluye el entorno Python
Interfaz Local	Pantalla LCD integrada con soporte táctil
Material de Carcasa	Polímeros técnicos (ASA/PETG) o Resina resistente
Conectividad	Wi-Fi local y soporte para protocolos SSH/Git
Alimentación	Fuente oficial de Raspberry Pi de 45W, que garantiza el suministro estable para el procesador y la pantalla táctil bajo carga de trabajo intensiva cuando se ejecuta el modelo. También funciona con una Power Bank de alta capacidad para acceder al sistema o a la información que guarda (no es recomendable ejecutar los modelos cuando está conectada a la Power Bank)

Tabla 16: Especificaciones del prototipo

CAPÍTULO IV.

4. RESULTADOS Y DISCUSIÓN

Elección del modelo

Se realizó una prueba de normalidad para cada una de las métricas de los modelos YOLOv8n, YOLOv11n, YOLOv26n, las métricas se basan en la siguiente hipótesis:

Hipótesis nula: Los datos siguen una distribución normal.

Hipótesis alternativa: Los datos no siguen una distribución normal.

Pruebas de normalidad				
Parámetro	Modelo	Shapiro-Wilk		
		Estadístico	gl	Sig.
precisión	yolov11n	0,880	100	1,84E-07
	yolov26n	0,878	100	1,43E-07
	yolov8n	0,900	100	1,44E-06
recall	yolov11n	0,987	100	4,42E-01
	yolov26n	0,867	100	5,19E-08
	yolov8n	0,964	100	7,49E-03
F1-Score	yolov11n	0,918	100	1,17E-05
	yolov26n	0,829	100	2,09E-09
	yolov8n	0,918	100	1,13E-05

mAP50	yolov11n	0,822	100	1,24E-09
	yolov26n	0,679	100	1,83E-13
	yolov8n	0,679	100	1,78E-13
mAP50-95	yolov11n	0,747	100	7,66E-12
	yolov26n	0,663	100	8,18E-14
	yolov8n	0,672	100	1,26E-13

Tabla 17: Prueba de normalidad a las métricas de cada modelo

Los resultados de la prueba de normalidad de Shapiro-Wilk demuestran que, para la mayoría de las métricas de cada uno de los modelos, el valor de significancia (p-valor) fue menor a 0,05. Esto descarta la hipótesis nula y acepta la hipótesis alternativa, la misma expresa que los datos no siguen una distribución normal. Por tal motivo, se realizará una prueba estadística para datos no paramétricos.

En base a lo anterior, se realiza una Prueba de Kruskal-Wallis para muestras independientes

Resumen de contrastes de hipótesis				
	Hipótesis nula	Prueba	Sig. (p-valor)	Decisión
1	La distribución de precisión es la misma entre categorías del modelo YOLO.	Prueba de Kruskal-Wallis para muestras independientes	0,750	Conserve la hipótesis nula.
2	La distribución de recall es la misma entre categorías del modelo YOLO.	Prueba de Kruskal-Wallis para muestras independientes	1,00E-06	Rechace la hipótesis nula.
3	La distribución de F1-Score es la misma entre categorías del modelo YOLO.	Prueba de Kruskal-Wallis para muestras independientes	1,8274E-7	Rechace la hipótesis nula.
4	La distribución de mAP50 es la misma entre categorías del modelo YOLO.	Prueba de Kruskal-Wallis para muestras independientes	9,1055E-19	Rechace la hipótesis nula.
5	La distribución de mAP50-95 es la misma entre categorías del modelo YOLO.	Prueba de Kruskal-Wallis para muestras independientes	3,8308E-14	Rechace la hipótesis nula.
Se muestran significaciones asintóticas. El nivel de significación es de 0,050.				

Tabla 18: Resumen de contraste de hipótesis de la prueba de Kruskal-Wallis




Ilustración 38: Diagrama de cajas de la métrica precisión

Se puede observar mediante el diagrama de cajas que la métrica de precisión revela una similitud en el comportamiento central de los tres algoritmos, situando sus medias en un rango estrecho cercano a 0.43, además los rangos intercuartiles se superponen casi en su totalidad, lo que justifica que la prueba de Kruskal-Wallis no halló diferencias significativas para la métrica de precisión.




Ilustración 39: Diagrama de cajas de la métrica Recall

Se puede observar mediante el diagrama de cajas que la métrica de Recall tiene una mediana 0.39 por parte de YOLOv8n y le sigue el modelo YOLOv11n con 0.38, mientras que YOLOv26n se posiciona visiblemente por debajo. Esta separación de medias posiciona al modelo YOLOv8n sobre los demás modelos. YOLOv11n muestra una distribución interna

más compacta y estable solo con un único valor atípico, mientras que YOLOv26n registra una dispersión hacia la baja con valores atípicos severos, representados por asteriscos como el caso 201 y 202 que caen por debajo de 0.20, esto con confirma visualmente su recurrente ineficiencia y tendencia a generar falsos negativos bajo condiciones de hacinamiento en un galpón.




Ilustración 40: Diagrama de cajas de la métrica F1-Score

Se puede observar mediante el diagrama de cajas que en la métrica F1-Score destacan los modelos YOLOv8n y YOLOv11n cuyas medias se localizan por encima del modelo YOLOv26n, además la presencia de valores atípicos como 216, 202, 206 y 201 muestran un desempeño deficiente para trabajar en las condiciones de un galpón de pollos de engorde.




Ilustración 41: Diagrama de cajas de la métrica mAP50

Se puede observar mediante el diagrama de cajas a la métrica mAP50 que representa la precisión promedio al umbral estándar del 50%. El modelo YOLOv11n tiene una diferencia significativa cuya mediana se encuentra sutilmente sobre el modelo YOLOv8n. Por otro

lado, el modelo YOLOv26n queda por debajo. Es importante destacar la extensión de los bigotes inferiores y la hilera de valores atípicos en descenso para los tres modelos. Esto visualmente se traduce en las dificultades que experimentan los algoritmos al intentar localizar con exactitud los límites corporales de los pollos en los momentos críticos de máxima aglomeración.




Ilustración 42: Diagrama de cajas de la métrica mAP50-95

Se puede observar mediante el diagrama de cajas que la métrica de Map50-95 que representa la precisión de la localización espacial de los pollos. Se tiene que el rango intercuartílico de YOLOv11n se encuentra posicionado de manera casi homogénea por encima de la caja de YOLOv26n y muestra una separación geométrica más limpia respecto a YOLOv8n. De esta manera se aprecia que el modelo YOLOv11n es eficiente localizando a las aves seguido del modelo YOLOv8n en la calidad para delimitar las cajas a la estructura del ave.

Si bien se utiliza la prueba de Kruskal-Wallis para verificar si existe diferencia significativa entre los modelos YOLO, además de observar los diagramas de cajas que reflejan que existieron diferencias significativas entre modelos en cada una de sus métricas, para elegir correctamente el modelo se realizó la prueba de U-Mann-Whitney con corrección de Bonferroni para determinar diferencias significativas entre pares, de esta manera comparamos cada modelo y evitamos tener falsos positivos.

Primero calculamos la significancia ajustada

$$\alpha_{ajustada} = \frac{\alpha}{n}$$

Donde n es igual al número de comparaciones

$$\alpha_{ajustada} = \frac{0.05}{3}$$

$$\alpha_{ajustada} = 0.016$$

Si el valor calculado entre pares por la prueba U-Mann-Whitney es mayor, da como resultado que no existe nivel de significancia, pero si el valor es menor este quiere decir que existe una diferencia significativa entre pares.

Métrica	YOLOv8n	YOLOv11n	Elección	sig	sig vs 0,016
precisión	98,33	102,67	YOLOv11n	0,596	no
recall	105,7	95,3	YOLOv8n	0,204	no
F1-Score	100,76	100,24	YOLOv8n	0,949	no
mAP50	91,6	109,4	YOLOv11n	0,03	no
mAP50-95	89,68	111,32	YOLOv11n	0,008	si

Tabla 19: Estadísticos de la prueba de agrupación YOLOv8n vs YOLOv11n y comparación

Los resultados de la tabla demuestran que mantienen una similitud en la detección de aves, esto se puede apreciar en las métricas precisión, recall, y F1-Score, pero se muestra que YOLOv11n optimiza de mejor manera la delimitación de cajas contenedoras bajo condiciones complejas.

Métrica	YOLOv8n	YOLOv26n	Elección	sig	sig vs 0,016
precisión	101,47	99,53	YOLOv8n	0,813	no
recall	120,73	80,27	YOLOv8n	7,69E-07	si
F1-Score	119,02	81,98	YOLOv8n	6,00E-06	si
mAP50	130,94	70,07	YOLOv8n	1,03E-13	si
mAP50-95	125,19	75,81	YOLOv8n	1,61E-09	si

Tabla 20: Estadísticos de la prueba de agrupación YOLOv8n vs YOLOv26n y comparación

En la tabla se puede apreciar que el modelo YOLOv8n es significativamente superior al modelo YOLOv26n. Si bien el modelo YOLOv26n en su métrica de precisión es significativamente mejor, el modelo YOLOv8n demuestra significativamente ser más eficiente tanto en capacidad de detección (Recall) como en la exactitud de la localización y delimitación de las aves.

Métrica	YOLOv11n	YOLOv26n	Elección	sig	sig vs 0,016
precisión	103,47	97,53	YOLOv11n	0,468	no
recall	115,98	85,02	YOLOv11n	1,55E-04	si
F1-Score	121,42	79,58	YOLOv11n	3,19E-07	si
mAP50	133,54	67,46	YOLOv11n	6,86E-16	si
mAP50-95	129,44	71,56	YOLOv11n	1,54E-12	si

Tabla 21: Estadísticos de la prueba de agrupación YOLOv11n vs YOLOv26n y comparación

En esta tabla se aprecia que el modelo YOLOv11n demuestra significativamente que es mejor que el modelo YOLOv26n. El análisis estadístico no paramétrico final, bajo la rigurosidad del umbral ajustado de Bonferroni revela que el modelo YOLOv11 en su métrica de precisión no es significativamente distinto de modelo YOLOv26n, pero en sus demás métricas si presenta diferencias significativas.

Comparación	Resultado
YOLOv8n vs YOLOv11n	Solamente el mAP50-90 favorece significativamente al modelo YOLOv11n
YOLOv8n vs YOLOv26n	El modelo YOLOv8n es significativamente mejor
YOLOv11n vs YOLOv26n	El modelo YOLOv11n es significativamente mejor

Tabla 22: Comparativa al cruzar los tres modelos analizados

Si bien el modelo YOLOv26n es el más actual queda demostrado significativamente que no presenta un desempeño eficiente al someterlo al conjunto de datos relacionado al análisis del comportamiento de pollos de engorde, siendo superado significativamente por los modelos YOLOv11n y YOLOv8n.

De tal manera la elección del modelo que se va a utilizar y cargar en el dispositivo es YOLOv8n como el modelo más óptimo para el sistema, su elección se fundamenta el análisis estadístico, al presentar una similitud entre las métricas contra su contraparte YOLOv11n, si bien el modelo YOLOv11n presenta una diferencia significativa en su métrica de mAP50-95, el modelo YOLOv8n demostró equivalencia estadística significativa frente a YOLOv11n en las métricas de rendimiento como la precisión con un valor de $p=0.596$ y el Recall con un valor $p=0.204$, además F1-Score con un valor $p=0.949$ y finalmente el mAP50 con un valor $p=0.030$. Al no existir diferencia estadísticamente significativa se concluye que tanto YOLOv8n como YOLOv11n trabajan de manera similar, por lo tanto, se pueden usar ambos para trabajar en la detección del comportamiento de pollos de engorde.

La elección final ahora se basa en la eficiencia computacional y de despliegue que presenta en dispositivos de bajo consumo. De tal manera se elige el modelo YOLOv8n al destacar por su ligereza gracias a que presenta una optimización de código, además al ser uno de sus primeros modelos, los desarrolladores cuentan con un amplio ecosistema de documentación, presentando así una estabilidad y un soporte que no solo presta la empresa, sino que también la comunidad.

4.1.1 Evaluación de la implementación de software



Ilustración 43: Prototipo en funcionamiento

En esta sección se presentan los resultados obtenidos tras la integración y despliegue del modelo YOLOv8n en el prototipo físico, evaluando su comportamiento operativo y analítico durante las pruebas de campo realizadas directamente en la galponera. Esta validación del sistema en un entorno real es importante para determinar la viabilidad del monitoreo continuo de los pollos de engorde.

Modelo Analizado	Especificaciones del modelo		
	Tamaño (MB)	Parámetros (M)	GFLOPs
YOLOv8n	6.1	3.2	8.7

Tabla 23: Especificaciones del modelo YOLOv8n

La Tabla 23: Especificaciones del modelo YOLOv8n muestra las características computacionales de la arquitectura seleccionada. El modelo YOLOv8n presenta un peso en disco de apenas 6.1 MB y está compuesto por 3.2 millones de parámetros, requiriendo 8.7 GFLOPs para su ejecución. Lo que reflejan estos valores es la capacidad del modelo para adaptarse al hardware, debido a su tamaño reducido el modelo se carga en la RAM sin generar cuellos de botella, esto garantiza que el procesamiento del modelo se realice de forma local.

Métrica	Métricas de Eficiencia de Hardware YOLOv8n			
	Media	Desviación estándar σ	Mín	Máx
Inferencia (ms)	78.71	7.65	70.5	112.5
FPS (Cuadros/seg)	5.69	0.25	4.7	6.0
CPU (%)	31.96	1.26	17.1	34.1
RAM (%)	13.03	0.28	12.8	14.4
Temperatura (°C)	52.09	3.12	45.2	58.4

Tabla 19: Métricas de eficiencia de Hardware implementado

La viabilidad técnica del prototipo se consolida en la Tabla 19: Métricas de eficiencia de Hardware implementado, donde se refleja el impacto del modelo sobre los recursos del sistema durante su operación continua. El sistema logró mantener un promedio de procesamiento de 5.69 FPS (cuadros por segundo) con una inferencia media de 78.71 milisegundos. Esto se debe a, que los patrones de movimiento de las aves, especialmente bajo condiciones de estrés, son relativamente lentos, una tasa cercana a los 6 FPS es completamente operativa y suficiente para el análisis temporal de su comportamiento.

Por otro lado, el consumo de recursos con una utilización media del 31.96% de la CPU y apenas un 13.03% de la RAM, justifica que el procesador mantiene un margen de trabajo adecuado. Esto quiere decir, que asegura que el sistema operativo y otros posibles subprocesos puedan ejecutarse en paralelo sin provocar bloqueos.

Uno de los puntos más importante es el análisis de la temperatura del *hardware*, puesto que de este depende y afecta el rendimiento del dispositivo, si bien se revela una media de 52.09 °C y un pico máximo de 58.4 °C. Estos valores demuestran una excelente disipación y estabilidad térmica en el equipo. Al mantenerse muy por debajo de los umbrales críticos del dispositivo lo que provocaría la reducción de frecuencia de reloj debido al sobrecalentamiento.

Todos estos puntos justifican que el prototipo es capaz de sostener jornadas de monitoreo prolongadas dentro de la galponera sin riesgo de degradación en su rendimiento o daños en sus componentes físicos.

Evaluación de la tasa de mortalidad detectada

Se realizó la evaluación de 35 imágenes específicas las cuales registran la detección del algoritmo y sus respectivas clases, además si el algoritmo cuenta la cantidad de aves correctas. Estos datos nacen de la interpretación del documento “Protocolo de validación técnica” facilitado por el Ph.D José Miranda zootecnista.

Los criterios de evaluación para etiquetar los resultados son:

Cuando el algoritmo cuenta una cantidad la mayoría de las aves dentro de la imagen se valora como 1, y cuando el algoritmo excluye un grupo considerable de aves se valora con 0.

Cuando el algoritmo genera correctamente las asignaciones de las clases se asigna un valor de 2, para la situación en que el algoritmo asigna parcialmente las clases y comete un grado de error se asigna un valor de 1 y en el caso de que el algoritmo presente una gran cantidad de fallas se asigna el valor de 0.

El apartado de observaciones es importante en la valoración del funcionamiento del sistema, este apartado determina si el algoritmo cumple con su función de detectar o no el comportamiento anómalo de los pollos de engorde en el entorno avícola.

Algoritmo	YOLOv8n		
	Cuenta	Asignación	Detecta
1	1	1	0
2	0	0	1
3	1	1	1
4	0	0	1
5	1	1	1
6	1	1	0
7	1	1	0
8	0	0	0
9	1	1	1
10	1	1	1
11	1	1	0
12	1	1	1
13	0	0	0
14	1	1	1
15	1	1	1
16	0	0	0
17	1	1	1
18	0	0	0
19	1	1	1
20	0	0	0
21	1	1	1

22	0	0	0
23	1	1	1
24	1	1	1
25	1	1	1
26	0	0	0
27	1	1	1
28	1	1	1
29	0	0	0
30	1	1	0
31	1	1	1
32	0	0	0
33	1	1	0
34	1	1	1
35	0	0	0

Tabla 24: Resultados interpretados del documento “Protocolo de validación técnica”

Para evaluar el desempeño del prototipo basado en el modelo YOLOv8n, se realizó un análisis de frecuencias absolutas y relativas sobre la muestra de 35 imágenes sometidas a análisis por el zootecnista. Si bien se trabajan con datos estadísticos descriptivos el algoritmo demuestra una capacidad mayoritaria para la localización espacial, logrando contabilizar la mayoría de las veces correctamente a los pollos (Cuenta=SI) en un 65.7% de los casos.

Cuenta					
		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	no	12	34,3	34,3	34,3
	si	23	65,7	65,7	100,0
	Total	35	100,0	100,0	
Asignación					
		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	no	12	34,3	34,3	34,3
	parcial	23	65,7	65,7	100,0
	Total	35	100,0	100,0	

Tabla 25: Tablas de frecuencia de las variables Cuenta y Asignación

Estas mismas proporciones se expresan en la variable de (Asignación=Parcial), esto propone que estas variables están altamente relacionadas en el funcionamiento del sistema.




Ilustración 44: Frecuencia de las variables Cuenta y Asignación

Si bien la eficiencia para diagnosticar anomalías representada por la variable (Detectar=SI) alcanza un 54,3%, frente a un 45.7% donde el sistema presenta un bajo rendimiento en la identificación del comportamiento.

Detecta					
		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	no	16	45,7	45,7	45,7
	si	19	54,3	54,3	100,0
	Total	35	100,0	100,0	

Tabla 26: Tabla de frecuencia de la variable Detecta




Ilustración 45: Frecuencia de la variable Detecta

Los resultados muestran que el algoritmo es robusto en tareas de visión básica como el conteo y la asignación de categorías, pero presenta una disminución de su rendimiento al momento de enfrentarse a una detección compleja.

Se debe tener en cuenta que el análisis se centra en proporciones y no en medianas, debido a las características de los datos no paramétricos se selecciona la prueba estadística de chi-cuadrado para evaluar la coherencia del modelo YOLOv8n. Se analiza las variables Detecta y Asigna, para lo cual se plantea la siguiente hipótesis.

Hipótesis Nula: No existe una relación estadística significativa entre la capacidad del modelo para clasificar o etiquetar correctamente a los individuos y su eficiencia general para detectar patrones de comportamiento en el entorno. Es decir, el rendimiento de clasificación es independiente del diagnóstico del sistema.

Hipótesis Alternativa: Existe una relación estadística significativa entre la capacidad del modelo para clasificar o etiquetar correctamente a los individuos y su eficiencia general para detectar patrones de comportamiento en el entorno. Es decir, el rendimiento de clasificación es dependiente de su precisión de clasificación.

Pruebas de chi-cuadrado			
	Valor	df	Significación asintótica (bilateral)
Chi-cuadrado de Pearson	10,413568	1	0,001251

Tabla 27: Prueba de Chi-Cuadrado

En este caso el valor de significancia es menor a 0.05 lo que me da como resultado el rechazo de la hipótesis nula donde las variables (Detecta y Asigna) tienen una relación estadísticamente significativa. Es decir que las variables no son independientes, esto se traduce en que si una variable se ve afectada automáticamente tiene un impacto en la otra. Esta evaluación demuestra que el algoritmo depende de forma directa de que su capa de predicción logre delimitar espacialmente a los individuos, puesto que, si logra observar e individualizar correctamente a los pollos, este logra detectar el comportamiento anómalo.

Ahora si bien el dispositivo junto con el modelo de reconocimiento funciona, al momento de someter el modelo a las grabaciones y especificar el frame en donde se identifican pollos que llegaron al estado de muerte, se presentan los siguientes datos:

Modelo	YOLOv8n	
ID imagen	Resul.	Eval
1	0	Fallo
2	1	Acierto
3	0	Fallo
4	0	Fallo
5	0	Fallo
6	0	Fallo
7	0	Fallo
8	1	Acierto
9	1	Acierto
10	0	Fallo
11	0	Fallo
12	1	Acierto
13	0	Fallo
14	0	Fallo
15	0	Fallo

Tabla 28: Detección de los pollos muertos

De los 31 pollos muertos en las últimas 2 semanas, el dispositivo registro 15 muertes, de las cuales, al someter las imágenes al modelo entrenado, 4 muertes fueron detectadas correctamente y 11 muertes no se detectaron.

Resumen			
Algoritmo	Aciertos	Fallos	%
YOLOv8n	4	11	26.67%

CAPÍTULO V.

5. CONCLUSIONES y RECOMENDACIONES

5.1 CONCLUSIONES

En base a los resultados experimentales, el análisis computacional y la validación, se formulan las siguientes conclusiones, las mismas dan respuesta a los objetivos planteados en la investigación.

Se logró estudiar e identificar los patrones etológicos de los pollos de engorde vinculados directamente a factores de riesgo como hipertermia, hipotermia y enfermedades locomotoras e índices de mortalidad dentro de una producción. El análisis permitió definir una clasificación clínica basada en tres categorías fundamentales: “good” (optimo) para aves en confort, “warning” (alerta) para individuos aislados o con decaimiento en la postura y “bad” (muerto) para la identificación de mortalidad. Esta clasificación permitió estructurar el etiquetado del Dataset y constituye la base zootécnica del sistema. La consulta al PhD. José Miranda validó que dichos patrones son observables y se puede distinguir visualmente.

Se evaluaron tres arquitecturas de la familia YOLO bajo condiciones idénticas de entrenamiento, es decir se realizaron 100 épocas, con un tamaño de imagen $\text{imgsz}=640$ y el procesamiento por lotes de $\text{batch}=16$. El análisis estadístico no paramétrico mediante Kruskal-Wallis y U-Mann-Whitney con corrección de Bonferroni demostró que YOLOv8n y YOLOv11n presentan equivalencia estadística en las métricas de precisión, Recall, F1-score y mAP50. Si bien la única diferencia significativa favoreció a YOLOv11n en mAP50-95 ($p=0.008$) en las demás métricas se aprecia similitud. Por lo tanto, YOLOv8n fue el modelo seleccionado por su menor complejidad para implementarlo y mayor eficiencia en hardware embebido, además de que su implementación cuenta con mayor documentación por parte de la comunidad y de Ultralytics.

En la siguiente etapa de la investigación se implementó un prototipo funcional basado en Raspberry Pi 5 con el modelo YOLOv8n ejecutándose en modo Edge Computing. El sistema demostró viabilidad técnica con una tasa de inferencia estable de 5.69 FPS, un consumo de CPU del 31.96% y una temperatura operativa máxima de 58.4°C, valores que se mantienen dentro de los límites seguros para operación continua. Esto confirma que hardware embebido de bajo costo puede soportar modelos de visión artificial para monitoreo avícola sin necesidad de aceleradores neuronales dedicados (GPU).

Si se evalúa la efectividad del prototipo, al realizar la validación con 35 imágenes analizadas por el zootecnista PhD. José Miranda reveló que el sistema logra contabilizar correctamente las aves en el 65.7% de los casos y detecta comportamiento anómalo en el 54.3%. La prueba Chi-cuadrado ($\chi^2=10.41$, $p=0.001$) confirmó una dependencia estadísticamente significativa entre la correcta delimitación espacial y la detección de anomalías. En cuanto a detección de mortalidad específica, el sistema identificó correctamente 4 de 15 eventos registrados (26.67%), esto muestra que la detección de pollos muertos representa la limitación del sistema actual, pero es un punto para mejorar en investigaciones futuras.

Si bien el sistema implementado constituye una herramienta funcional de monitoreo no invasivo que complementa la observación manual en granjas avícolas. Y los resultados estadísticos demuestran la capacidad de detección conductual, pero no una tasa baja de detección de mortalidad significativa, en base a mencionado se concluye que el sistema actúa como un apoyo al avicultor y no como un sustituto de la supervisión experta. La contribución principal de la investigación radica en la automatización del monitoreo continuo, reduciendo la necesidad de presencia física constante y permitiendo una intervención más oportuna ante patrones anómalos detectados.

5.2 RECOMENDACIONES

Se recomienda incorporar algoritmos de seguimiento temporal de objetos, tales como ByteTrack o BoT-SORT, acoplados al modelo YOLOv8n. Esto permitirá mantener la identidad individual de cada ave a lo largo de los fotogramas, reduciendo la fusión de cajas y los errores de conteo provocados por el hacinamiento natural en las zonas de comederos y bebederos.

Ampliar el conjunto de datos de entrenamiento incluyendo imágenes que contengan variaciones drásticas de luz como: visión nocturna, sombras proyectadas y escenarios con "suelo limpio" es decir no existan pollos y solo la presencia de viruta dispersa. Esto robustecerá los umbrales de confianza del modelo, evitando las falsas alarmas sanitarias reportadas en la validación zootécnica.

Desarrollar una fase experimental posterior que integre un módulo de notificaciones físicas, tener en cuenta las alertas vía mensajes.

BIBLIOGRAFÍA

- [1] La Carolina, «Sector avícola en Ecuador», La Colina. Accedido: 7 de julio de 2024. [En línea]. Disponible en: <https://lacolina.com.ec/sector-avicola-en-ecuador/>
- [2] C. D. Bacilio Quirumbay, «Evaluación de comportamiento productivo de pollos camperos con la sustitución de tres niveles de maíz (Zea mays) a la dieta», Titulación, Universidad Estatal Península de Santa Elena, La Libertad, 2021. [En línea]. Disponible en: <https://repositorio.upse.edu.ec/bitstream/46000/6424/1/UPSE-TIA-2021-0116.pdf>
- [3] M. Yerpes Ron, «Factores de riesgo asociados con la mortalidad de los pollos de engorde durante la primera semana de vida», Ph.D. Thesis, Universitat Autònoma de Barcelona, 2020. Accedido: 7 de julio de 2024. [En línea]. Disponible en: <https://www.tdx.cat/handle/10803/670986>
- [4] C. P. Torres-Vinueza, L. J. Ron-Garrido, y J. E. Grijalva-Olmedo, «Evaluación de factores de riesgo que afectan la mortalidad en pollos de engorde durante el proceso de traslado granja-planta de faenamiento en el centro norte de la región interandina», *Siembra*, vol. 8, n.º 1, pp. 1-12, 2021.
- [5] S. A. y P. Digital, «Inteligencia artificial y robótica de enjambres: la evolución de la avicultura». Accedido: 7 de julio de 2024. [En línea]. Disponible en: <https://soloavesyporcinos.com/nota/564077-inteligencia-artificial-y-robotica-de-enjambres-la-evolucion-de-la-avicultura-3>
- [6] G. C. Quiroz, A. C. Garrido, E. G. Licon, y E. L. Mejía, «Diseño e implementación de sistema de monitoreo automatizado en granja avícola», *Rev. Investig. En Tecnol. Inf.*, vol. 7, n.º 14, Art. n.º 14, oct. 2019, doi: 10.36825/RITI.07.14.011.
- [7] C. C. Solórzano, «Cifras de la producción avícola en Ecuador muestran cambios en el consumo de pollo y huevos, según Conave», *El Diario*. Accedido: 27 de enero de 2026. [En línea]. Disponible en: <https://www.eldiario.ec/negocios/cifras-de-la-produccion-avicola-en-ecuador-muestran-cambios-en-el-consumo-de-pollo-y-huevos-conave-21012026/>
- [8] «Información Sector Avícola Público - CONAVE». Accedido: 27 de enero de 2026. [En línea]. Disponible en: <https://conave.org/informacion-sector-avicola-publico/>
- [9] CONAVE, «Contexto ecuatoriano de la producción y comercialización de huevo - CONAVE». Accedido: 28 de enero de 2026. [En línea]. Disponible en: <https://conave.org/contexto-ecuatoriano-de-la-produccion-y-comercializacion-de-huevo/>
- [10] «Resolucion-0009-Instructivo-para-el-Proceso-de-Certificacion-de-Granjas-Avicolas-y-Plantas-de-Incubacion-Artificial-para-Aves-como-Libres-a-Mycoplasma.pdf». Accedido: 28 de enero de 2026. [En línea]. Disponible en: <https://www.agrocalidad.gob.ec/wp-content/uploads/2025/04/Resolucion-0009-Instructivo-para-el-Proceso-de-Certificacion-de-Granjas-Avicolas-y-Plantas-de-Incubacion-Artificial-para-Aves-como-Libres-a-Mycoplasma.pdf>
- [11] N. L. Ortiz Almeida, «Implementación de procedimientos operativos estandarizados de saneamiento (POES) en granja avícola experimental», dic. 2023, Accedido: 28 de enero de 2026. [En línea]. Disponible en: <https://hdl.handle.net/20.500.12494/54094>
- [12] «Agrocalidad – Agencia de Regulación y Control Fito y Zoonosanitario». Accedido: 22 de mayo de 2026. [En línea]. Disponible en: <https://www.agrocalidad.gob.ec/>
- [13] O. W. A. Vásquez y F. R. A. Morocho, «Análisis de la Industria 4.0 como factor diferenciador del Sector Industrial del Ecuador», *Cienc. Lat. Rev. Científica Multidiscip.*, vol. 5, n.º 3, Art. n.º 3, jun. 2021, doi: 10.37811/cl_rcm.v5i3.533.

- [14] J. A. Villa Yuquilema, «Diseño e implementación de un sistema inteligente basado en visión artificial para el monitoreo y prevención de robos en tiempo real en la farmacia Pharmatodo de la ciudad de Riobamba», bachelorThesis, Riobamba, 2025. Accedido: 27 de marzo de 2026. [En línea]. Disponible en: <http://dspace.unach.edu.ec/handle/51000/14493>
- [15] M. Campbell *et al.*, «A computer vision approach to monitor activity in commercial broiler chickens using trajectory-based clustering analysis», *Comput. Electron. Agric.*, vol. 217, p. 108591, feb. 2024, doi: 10.1016/j.compag.2023.108591.
- [16] O. M. Oso *et al.*, «Automatic analysis of high, medium, and low activities of broilers with heat stress operations via image processing and machine learning», *Poult. Sci.*, vol. 104, n.º 4, p. 104954, abr. 2025, doi: 10.1016/j.psj.2025.104954.
- [17] J. M. Massari, D. J. de Moura, I. de Alencar Nääs, D. F. Pereira, y T. Branco, «Computer-Vision-Based Indexes for Analyzing Broiler Response to Rearing Environment: A Proof of Concept», *Animals*, vol. 12, n.º 7, p. 846, ene. 2022, doi: 10.3390/ani12070846.
- [18] G. Brugaletta, J.-R. Teyssier, S. J. Rochell, S. Dridi, y F. Sirri, «A review of heat stress in chickens. Part I: Insights into physiology and gut health», *Front. Physiol.*, vol. 13, p. 934381, ago. 2022, doi: 10.3389/fphys.2022.934381.
- [19] O. O. Apalowo, D. A. Ekunseitan, y Y. O. Fasina, «Impact of Heat Stress on Broiler Chicken Production», *Poultry*, vol. 3, n.º 2, pp. 107-128, jun. 2024, doi: 10.3390/poultry3020010.
- [20] R. S. Sánchez, «MONOGRAFÍA BIBLIOGRÁFICA: PRESENTADA COMO REQUISITO PARCIAL PARA OBTENER EL TÍTULO DE»:.
- [21] S. Reaño Montoro y D. Mateos Costilla, «Streaming de Audio/Video. Protocolo RTSP», *Enginyeps Rev. Esc. Politècnica Super.*, n.º 1, pp. 15-18, 2008.
- [22] A. Calo Giménez, «Implementación de un sistema de seguridad y control de accesos», Trabajo final de grado, Universidad Politècnica de Catalunya, 2025. Accedido: 15 de febrero de 2026. [En línea]. Disponible en: <https://upcommons.upc.edu/entities/publication/90e5b6d9-6fc8-4adb-aa95-ec6b3cad7317>
- [23] D. M. Alcívar Mendoza y R. E. Vera Olmedo, «Implementación de un sistema de seguridad con sensores de movimiento y cámaras IP.», 2025, Accedido: 14 de febrero de 2026. [En línea]. Disponible en: <https://repositorio.uleam.edu.ec/handle/123456789/9885>
- [24] J. Redmon, S. Divvala, R. Girshick, y A. Farhadi, «You Only Look Once: Unified, Real-Time Object Detection», 9 de mayo de 2016, *arXiv*: arXiv:1506.02640. doi: 10.48550/arXiv.1506.02640.
- [25] J. Redmon y A. Farhadi, «YOLO9000: Better, Faster, Stronger», 25 de diciembre de 2016, *arXiv*: arXiv:1612.08242. doi: 10.48550/arXiv.1612.08242.
- [26] A. Bochkovskiy, C.-Y. Wang, y H.-Y. M. Liao, «YOLOv4: Optimal Speed and Accuracy of Object Detection», 23 de abril de 2020, *arXiv*: arXiv:2004.10934. doi: 10.48550/arXiv.2004.10934.
- [27] Ultralytics, «Explore Ultralytics YOLOv8». Accedido: 24 de febrero de 2026. [En línea]. Disponible en: <https://docs.ultralytics.com/es/models/yolov8/>
- [28] «What is YOLOv8: An In-Depth Exploration of the Internal Features of the Next-Generation Object Detector». Accedido: 10 de mayo de 2026. [En línea]. Disponible en: <https://arxiv.org/html/2408.15857v1>
- [29] «Pruning and Quantization in Computer Vision | Ultralytics». Accedido: 10 de mayo de 2026. [En línea]. Disponible en: <https://www.ultralytics.com/blog/pruning-and-quantization-in-computer-vision-a-quick-guide>

- [30] «ultralytics/docs/en/models/yolov8.md at main · ultralytics/ultralytics», GitHub. Accedido: 10 de mayo de 2026. [En línea]. Disponible en: <https://github.com/ultralytics/ultralytics/blob/main/docs/en/models/yolov8.md>
- [31] «Detectores sin anclaje en la detección de objetos | Ultralytics». Accedido: 10 de mayo de 2026. [En línea]. Disponible en: <https://www.ultralytics.com/es/glossary/anchor-free-detectors>
- [32] «Data Augmentation using Ultralytics YOLO», Ultralytics Docs. Accedido: 10 de mayo de 2026. [En línea]. Disponible en: <https://docs.ultralytics.com/guides/yolo-data-augmentation>
- [33] «Ultralytics YOLO Hyperparameter Tuning Guide», Ultralytics Docs. Accedido: 10 de mayo de 2026. [En línea]. Disponible en: <https://docs.ultralytics.com/guides/hyperparameter-tuning>
- [34] B. Sharma, «YOLOv26: An Object Detector Built for Real-Time Deployment». Accedido: 11 de mayo de 2026. [En línea]. Disponible en: <https://learnopencv.com/yolov26-real-time-deployment/>
- [35] «YOLO26: YOLO Model for Real-Time Vision AI [2026]», Roboflow Blog. Accedido: 11 de mayo de 2026. [En línea]. Disponible en: <https://blog.roboflow.com/yolo26/>
- [36] «Ultralytics YOLO26», Ultralytics Docs. Accedido: 11 de mayo de 2026. [En línea]. Disponible en: <https://docs.ultralytics.com/models/yolo26>
- [37] «YOLO26: Key Architectural Enhancements and Performance Benchmarking for Real-Time Object Detection», ar5iv. Accedido: 11 de mayo de 2026. [En línea]. Disponible en: <https://ar5iv.labs.arxiv.org/html/2509.25164>
- [38] «Ultralytics YOLO11», Ultralytics Docs. Accedido: 30 de mayo de 2026. [En línea]. Disponible en: <https://docs.ultralytics.com/models/yolo11>
- [39] «ultralytics/ultralytics/cfg/models/11/yolo11.yaml at main · ultralytics/ultralytics», GitHub. Accedido: 2 de junio de 2026. [En línea]. Disponible en: [https://github.com/ultralytics/ultralytics/blob/main/ultralytics/cfg/models/11/yolo11.y aml](https://github.com/ultralytics/ultralytics/blob/main/ultralytics/cfg/models/11/yolo11.yaml)
- [40] «YOLOv11: An Overview of the Key Architectural Enhancements». Accedido: 2 de junio de 2026. [En línea]. Disponible en: <https://arxiv.org/html/2410.17725v1>

ANEXOS




Ilustración 46: Bitácora de mortalidad en la crianza de pollos

image21.jpg	SI	Parcial	Seguimiento de calidad en individuos cercanos. Pierde la visión de conjunto al ignorar el fondo del galpón.
image22.jpg	No	No	Muestra interacción social en comedero. La fusión de cajas subestima la competencia por el recurso alimenticio.
image23.jpg	SI	Parcial	Diferencia actividad de reposo. La inconsistencia en etiquetas debilita la detección temprana de letargo.
image24.jpg	SI	Parcial	Intento de mapeo espacial del lote. Las cajas vacías generan errores en el mapa de calor de ocupación.
image25.jpg	SI	Parcial	Captura la masa poblacional con éxito. La saturación de etiquetas impide un análisis de bienestar individualizado.
image26.jpg	No	No	Identifica ave frontal con alta confianza. La incapacidad de separar siluetas en contacto oculta problemas de densidad.
image27.jpg	SI	Parcial	Crítico acierto en detección de mortalidad en exteriores. La confusión con el descanso afecta el índice de supervivencia.
image28.jpg	SI	Parcial	Reconoce aves en confort lumínico. Omite zonas de sombra, críticas para detectar amontonamientos por frío.
image29.jpg	No	No	Operación funcional bajo visión nocturna. La baja precisión actual impide auditar el ciclo de descanso del lote.
image30.jpg	SI	Parcial	Procesa el hacinamiento visual. La falta de etiquetado central subestima el estrés por competencia de espacio.
image31.jpg	SI	Parcial	Detección de individuos en comedero. El 'efecto fantasma' genera errores en el algoritmo de flujo de movimiento.
image32.jpg	No	No	Capta individuos cercanos con claridad. El error de escala impide medir el crecimiento fenotípico real.
image33.jpg	SI	Parcial	Registra reposo activo de forma estable. La división arbitraria dificulta la detección de cuadros de apatía.
image34.jpg	SI	Parcial	Identifica aves bajo oclusión parcial. El sistema pierde eficiencia en zonas de alta interferencia física.
image35.jpg	No	No	Detección activa en todo el frame. El error visual de etiqueta duplicada indica inestabilidad lógica.

Confiabilidad del prototipo expresada en porcentaje 60%



Escanea para validar la firma

JOSE EFRAIN MIRANDA

YUQUILEMA

Dr. José Efraín Miranda-Yuquilema, Ph.D.

Validador

Ilustración 47: Firma del documento “Protocolo de validación técnica” que avala el diagnostico visual y la capacidad de detección del modelo de 35 imágenes