



UNIVERSIDAD TÉCNICA DE MACHALA

FACULTAD DE INGENIERÍA CIVIL

MAESTRÍA EN SOFTWARE - COHORTE III

**DESARROLLO DE UN PROTOTIPO DE BAJO COSTO PARA LA
IDENTIFICACIÓN Y CLASIFICACIÓN DE HUEVOS DE GALLINA CON UN
SISTEMA INTELIGENTE DE APRENDIZAJE PROFUNDO**

AUTOR:

Ing. Milton Genaro Benavides Duran

TUTOR:

DR. IVAN RAMÍREZ MORALES, PH. D.

COTUTOR:

ING. WILMER RIVAS ASANZA, PH. D.

MACHALA

2025

PENSAMIENTO

“Mi cerebro es solo un receptor, en el universo hay un núcleo del cual obtenemos conocimiento, fuerza e inspiración”

- Nikola Tesla

DEDICATORIA

Le dedico este trabajo a mi familia en especial a mis hijos quienes son el motivo por el cual busco superarme, seguir adelante e investigar en lo que me apasiona; en primer lugar, ser agradecido con quienes han estado conmigo en mis buenos y malos momentos, ser fiel a mis principios e inculcar en quienes siguen nuestros pasos el afán de ser mejores, contribuir con el desarrollo a nuestro alrededor y alcanzar nuestras metas.

Milton Benavides

RESPONSABILIDAD DE AUTORÍA

Yo, Ing. Milton Genaro Benavides Duran con C.C./C.I./Pasaporte 070358371-6, declaro que el trabajo de “DESARROLLO DE UN PROTOTIPO DE BAJO COSTO PARA LA IDENTIFICACION Y CLASIFICACION DE HUEVOS DE GALLINA CON UN SISTEMA INTELIGENTE DE APRENDIZAJE PROFUNDO”, en opción al título de Magister en Software, es original y auténtico; cuyo contenido: conceptos, definiciones, datos empíricos, criterios, comentarios y resultados son de mi exclusiva responsabilidad.

Atentamente.

Milton Genaro Benavides Duran

C.I. 070358371-6

Machala, 14 de Marzo del año 2025.

REPORTE DE SIMILITUD DE COMPILATIO



CERTIFICADO DE ANÁLISIS
magister

EGG_TURNITING_F

2%
Textos sospechosos



1% Similitudes
0% similitudes entre comillas
0% entre las fuentes mencionadas
< 1% Idiomas no reconocidos

Nombre del documento: EGG_TURNITING_F.docx
ID del documento: 4562fd5efe47d826bad9caca9454acd06f70f22
Tamaño del documento original: 15,08 MB
Autores: []

Depositante: IVAN RAMIREZ MORALES
Fecha de depósito: 15/1/2025
Tipo de carga: interface
fecha de fin de análisis: 15/1/2025

Número de palabras: 13.535
Número de caracteres: 86.615

Ubicación de las similitudes en el documento:



Fuentes principales detectadas

N°	Descripciones	Similitudes	Ubicaciones	Datos adicionales
1	www.innovatrics.com Reconocimiento Facial - Definición, Preguntas frecuentes- In... 2 fuentes similares	< 1%		Palabras idénticas: < 1% (55 palabras)
2	www.ibm.com ¿Qué es el etiquetado de datos? IBM https://www.ibm.com/es/es/topics/data-labeling	< 1%		Palabras idénticas: < 1% (44 palabras)

Fuentes con similitudes fortuitas

N°	Descripciones	Similitudes	Ubicaciones	Datos adicionales
1	Documento de otro usuario #30be7a El documento proviene de otro grupo	< 1%		Palabras idénticas: < 1% (12 palabras)
2	Documento de otro usuario #86fa83 El documento proviene de otro grupo	< 1%		Palabras idénticas: < 1% (11 palabras)
3	Documento de otro usuario #2314f5 El documento proviene de otro grupo	< 1%		Palabras idénticas: < 1% (10 palabras)
4	repository.usta.edu.co https://repository.usta.edu.co/bitstream/11634/58083/3/2024camiloandresmelotayo.pdf	< 1%		Palabras idénticas: < 1% (10 palabras)

CERTIFICACIÓN DEL TUTOR

Yo, DR. IVAN RAMÍREZ MORALES, PH. D. con C.C./C.I./Pasaporte 070405590-3, declaro que el trabajo titulado: "DESARROLLO DE UN PROTOTIPO DE BAJO COSTO PARA LA IDENTIFICACION Y CLASIFICACION DE HUEVOS DE GALLINA CON UN SISTEMA INTELIGENTE DE APRENDIZAJE PROFUNDO", en opción al título de Magister en Software, ha sido revisado, enmarcado en los procedimientos científicos, técnicos, metodológicos y administrativos establecidos por el Centro de Posgrado de la Universidad Técnica de Machala (UTMACH), razón por la cual doy fe de los méritos suficientes para que sea presentado a evaluación.

Atentamente.

Ivan Ramírez Morales, Ph. D.

C.I. 070406590-3

Machala, 14 de Marzo del año 2025.

CERTIFICACIÓN DEL COTUTOR

Yo, ING. WILMER RIVAS ASANZA, PH. D. con C.C./C.I./Pasaporte, 070258019-2, declaro que el trabajo titulado: "DESARROLLO DE UN PROTOTIPO DE BAJO COSTO PARA LA IDENTIFICACION Y CLASIFICACION DE HUEVOS DE GALLINA CON UN SISTEMA INTELIGENTE DE APRENDIZAJE PROFUNDO", en opción al título de Magister en Software, ha sido revisado, enmarcado en los procedimientos científicos, técnicos, metodológicos y administrativos establecidos por el Centro de Posgrado de la Universidad Técnica de Machala (UTMACH), razón por la cual doy fe de los méritos suficientes para que sea presentado a evaluación.

Atentamente.

Ing. Wilmer Rivas Asanza Mg. Sc.

C.I. 070258019-2

Machala, 14 de Marzo del año 2025.

CESIÓN DE DERECHOS DEL AUTOR

Yo, Ing. Milton Genaro Benavides Duran con C.C./C.I./Pasaporte 070358371-6, declaro que el trabajo de “DESARROLLO DE UN PROTOTIPO DE BAJO COSTO PARA LA IDENTIFICACION Y CLASIFICACION DE HUEVOS DE GALLINA CON UN SISTEMA INTELIGENTE DE APRENDIZAJE PROFUNDO”, en opción al título de Magíster En Software III, declaro bajo juramento que:

- El trabajo aquí descrito es de mi autoría, que no ha sido presentado previamente para ningún grado o calificación profesional. En consecuencia, asumo la responsabilidad de la originalidad del mismo y el cuidado al remitirse a las fuentes bibliográficas respectivas para fundamentar el contenido expuesto, asumiendo la responsabilidad frente a cualquier reclamo o demanda por parte de terceros de manera exclusiva.

- Cedo a la Universidad Técnica de Machala de forma o exclusiva con referencia a la obra en formato digital los derechos de:

- a. Incorporar la mencionada obra en el repositorio Institucional para su democratización a nivel mundial, respetando lo establecido por la Licencia Creative Commons Attribution-No Comercial – Compartir igual 4.0 Internacional (CC BY NCSA 4,0); la Ley de Propiedad Intelectual del Estado Ecuatoriano y el Reglamento Institucional.

- b. Adecuarla a cualquier formato o tecnología de uso en INTERNET, así como correspondiéndome como Autora la responsabilidad de velar por dichas adaptaciones con la finalidad de que no se desnaturalice el contenido o sentido de la misma.

Milton Genaro Benavides Duran

CC. 070358371-6

ÍNDICE DE CONTENIDOS

Contenido

PENSAMIENTO	2
DEDICATORIA	3
RESPONSABILIDAD DE AUTORÍA	4
REPORTE DE SIMILITUD DE COMPILATIO	5
CERTIFICACIÓN DEL TUTOR.....	6
CERTIFICACIÓN DEL COTUTOR	7
CESIÓN DE DERECHOS DEL AUTOR.....	8
ÍNDICE DE CONTENIDOS	9
ÍNDICE DE FIGURAS.....	11
ÍNDICE DE TABLAS	12
ÍNDICE DE ANEXOS	13
RESUMEN	14
ABSTRACT.....	15
INTRODUCCIÓN	16
1. CAPÍTULO 1. MARCO TEÓRICO.....	23
1.1. Antecedentes Históricos.....	23
1.2. Antecedentes Referenciales	24
1.2.1. Preguntas de investigación.....	24
1.2.2. Palabras claves y cadenas de búsquedas.....	25
1.2.3. Criterios de inclusión y exclusión.....	25
1.2.4. Proceso y resultado de la búsqueda	26
1.2.5. Establecimiento de requerimientos	27
1.2.6. Contexto del problema.....	28

1.3.	Antecedentes conceptuales	29
1.3.1.	Antecedentes conceptuales de la variable dependiente	29
1.3.2.	Fundamentación Teórica De La Variable Independiente	29
1.4.	Antecedentes Contextuales	36
1.4.1.	Trabajos Previos.....	36
2.	CAPÍTULO II. METODOLOGÍA Y POBLACIÓN.....	39
2.1.	Tipo de estudio.....	39
2.1.1.	Tipo de investigación.....	40
2.2.	Paradigma	40
2.3.	Población y muestra.....	41
2.4.	Métodos empíricos utilizados	41
2.5.	Técnicas estadísticas para el procesamiento de datos.....	42
2.6.	Metodología CRISP-DM	43
3.	CAPÍTULO III. RESULTADOS.....	44
3.1.	Fase de comprensión del negocio	44
3.2.	Fase de comprensión de datos.....	45
3.3.	Fase de preparación de datos	45
3.4.	Fase de modelado.....	46
3.5.	Fase de evaluación	47
3.6.	Fase de despliegue	59
3.7.	Presupuesto	60
	CAPÍTULO IV: DISCUSIÓN DE RESULTADOS.....	62
4.1	Diseño de pruebas	62
4.1.1.	Métricas de evaluación	62
4.2.	Resultados.....	63

4.3. Prueba de hipótesis para proporciones.....	65
4.3.1. Criterio de selección del estadístico.....	66
4.3.2. Conclusión de la prueba de hipótesis.....	67
4.4. Discusión de resultados.....	67
CONCLUSIONES	72
RECOMENDACIONES.....	74
Consideraciones futuras	74
BIBLIOGRAFÍA	76
ANEXOS	81

ÍNDICE DE FIGURAS

<i>Figura 1. Resumen de hitos históricos de la visión por computadora</i>	24
Figura 2. Fotograma usado para entrenar a la IA mediante YoloV8	28
Figura 3. Redes neuronales artificiales	30
Figura 4. Esquema de una red neuronal artificial.	33
Figura 5. NVIDIA Jetson Orin Nano Developer Kit	34
<i>Figura 6. Proceso de comprensión del negocio</i>	44
Figura 7. Cantidad de fotogramas por categoría.....	46
Figura 8. Tipo de red neuronal empleada en el proyecto.....	46
Figura 9. Entrenamiento de la IA mediante modelo de aprendizaje.....	47
Figura 10. Evaluación del modelo entrenado en la detección de huevos de gallina.....	48
Figura 11. Puesta en marcha del modelo entrenado (ejecutable) con imágenes.....	49
Figura 12. Captura de los huevos de gallina en la banda transportadora.....	50
<i>Figura 13. Etiquetado por colores de cada clase de huevo de gallina</i>	50
<i>Figura 14. Proceso de etiquetado manual por color de cada clase de huevo.....</i>	51
<i>Figura 15. Clasificación de los huevos por etiquetado en el software de programación</i>	52
<i>Figura 16. Depuración del código de entrenamiento en Visual Studio Code.....</i>	52

<i>Figura 17. Ejemplo del modelo importado.....</i>	53
<i>Figura 18. Proceso de aumentación con volteo vertical.</i>	53
<i>Figura 19. Opciones de imágenes en el modelo de entrenamiento</i>	54
<i>Figura 20. Fotogramas de entrenamiento (matriz de 33468 imágenes)</i>	55
<i>Figura 21. Estadísticas de la visión por computadora 274617 objetos (huevos clasificados)</i>	56
<i>Figura 22. Configuraciones de lotes para los entrenamientos.....</i>	57
<i>Figura 23. Datos de la tarjeta gráfica del prototipo (AMD Ryzen 7 5700G, 3.8 Ghz) a 32 Gb RAM Instalada</i>	58
<i>Figura 24. Prueba del aplicativo y verificación del modelo de predicción</i>	59
<i>Figura 25. Matriz de confusión para huevos rotos (azules)</i>	63
<i>Figura 25. Matriz de confusión expresada en curvas de probabilidades.....</i>	64
<i>Figura 27. Métricas resultantes del proceso de aprendizaje (probabilidad y nivel de confianza)</i>	65
<i>Figura 28. Zona de rechazo en función del estadístico Z</i>	66

ÍNDICE DE TABLAS

Tabla 1. Resultados del proceso de búsqueda de contenidos.....	26
Tabla 2. Variables y unidades empleadas en el desarrollo del prototipo.....	39
Tabla 3. Recursos necesarios para fabricar el prototipo	60
Tabla 4. Comparación de resultados en investigaciones similares	70

ÍNDICE DE ANEXOS

Anexo 1. Curvas de precisión del modelo de clasificación de huevos de gallina	81
Anexo 2. Prueba del prototipo en campo junto al tutor del proyecto	82
Anexo 3. Instalación del prototipo en sitio (banda transportadora de huevos)	83
Anexo 4. Evidencia de haber probado y entrenado el prototipo.....	83
Anexo 5. Vista de la banda transportadora y recibidora de huevos.....	84
Anexo 6. Vista del proceso de clasificación de huevos en la granja	84
Anexo 7. Producción total diaria de huevos (36449 por hora) hasta 136000 al día	85
Anexo 8. Datos de la producción neta de huevos (con sangre, por peso, líneas y descartados)...	85
Anexo 9. Proceso de aumentación de imágenes en el modelo de entrenamiento.....	86
Anexo 10. Evaluación del modelo entrenado mediante imágenes de huevos de gallina	87

RESUMEN

La evolución de la tecnología y la infraestructura digital ha hecho posible que las inteligencias artificiales (IA) se utilicen como herramientas eficaces para resolver problemas industriales, permitiendo una mejor optimización de recursos. Este estudio surge ante la necesidad de clasificar huevos de gallina en granjas avícolas locales, una tarea que normalmente realiza un inspector, pero que puede estar expuesta a errores o subjetividades debido a la fatiga, considerando que el humano mantiene entre 60% a 90% de probabilidad de error frente a un 3% de las máquinas. El objetivo principal es desarrollar un prototipo de aplicación que utilice redes neuronales profundas, ejecutadas en hardware NVIDIA Jetson Orin Nano para una clasificación automática eficiente de huevos de gallina. Se aplicó una metodología cuantitativa, del tipo cuasiexperimental al operar variables como cantidad de huevos, imágenes, porcentajes y clases; el tipo de estudio es empírico al ser un proceso sistemático e iterativo englobando la data, esquema de entrenamiento, programación, evaluación y puesta a prueba del modelo. La metodología *CRISP-DM* se aplicó para comprender el negocio junto a los requerimientos del prototipo. La población son todos los huevos procesados en una hora (36000) y la muestra son los huevos que pasan en dos minutos por la cinta transportadora alrededor de 1200 tomando 200 fotogramas como base para el modelo de aprendizaje. En los resultados se destaca que el nivel de precisión al detectar/clasificar huevos de gallina en sano (verde), sucio (rojo), roto (morado) y rugoso (azul) es mayor al 95% logrando un desempeño del 99% de efectividad cumpliendo con el objetivo del estudio. El prototipo desarrollado en hardware NVIDIA soporta la red neuronal You Only Look Once (Yolo V8n) empleada para ver y clasificar los huevos con un presupuesto de bajo costo en contraste con soluciones industriales disponibles en el mercado; llegando a ser alrededor del 10% de una máquina comercial capaz de realizar mismo proceso; además, destaca por su escalabilidad, adaptación y bajo consumo energético; por lo tanto, es una solución práctica que satisface los requerimientos de diseño demostrando a través de la discusión que se obtienen resultados similares en investigaciones de visión por computadora al utilizar Yolo para clasificar objetos e inclusive estudiar patrones de movimiento en seres vivos.

Palabras Clave: YoloV8, prototipo, clasificación, huevos de gallina, Jetson Orin Nano.

ABSTRACT

The evolution of technology and digital infrastructure has made it possible for artificial intelligence (AI) to be used as effective tools to solve industrial problems, allowing better optimization of resources. This study arises from the need to classify chicken eggs in local poultry farms, a task that is normally carried out by an inspector, but which can be exposed to errors or subjectivities due to fatigue, considering that humans maintain between 60% to 90% probability of error compared to 3% for machines. The main objective is to develop a prototype application that uses deep neural networks, executed on NVIDIA Jetson Orin Nano hardware for efficient automatic classification of chicken eggs. A quantitative methodology is applied, of the quasi-experimental type by operating variables such as number of eggs, images, percentages and classes; The type of study is empirical as it is a systematic and iterative process encompassing data, training scheme, programming, evaluation and testing of the model. The CRISP-DM methodology was applied to understand the business along with the prototype requirements. The population is all the eggs processed in one hour (36,000) and the sample is the eggs that pass through the conveyor belt in two minutes, around 1,200, taking 200 frames as a basis for the learning model. The results highlight that the level of precision when detecting/classifying chicken eggs into healthy (green), dirty (red), broken (yellow) and rough (blue) is greater than 95%, achieving a performance of 99% effectiveness, meeting the objective of the study. The prototype developed on NVIDIA hardware supports the You Only Look Once (Yolo V8n) neural network used to view and classify eggs with a low-cost budget in contrast to industrial solutions in between; becoming around 10% of a commercial machine capable of carrying out the same process; Furthermore, it stands out for its scalability, adaptation and low energy consumption; Therefore, it is a practical solution that satisfies the design requirements, demonstrating through the discussion that similar results are obtained in computer vision research when using Yolo to classify objects and even study movement patterns in living beings.

Keywords: YoloV8, prototype, classification, chicken eggs, Jetson Orin Nano.

INTRODUCCIÓN

Desde tiempos antiguos, el huevo de gallina (*Gallus gallus domesticus*) ha sido un alimento fundamental para la humanidad, cuyo consumo se ha expandido globalmente, impulsando una actividad económica particular. Los productores de huevos de gallina constituyen un sector específico dentro de la ganadería y la industria alimentaria. Aunque también se comercializan huevos de otras especies como pato, codorniz y avestruz, estos no alcanzan la misma importancia económica que los huevos de gallina [1]. Desde su concepción formal la lengua española caracteriza al huevo como un cuerpo redondo, con forma, dureza y tamaño variable puestos por aves para proteger sus embriones; sin embargo, en lo referente al huevo de gallina, es el más consumido por el ser humano, se produce en granjas avícolas mediante un proceso industrializado, donde se requiere clasificarlos para ser comercializados; a nivel general su producción en masa se intensificó a mediados de la década de los 70 cuando fue incluido en la dieta cotidiana de los hogares [2].

En [3] refiere que en el Ecuador el tercer viernes de marzo se festeja el día del huevo de mesa, en honor a sus beneficios e impacto socioeconómico en el sector, siendo fuente de empleo, nutrientes e ingrediente gastronómico local; de igual forma en [4] en un informe de la Corporación Nacional de Avicultores del Ecuador (CONAVE) indica que en el 2022 fueron vendidos 3.8 millones de huevos, un ciudadano promedio consume 212 huevos por año, donde más se produce son en la sierra con el 62% y en la costa con el 22% de la producción.

En la agricultura e industria alimenticia, clasificar los productos es esencial al mantener las características y propiedades adecuadas para ser comercializados; sin embargo, en la Universidad Miguel Hernández de Elche (España) [5] indica que la clasificación manual está sujeta a la interpretación y subjetividad del clasificador de huevos en contraste con la clasificación por redes neuronales. Además, diferentes personas pueden tener criterios diferentes para identificar y clasificar los tipos de huevo, lo que puede resultar en discrepancias y falta de consistencia en los resultados. Además, incluso para un clasificador individual, puede haber variabilidad en la clasificación debido a factores como la fatiga visual y la experiencia.

Hoy en día existe una variedad de algoritmos de aprendizaje automático, pero no todos tienen la misma precisión, especialmente en la clasificación de tipos de huevo, una actividad que requiere de gran precisión. Ante ello, es necesario investigar cómo funcionan para este tipo de producto en particular [6]. En su investigación en [6] propone técnicas de clasificación de huevos basadas en imágenes de cáscaras de huevo utilizando el clasificador K-Nearest Neighbors (KNN) basado en dos extracciones de características, a saber, la extracción de características de color del valor de saturación de tono (HSV) y la matriz de concurrencia de nivel de grises (GLCM). El experimento se llevó a cabo utilizando 100 imágenes de huevos de tres clases: huevos de buena calidad, podridos y defectuosos. De las 100 imágenes, se utilizaron 21 como imágenes de prueba y el resto como imágenes de entrenamiento. La prueba se realizó con los valores de los parámetros $k = 1, 3$ y 9 , mientras que la distancia utilizada para cada k fue $1, 2$ y 4 . Entre los hallazgos se destaca que la mayor precisión de $85,71\%$, donde el valor del parámetro $k = 1; d = 2$ y $k = 1; d = 4$.

Hoy en día las máquinas clasificadoras de huevos existentes en el mercado miden el peso en un flujo, luego lo separan en clases por rangos de gramos y finalmente alinean en la cinta transportadora; este proceso no es del todo automatizado siendo lento e incluso tedioso; por ende, es posible ponderar su peso partiendo de su geometría empleando métodos numéricos; a su vez en [5] refiere que la visión computarizada permite no solo dar un aproximado del peso sino detectar otras cualidades a través del uso de redes neuronales entrenadas para dicha finalidad.

Las limitaciones de los trabajos anteriores están en la tecnología a emplear, a diferencia de las inteligencias artificiales las máquinas clasificadoras como modelo Forta Gt ocupan mucho espacio, no son escalables, solo hacen secuencias preprogramadas y el costo es elevado siendo poco factible para granjas locales; por lo tanto, es de suma relevancia innovar en soluciones accesibles para la industria avícola local.

En este estudio en el ámbito de la minería de datos, se emplea la metodología CRISP-DM (Cross Industry Standard Process for Data Mining) misma que es un referente en el medio gracias a sus prestaciones durante el desarrollo. Según en [7] este proceso se caracteriza por los siguientes pasos:

- ❖ **Comprensión del negocio:** Se caracteriza el contexto y enfoque del estudio, en este caso lo relacionado con la clasificación de imágenes de tipos de huevo. Se identifican los requisitos y criterios de éxito.

- ❖ **Comprensión de los datos:** Se levante la información más relevante e incluye imágenes a utilizar en el modelo. Se realiza un análisis de los datos para organizarlos, decidir cómo usarlos y mejorar la precisión de las variables.
- ❖ **Preparación de los datos:** Comprende escoger, filtrar y refinar los datos al formar el esquema de entrenamiento mediante las imágenes obtenidas en campo de los tipos de huevos. También se pueden realizar tareas de aumento de datos o mejora de la calidad de las imágenes.
- ❖ **Modelado:** Se entrena a la IA, analiza cómo responde y las épocas de aprendizaje, como redes neuronales convolucionales (CNN), para entrenar un modelo que pueda clasificar las imágenes de los tipos de huevos.

Se realizan pruebas y ajustes para mejorar el rendimiento del modelo.

- ❖ **Evaluación:** se utilizan indicadores al medir su nivel de aceptación, falsos positivos, probabilidad y cumplimiento de los requerimientos de diseño.
- ❖ **Despliegue:** Se pone en marcha el prototipo al clasificar imágenes de tipos de huevos en un entorno operativo. Se documenta el proceso y se realiza un seguimiento del rendimiento del modelo a medida que se utiliza en la práctica.

La razón que justifica el estudio es el grado de dificultad y precisión en la clasificación de huevos, proceso que se puede automatizar mediante el uso de inteligencia artificial; el huevo al ser un alimento de la canasta básica debe estar presente en tiendas, minimarkets y ser distribuido mientras menos pérdidas existan mejor será tanto para los productores como consumidores al mantenerse su costo. Otro factor importante es el tiempo, un empleado se cansa con las horas disminuyendo drásticamente su rendimiento e incluso precisión ante la fatiga, hecho que se evita al usar un ordenador o sistema mecatrónico.

La falta de conjuntos de datos lo suficientemente grande y diverso de imágenes de huevo etiquetadas representa un obstáculo para el entrenamiento de modelos de aprendizaje profundo. Comúnmente, la evaluación de la calidad de huevo se realiza mediante inspecciones visuales y mediciones manuales, no obstante, este enfoque presenta limitaciones en términos de velocidad, subjetividad y susceptibilidad a errores humanos.

Por lo tanto, la clasificación de imágenes de tipos de huevo mediante el aprendizaje profundo tiene un impacto significativo en la sociedad al automatizar y agilizar las tareas de clasificación, mejorar la calidad de los productos, optimizar la producción, facilitar la toma de decisiones y promover la investigación científica. El aporte del proyecto no solo es clasificar huevos automáticamente, sino demostrar que mediante el uso de inteligencias artificiales se pueden solucionar problemas locales, mejorar procesos de producción e incentivar a idear nuevas formas de ver la industria, resaltar la relevancia de implementar estas tecnologías en el área local y dar ejemplo de cómo es posible con una inversión mínima haciendo uso de la creatividad e ingenio.

El problema es la imprecisión en la clasificación e identificación de huevos de aves de corral en granjas locales, es decir, ¿Cómo desarrollar un prototipo capaz de clasificar huevos de gallina en base a imágenes con uso de hardware NVIDIA mediante inteligencia artificial? Las causas que originan la situación conflictiva son:

- Fatiga mental (trabajar jornadas de 8 horas)
- Cansancio en la vista (tener que observar constantemente los huevos)
- Subjetividad, el ser humano varía su desempeño según su carácter o estado mental
- Errores, los criterios de selección difieren de la experiencia del inspector

El profesional encargado de separar y catalogar los huevos los analiza mientras pasan por la banda transportadora, sin embargo, a medida que transcurre el día se cansa o fatiga tanto visualmente como en su ánimo, lo cual puede hacer que sus labores se vean afectadas, sean susceptibles a subjetividades o errores al ser humano; por mejor profesional que sea no es infalible ni excepto a pasar por alto algún huevo. Por ende, este proyecto planea mejorar el proceso al emplear una inteligencia artificial mediante un modelo de entrenamiento automatizando la clasificación y optimizando costos operativos en granjas locales.

Los efectos que derivan del problema son:

- Imprecisión en la clasificación de los huevos
- Pérdidas en las ventas al pasar huevos quebrados o sucios
- Retrasos en la entrega al contabilizarlos y clasificarlos manualmente

En las granjas avícola se contabilizan miles de huevos, por ello, deben mantener a cientos de gallinas e invertir en infraestructura tanto para transportarlos como clasificarlos antes de ser comercializados.

No obstante, al depender de supervisores son susceptibles a cometer errores, demoras en el tiempo de clasificación, costos operativos e incluso faltas por accidentes o enfermedades; por lo tanto, al automatizar el proceso se evitan estas condiciones adversas a la vez que mejora el procedimiento de clasificación de huevos de gallina.

El objetivo general del estudio es: Desarrollar un prototipo de aplicación que utilice redes neuronales profundas, ejecutadas en hardware NVIDIA Jetson Orin Nano para una clasificación automática eficiente de huevos de gallina.

Los objetivos específicos que delinear el desarrollo del proyecto son:

- Realizar una búsqueda sistemática de literatura mediante criterios de exclusión e inclusión para determinar los modelos sujetos a experimentar.
- Levantar una base de datos de imágenes representativas de los tipos de huevos a partir de videos obtenidos de una clasificadora in situ.
- Implementar y evaluar una red neuronal profunda, utilizando conjunto de datos de prueba y validación para determinar la capacidad de clasificación de modelo
- Desarrollar un aplicativo a partir del hardware de NVIDIA que soporte la red neuronal convolucional entrenada y permita que realice detección en tiempo real.

La metodología aplicada es la cuantitativa, partiendo de un paradigma positivista desde modelos de aprendizaje hasta el desarrollo del aplicativo, el corte del estudio es longitudinal al analizar como varía la clasificación al ajustar los parámetros (tamaño, clases, colores e iluminación) y es cuasiexperimental debido a que no se alteran las variables del estudio, pero sí configura las mejores condiciones para el modelo de aprendizaje (videos, eras y fotogramas). La población es la producción de huevos que pasan por la cinta transportadora en una hora, mientras que la muestra son dos minutos de producción que serán grabados para obtener los fotogramas; resaltando que la granja al clasificar los huevos opera por intervalos de 30 minutos a una hora. En el desarrollo del aplicativo en su programación se emplea la metodología CRISP-DM (Cross Industry Standard

Process for Data Mining) siendo esencial en minería de datos y comprende distintas etapas como comprensión del negocio (huevos de gallina), comprender datos (variables, cantidades e indicadores), preparación de datos (cómo recopilarlos y procesarlos), modelo (entrenamiento de la IA) y evaluación (tasa de éxito al clasificar los huevos); cabe recalcar que es un proceso dinámico e interactivo que requiere ensayo/error hasta obtener resultados favorables para el objetivo del estudio.

La hipótesis por comprobar es: Sí se desarrolla un prototipo de aplicación con redes neuronales profundas, ejecutadas en hardware NVIDIA, se obtendrá una clasificación automática de huevos de gallina con una precisión igual o superior al 95 %.

La variable Independiente del estudio es: Desarrollo de un prototipo de aplicación que clasifique huevos de gallina con redes neuronales profundas, ejecutadas en hardware NVIDIA (Jetson Orin nano). La variable Dependiente: Clasificación automática de huevos de gallina mediante modelo de aprendizaje profundo con una precisión igual o superior al 95%.

El objeto de estudio es el proceso de clasificación de objetos mediante algoritmos o inteligencias artificiales; mientras, que el campo de acción es la clasificación de huevos de gallina considerando los factores de textura, tamaño y tipos de huevos destinado al comercio. Pero para este campo de trabajo es para gallinas que han sido criadas en suelo, en cautiverio, sin salir y alimentadas casi exclusivamente de balanceado, cuyo tamaño de selección es de talla mediano, entre los 53 y 63 gramos. De los diferentes tipos que huevos que se pueden observar solo se va a identificar cuatro tipos: quebrado, rugoso, sanos y sucio.

Hoy en día existen soluciones automatizadas para clasificar huevos disponibles en mercados como Alibaba o Amazon con precios que van desde \$2500 a \$24000 Usd, siendo la alternativa más cercana **“Lavadora de huevos de alta eficiencia Línea de producción automática de clasificación de peso de huevos”** [1] de procedencia China a \$12000 Usd, sin embargo, no son escalables ni encuentran repuestos en mercado local e importarlas es complejo; por ende, lo mejor para el estudio es diseñar una acorde a las necesidades del medio y sea compacta pudiendo adaptarla a la demanda de la granja.

La estructura del trabajo comprende en primer lugar los preliminares donde se destaca el cumplimiento de las formalidades, el resumen donde se sintetiza los lineamientos y resultados del estudio; la introducción partiendo desde el contexto del trabajo para inducir al lector e inferir de

que trata el proyecto, el capítulo 1 detallando los antecedentes del trabajo, citando estudios referenciales y planteando los requerimientos; en el capítulo 2 se explica la metodología aplicada, justificando la selección de métodos e instrumentos a emplear; en el capítulo 3 donde se aprecia el desarrollo del prototipo junto a los principales resultados; en el capítulo 4 se comprueba la hipótesis a la vez que se discuten los hallazgos en relación con trabajos similares y finalmente las conclusiones evidenciando el cumplimiento de los objetivos.

1. CAPÍTULO 1. MARCO TEÓRICO

En este apartado se describen los antecedentes partiendo desde la historia, evolución, conceptos y entorno de la problemática para entenderla, caracterizarla en el objeto de estudio.

1.1. Antecedentes Históricos

La visión por computadora es un campo amplio de investigación que a través de las computadoras emulan el sistema visual humano. Es un subsistema de la inteligencia artificial que recopila información de videos o imágenes digitales y los analiza para determinar características. Todo el proceso incluye adquisición, filtrado, análisis, reconocimiento y extracción de información de imágenes. Este proceso integral permite que las computadoras comprendan todo el contenido visual y actúen en consecuencia. El objetivo principal de esta línea en la inteligencia artificial es entrenar a las máquinas a extraer información a partir de datos basados en píxeles.

Los avances en procesamiento de imágenes mediante mecanismos artificiales se dieron a partir de estudios relacionados con animales como gatos al observar su conducta cuando se les mostraba distintas imágenes, donde se apreciaba que primero respondían ante bordes, líneas o contornos causando una respuesta en su cerebro; estos hallazgos fueron la base sobre la cual se comenzó a programar e indagar en la visión por ordenador.

En ese mismo periodo, se desarrollaba la primera tecnología de escaneo con imágenes por computadora, lo que permitió que las computadoras digitalizaran y adquirieran imágenes. Otro avance fue cuando en 1963 se logró convertir imágenes bidimensionales en figuras tridimensionales utilizando computadoras. A partir de la década de 1960, surgió un campo de estudio llamado “Inteligencia Artificial” (IA) que marcó un comienzo en la búsqueda de automatizar procesos y ofrecer soluciones a problemas en los que el ser humano se ve superado en términos de tiempo/recursos.

La tecnología del reconocimiento óptico tuvo sus inicios en 1970 cuando se identifica por medio de caracteres escritos en documentos, haciendo que sean incluidos en los sistemas de facturación, bancarios, aplicativos, dispositivos, entre otros usos acorde a la necesidad de identificar tipografías. Luego, el neurocientífico David Marr desarrolló un algoritmo capaz de detectar líneas o siluetas simples; esto ayudó al diseño de la red neuronal Neocognitron operando a través de capas al reconocer curvas, esquinas o contornos.

A inicios del siglo XX se implementan los primeros softwares de reconocimiento facial, esto fomentó su estandarización y uso en el mercado, dando lugar a bases de dato, categorías de objetos y uso de redes neuronales; la Universidad de Toronto fue pionera en los modelados de entrenamiento para minimizar errores e incrementar el nivel de precisión en la detección.

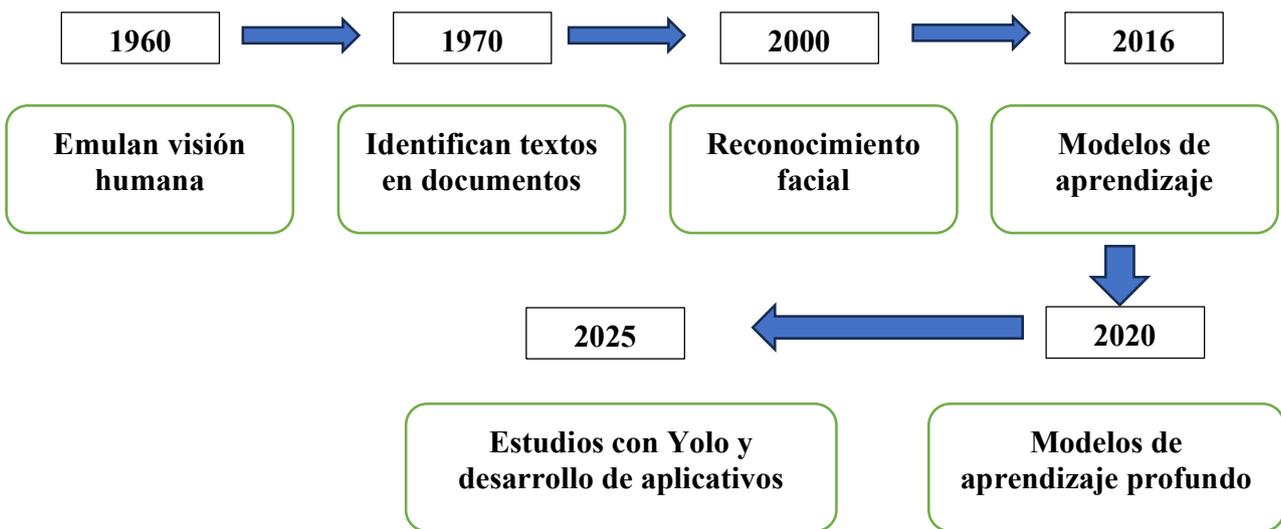


Figura 1. Resumen de hitos históricos de la visión por computadora

1.2. Antecedentes Referenciales

En esta sección, se presentan las definiciones clave que caracterizan la temática, guiando al lector hacia los criterios adoptados en el desarrollo del proyecto. Se inicia con la comprensión de los conceptos fundamentales de Big Data y se avanza hacia los métodos de diseño destinados al panel de control y la interfaz del estudiante para la Universidad Técnica de Machala (UTMACH).

1.2.1. Preguntas de investigación

Las preguntas de investigación que deben solventarse con el desarrollo del estudio son:

¿La tecnificación del proceso de clasificación podrá bajar la cantidad de veces que necesita ser manipulado un huevo de gallina antes de ser puesto en la cubeta?

¿Cuáles son los procesos para desarrollar un prototipo de bajo costo para identificar y clasificar huevos de gallina con un sistema de inteligente de aprendizaje profundo?

¿Al desarrollar el aplicativo mejorará el proceso de clasificación de huevos de gallina con una tasa de éxito superior o igual al 95%?

Es necesario indagar en publicaciones de sociedades científicas, trabajos de titulación, sitios web, contenidos sobre IA, programación, desarrollo de prototipos e integrarlos con las palabras adecuadas al discernir documentos como referencias en este proyecto.

1.2.2. Palabras claves y cadenas de búsquedas.

La cadena de búsqueda se realiza de lo general a lo particular, se usan términos comunes para sumarlos palabras más específicas relacionadas con la temática; generalmente se utilizan términos clave con palabras técnicas.

Para el buscador de Google y Google académico se empleó:

Desarrollo, inteligencia artificial, clasificación, huevos, prototipo.

Al refinar la cadena de búsqueda se obtienen:

- ❖ Inteligencia artificial + aprendizaje + clasificación + ISSN + 2023
- ❖ Huevos de gallina OR prototipo OR detección OR Inteligencia artificial
- ❖ Prototipo OR YoloV8 AND Clasificación + Desarrollo
- ❖ Python OR Detección e identificación de objetos OR entrenamiento IA

Para los metabuscadores de sociedades científicas como Taylor and Francis y Elsevier se aplican estos filtros:

- ❖ Fecha de publicación entre 2018 al 2024
- ❖ Sean de libre acceso
- ❖ Hablen directamente de la temática (revisar resumen)

1.2.3. Criterios de inclusión y exclusión

Los filtros que deben aplicarse a la documentación encontrada para ser incluida dentro del estudio son:

- ❖ Estudios primarios

- ❖ Los años de publicación sean superiores o iguales al 2018
- ❖ Los títulos tengan relación con el objeto de estudio
- ❖ La metodología sea clara y referente al desarrollo de prototipos
- ❖ Se encuentren respaldados por universidades o revistas indexadas

Los estudios que no son incluidos en el proyecto son aquellos que:

- ❖ Publicaciones que utilicen información primaria para otros fines (estudios secundarios)
- ❖ No sean respaldados por revistas indexadas o instituciones de educación superior
- ❖ El autor no tenga preparación profesional en el área
- ❖ No tengan afinidad con el objeto de estudio
- ❖ Exista redundancia en el trabajo
- ❖ No tengan relevancia para la finalidad del estudio
- ❖ Literatura gris
- ❖ Los resultados no sean respaldados por la metodología empleada

1.2.4. Proceso y resultado de la búsqueda

Los resultados se sintetizan mediante la *tabla 1*.

Tabla 1. Resultados del proceso de búsqueda de contenidos

Búsqueda automática	Bases de datos	Excluir documentos que no tienen relación con el objetivo	Revisar los resúmenes de las publicaciones
100 publicaciones	Scielo (15) Latindex (6) Scopus (3) Taylor and Francis (5) Google Scholar (15)	70 Títulos	50 Títulos
Aplicar criterios de exclusión	Artículos citados		
30 Títulos	26 títulos		

1.2.5. Establecimiento de requerimientos

En el proceso de desarrollo, programación, ensamble y puesta a prueba del prototipo es necesario tener en claro los requerimientos, con que métodos solventarlos, recursos e intuir la mejor solución posible optimizando lo más posible sin sacrificar eficiencia.

Se diseña una data de fotogramas e imágenes, en una granja de huevos en Piñas con el docente tutor poniendo una cámara frente a la cinta para obtener el fotograma (200 fotos); luego a cada imagen se le etiqueta cada huevo y se incorpora el método Yolo V8 para que enseñarle a la IA con el ejemplo que debe hacer.

Para el procedo de detección e identificación se emplea el método de aprendizaje Yolo V8 es la última versión del modelo, es de Ultralytics siendo un soporte para IA en lo relacionado a visión por ordenador, permite cargar datos, transformar imágenes y procesarlas en función del algoritmo de aprendizaje; además permite exportarlas como modelo de entrenamiento para otros proyectos.

Para elaborar el modelo de entrenamiento se graban cuatro videos de 2 minutos en la granja de huevos Ramírez situada en el cantón Piñas provincia de El Oro; se enfoca la cinta transportadora de huevos de gallina en intervalos regulares; luego en el aplicativo Supervisely.com se segmenta los videos en fotogramas (50 imágenes por video) dando un total de 200 imágenes para etiquetar en el aplicativo haciendo que la visión por computadora las interprete como objetos a clasificar. Se realiza manualmente el etiquetado/clasificado de cada huevo en algunas fotos son 35 hasta 108 huevos que deben colorearse individualmente para que la IA los identifique como el modelo a seguir en su entrenamiento. Las figuras se guardan en una carpeta donde cada tipo de huevo se encuentra identificado y así la IA pueda compararlos aprendiendo a detectarlos. Los 200 fotogramas se trabajan individualmente, primero se pinta los huevos de colores según la clase, luego se etiqueta en la pantalla a que clase pertenece siendo reflejada en el monitor la clasificación correspondiente. En el proceso de etiquetado los huevos se pintan bajo el siguiente criterio:

- ❖ Verde huevo sano
- ❖ Azul huevo rugoso
- ❖ Rojos huevo sucio
- ❖ Celeste es quebrado

Cada imagen se enlace con un archivo semejante que le indica la IA las coordenadas de cada clase de huevo, ejemplo: clase 0 es X 0.64, 0498 Y estando en milímetros. En la *figura 1*, se aprecia una imagen procesada por la IA donde cada huevo es identificado por una clase (del 0 al 3) junto a unas coordenadas sirviendo de modelo para el aprendizaje en la clasificación de huevos.

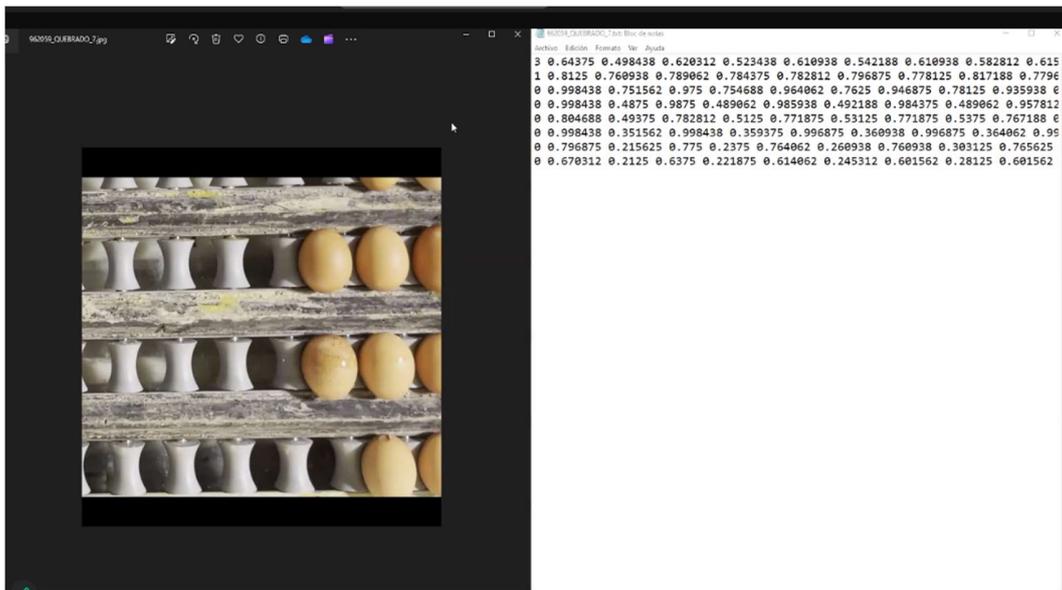


Figura 2. Fotograma usado para entrenar a la IA mediante YoloV8

1.2.6. Contexto del problema

El problema desde el punto de vista empresarial es cómo automatizar la clasificación de huevos de manera rentable y eficiente; es decir, pese a que existen tecnologías o soluciones a nivel industrial no las hay al alcance de granjas locales o pequeños productores haciendo necesario el desarrollo de un aplicativo; desde la perspectiva estadística la probabilidad del fallo humano es del 60% al 90% e incrementa según condiciones (fatiga o actitudes), mientras que la de una máquina del 3%; según en [19] el fallo humano tiene un impacto significativo en las líneas de producción, siendo relevante al no poder ser eliminado por completo, pero sí reducido a través de un sistema como propone el estudio. Además, clasificar miles de huevos por hora cansa al supervisor y en general se tienen un porcentaje de huevos sucios, quebrados o rugosos que son pasados por alto en ocasiones. En base a la visita previa a la granja al interactuar con el supervisor y encargado se analiza la posible solución mediante un aplicativo empleando visión por computadora, con la finalidad de mejorar la eficiencia del proceso.

1.3. Antecedentes conceptuales

Comprenden los lineamientos teóricos relacionados a las variables principales del estudio para caracterizar el desarrollo del proyecto partiendo desde la clasificación de huevos hasta el prototipo a diseñar para automatizar este proceso.

1.3.1. Antecedentes conceptuales de la variable dependiente

En la producción avícola se requieren mantener condiciones adecuadas al garantizar la calidad de los huevos y su eclosión para comercializar tanto las aves como derivados; es necesario clasificar los huevos procedentes de diferentes galgones hasta 6 veces al día, la cinta responde a un procedimiento autónomo a través de maquinaria. Un indicador importante es el peso de los huevos, su tamaño y cantidad debiendo llegar a una velocidad estable, pero sin acumularse [20].

Es importante tomar muestras de huevos diariamente para determinar tendencias. Debido a que la permeabilidad del huevo aumenta luego de las 24 horas, haciendo necesario su tratamiento al evitar infecciones, deben estar limpios antes de ingresar en el almacén. Los huevos deben clasificarse cuidadosamente para evitar danos físicos y desechar los huevos que no sean aptos para la incubación, tales como:

- Sanos; son los huevos que no presentan machas, rugosidades o grietas
- Sucios, los que presentan rastros de plumas o sangre
- Rugosos, los que tienen su superficie imperfecciones o pecas rugosas
- Rotos, los que están agrietados o fisurados

Los huevos deben recolectarse y enfriarse a una temperatura de 21 a 25°C y la humedad con un parámetro del 50 y 70% esto depende de cuantos días tiene de almacenamiento y esto no debe superar los 7 días, para retrasar la eclosión temprana y desarrollo embrionario [21].

1.3.2. Fundamentación Teórica De La Variable Independiente

Los rasgos físicos del huevo de gallina tienen características bien definidas, y con ayuda de la identificación automática ha sido posible que medida que ha ido avanzando el reconocimiento de objetos y los diferentes modelos disponibles de aprendizaje profundo, es necesario iniciar un previo etiquetado de los rasgos biométricos del huevo. Este proceso de etiquetado es la base para el buen procesado y modelado del sistema y tener una comparación lo más cercana a lo esperado.

Estos modelos utilizan procesos de cálculo estadístico y matemáticas que se aplican dependiendo la técnica de modelado para determinar la identidad y verificar lo aprendido.

1.3.2.1. *Biometría.*

Es el análisis de las mediciones al cuantificar la morfología, fisiología o rasgos de seres vivos; en este caso se refiere a los huevos, su forma, peso, dimensiones e instrumentos o técnicas para evaluarlos, registrarlos e identificarlas con exactitud [22]. Para determinar las características morfológicas del huevo, este debe examinarse externa e internamente. Para la medición externa se usan los siguientes parámetros: peso del huevo, integridad de la cascara del huevo y altura de la celda del aire, sin romper el huevo es posible medir estos parámetros usando un ovoscopía.

1.3.2.2. *Aprendizaje de maquina vs aprendizaje profundo*

Es el proceso de aprendizaje virtual aplicado a las IA, se emplean modelos de entrenamiento, algoritmos y patrones al enseñarles como realizar una tarea a través de un análisis; esto depende en gran parte de la potencia tanto del hardware como algoritmo a emplear. Este tipo de aprendizaje permite a los ordenadores realizar determinadas tareas de forma autónoma, es decir, sin necesidad de un programador. Gracias al poder del aprendizaje automático, los sistemas basados en inteligencia artificial pueden realizar tareas que antes eran imposibles para las maquinas, e incluso pueden realizar tareas difíciles o peligrosas para los humanos *Figura 1.*

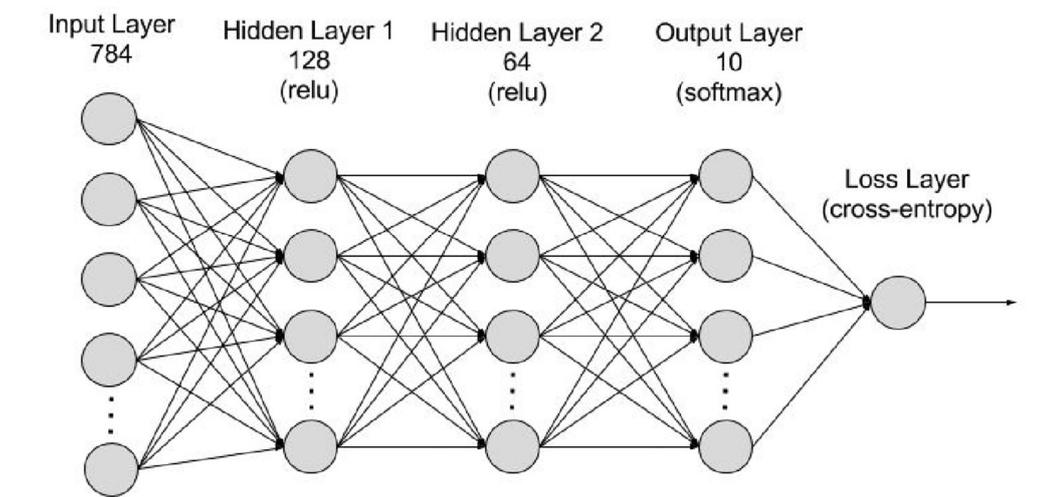


Figura 3. Redes neuronales artificiales

Fuente: [23]

Machine Learning utiliza algoritmos para aprender patrones a partir de datos. Por ejemplo, al estudiar los patrones de usuario del navegador, es fácil comprender el comportamiento de recomendación de búsqueda para temas similares a las búsquedas recientes, entrenando así al navegador para sugerir temas similares en el futuro. La misma dinámica se aplica a la música, el video y otras aplicaciones, lo que demuestra la ubicuidad del aprendizaje automático [23].

1.3.2.3. Aprendizaje Automático (Machine Learning)

Es una rama de la inteligencia artificial. Su objetivo es enseñar a las computadoras el aprendizaje de datos y mejorarlos. Basándose en la experiencia, en lugar de hacerlo mediante programación explícita. Generalmente consiste en determinar relaciones entre datos, patrones e identificar cómo analizarlos para que la máquina aprenda a utilizarlos con una finalidad específica.

Las aplicaciones de machine learning están en todas partes de nuestro hogar, supermercados, entretenimiento, atención médica. El proceso de aprendizaje se sustenta en métodos matemáticos, análisis de datos, variables y conjugar diversos algoritmos de enseñanza al entrenar a la máquina.

1.3.2.4. Inteligencia artificial

Se define como un conjunto de algoritmos que dan a las máquinas la capacidad de comprender y aprender para que puedan tomar decisiones como los humanos. Si se implementa correctamente, esta tecnología permite que las máquinas trabajen continuamente sin fatiga y realicen análisis de metadatos más rápidos y eficientes.

La inteligencia artificial hace tiempo que abandonó el espectro de la ciencia ficción y está empezando a ser de uso cotidiano evolucionando hasta la Industria 4.0 están cambiando las capacidades de los dispositivos tecnológicos actuales. Esto ha dado lugar a dispositivos más sofisticados y eficientes, como asistentes virtuales, robots y vehículos autónomos.

Además, la automatización y digitalización de la producción de productos reduce los costes y optimiza la experiencia como en el caso de la Web 4.0 e Industria 4.0; igualmente [24] donde mediante un IA empleando el método Naïve-Bayes combinado con espectroscopia de transmisión de infrarrojo visible se puede predecir los huevos infértiles antes de su eclosión con 89,2% de confiabilidad.

1.3.2.5. Visión computacional

Es un campo de la ingeniería informática y eléctrica que integra mecanismos para adquirir, procesar, analizar y comprender contenidos digitales como imágenes (imágenes normales, imágenes infrarrojas, entre otros) y videos. Los sistemas de visión por computadora están diseñados para aceptar diferentes tipos de datos como variables de entrada, como imágenes o secuencias de video, que pueden transmitirse desde múltiples fuentes para procesarse en consecuencia y transformarse en datos capaces de solventar decisiones [25].

1.3.2.6. Red neuronal

En un enfoque biológico, una red neuronal es la parte del cerebro que se utiliza para tomar decisiones basadas en estímulos. El trasfondo es que existen miles de millones de neuronas en el cerebro humano que controlan las acciones que se realizan cada día ante cualquier evento o acción realizada, incluso con este concepto es posible predecir eventos futuros basándose en la memoria de la red neuronal *Figura 2*. La analogía entre la definición biológica y su contraparte técnica es que ambas constan de un grupo de neuronas interconectadas.

En este contexto, las redes neuronales operan mediante capas tanto de entrada/salida como estructuras interconectadas para el procesamiento de datos validando la información a presentar [26].

1.3.2.7. Red neuronal artificial

Las redes neuronales artificiales son algoritmos que actúan como modelos de programación para la resolución de problemas. Se pueden utilizar en cualquier entorno que requiera analizar gran volumen de datos y resolver problemas basados en los sistemas de decisión necesarios. Las unidades básicas que componen este sistema son las neuronas, que suelen estar dispuestas en capas. Una red neuronal bien configurada tiene las siguientes características principales.

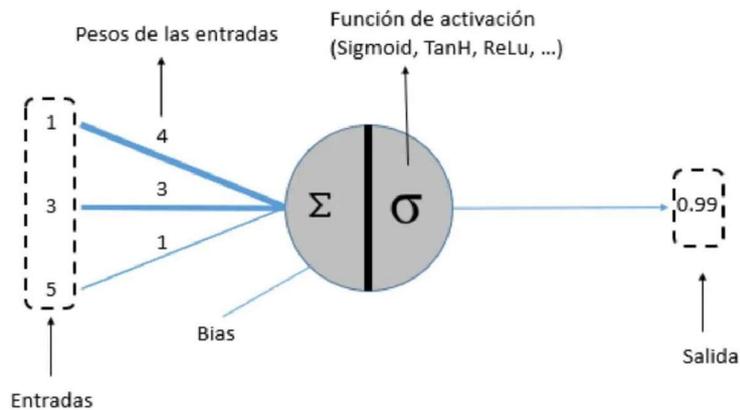


Figura 4. Esquema de una red neuronal artificial.

Fuente: [26]

1.3.2.8. Etiquetado

Es una etapa clave del modelo de aprendizaje automático. Este requiere identificar el material fuente y luego agregar una o más etiquetas para indicar el contexto del modelo para que el modelo de aprendizaje automático pueda hacer predicciones precisas. Estos datos forman la base de varios modelos. Casos de uso de aprendizaje automático y aprendizaje profundo, incluida la visión por artificial e implicaciones en el ámbito avícola [27].

La empresa incorpora software, proceso y anotaciones de datos para limpiar, etiquetar y estructurar los datos. Estos datos de entrenamiento se convierten en la base del modelo de aprendizaje automático. Estas etiquetas permiten a los analistas tomar variables del conjunto de datos para seleccionar mejor variables predictivas para el método de aprendizaje. El reconocimiento de etiquetas implica extraer los datos correctos para entrenar un modelo luego el modelo aprende a hacer mejor las predicciones.

Los datos etiquetados se utilizan para el entrenamiento supervisado, los datos sin etiquetar se utilizan para el entrenamiento no supervisado. Los datos etiquetados son más difíciles de obtener y almacenar, mientras que los datos no etiquetados son más fáciles de obtener y almacenar.

Los datos etiquetados se pueden utilizar para identificar información útil, mientras que los datos no etiquetados tienen una utilidad más limitada. Se pueden utilizar técnicas de aprendizaje no supervisado para descubrir nuevos conjuntos de datos y así facilitar nuevas clasificaciones mediante el etiquetado.

1.3.2.9. Jetson orin nano

El Jetson orin nano es un mini computador de Nvidia impulsado por inteligencia artificial (IA), permite integrar cámaras inteligentes, adaptar componentes, desarrollar y transformar sus conceptos en aplicaciones ejecutables. El módulo contiene 8GB, placa portadora, tarjeta gráfica ampere, CPU ARM de 6 núcleos, conectores MIPI CSI, cámara de hasta cuatro carriles en alta resolución y aplicaciones para robótica, DeepStream para IA de visión y Riva para IA conversacional.

Este mini ordenador es el núcleo del proyecto sobre el cual se correrá la IA que detecta/clasifica los huevos, su potencia, versatilidad y facilidad para programarse permite obtener un mecanismo robusto con alta eficiencia al momento de automatizar el proceso de clasificar huevos en las cuatro clases seleccionadas.



Figura 5. NVIDIA Jetson Orin Nano Developer Kit

Fuente: [28]

1.3.2.10. YoloV8

El modelo Yolo en su octava versión es el método para enseñar y entrenar a la IA, tiene la ventaja de que se puede configurar, adaptar e integrar a partir de modelo pre entrenados; es decir, decirle a la IA que quiero que haga con el modelo, cómo entienda e interprete las órdenes para ejecutar el programa.

De acuerdo con [29] YoloV8 es desarrollado por Ultralytics siendo un código de licencia libre mismo que tienen las ventajas de detectar sin anclajes, cambios en bloques convolucionales en el modelo e incremento del mosaico de entrenamiento; es compatible con Python facilitando las tareas de detección, clasificación y diferenciar objetos.

1.3.2.11. Supervisely.com

Según [30] es una plataforma de soporte para IA en especial el *Etiquetado Inteligente*; es decir, herramientas capaces de etiquetar imágenes, videos, emplear sensores, gestionar datos, entrenar redes neuronales y es compatible con el lenguaje Python haciéndolo ideal para el aporte práctico. Su principal ventaja es que es un sistema operativo adaptable, personalizado y versátil capaz de entrenarse para diversos fines como en el caso de la clasificación de huevos utilizando una IA junto a una cámara.

1.3.2.12. Lenguaje Python

Es usado en el módulo de entrenamiento de la IA; creando la data para entrenarlo, etiquetar y probar el modelo. En este caso se usaron 200 imágenes con 35 a 108 huevos por imagen tomadas de un video en campo por medio de fotogramas que la IA debe detectar, contabilizar, clasificar y colorear la pantalla.

Python de acuerdo con [31] es un lenguaje de programación orientado a la ciencia de datos y aprendizaje de máquinas, es ideal para aplicativos relacionados con IA al programar instrucciones y es compatible con distintos códigos e incluso multiparadigma.

1.4. Antecedentes Contextuales

Las redes neuronales permiten analizar datos, aprender e interpretar información en forma lógica; ganando espacio en asuntos cotidianos como inicio de sesiones, reconocimiento de imágenes, procesar datos u optimizar dispositivos inteligentes como smartphone. En el año del 2017 la compañía Apple presento una nueva tecnología que es el Face ID para el nuevo iPhone X y de ahí en adelante ahora es parte para todos los equipos de esta compañía. Otra compañía es la British Airways, que utiliza un software de reconocimiento facial para que los pasajeros puedan ingresar a los vuelos procedentes a Estados Unidos sin tener la necesidad de presentar su pasaporte o tarjeta de embarque. Esta tecnología de reconocimiento facial también esta implementada en el control de seguridad de la terminal del aeropuerto de Heathrow para mejorar la seguridad y fluides para el control de identidad.

La precisión del reconocimiento facial mejoro rápidamente que en la década de los 70, con aspectos importantes como el color cabello, forma de los labios y otras áreas importantes de identificación. En los años siguientes, el algebra lineal se utilizó cada vez más para funcionar cada vez mejor el sistema. Un gran avance se produjo en el año 2001, cuando las autoridades de Estados Unidos utilizaron por primera vez la tecnología de reconocimiento facial para el perfilamiento a los espectadores del Super Bowl que podrían causar desmanes o daños. El sistema de reconocimiento facial desempeñó un papel importante en la localización de Osama Bin Laden en 2011 [55].

En la llegada del Covid-19 en el año 2020 ha cambiado la forma en que interactuamos y de muchas maneras, tanto en grande como en pequeñas cosas. Un gran cambio fue el uso de la mascarilla en lugares reducidos o públicos. Para un sistema de reconocimiento facial era más que obvio que fuera afectado la efectividad del análisis. Muchas empresas como HKVISION empezaron a trabajar para mitigar ese efecto y a cambiar de algoritmo para tener ahora en cuenta las mascarillas dando como resultado una precisión significativamente mayor en algunos casos.

1.4.1. Trabajos Previos

Una investigación realizada en 2013 en Brasil sobre la selección de huevos mediante el uso de cámara y laboratorio de matrices permitió designar diversos patrones al entrenar programas capaces de reconocer objetos, dando como resultado un modelo de aprendizaje basado en el grado y volumen de información [8]. Luego, en el 2014 se diseñó un prototipo capaz de separar huevos

de gallina en clases, se empleó programas de licencia libre, Arduino, cámara y un módulo de iluminación para lograr imágenes con características similares sin importar la hora alcanzando un error menor al cinco por ciento [9].

La universidad de las fuerzas armadas del Ecuador en 2014 logró implementar un mecanismo de ovoscopia a través de visión por computadora, el objeto era identificar huevos fértiles para la empresa Incubandina S.A para ello utilizaron un hardware gratuito para construir las piezas mecánicas y el control del sistema y con el IDE de Matlab para procesar los datos, dieron como resultado si bien que la visión artificial no es 100% confiable debido a los errores por condiciones de rendimiento, la ovoscopia puede identificar una gran parte de cantidad de defectos, en el que los huevos se clasifican de los fecundados y no fecundados. Teniendo cifras de eclosión satisfactorias [10].

El proyecto de atomización al clasificar 2000 huevos de gallina por hora mediante un controlador lógico programable (PLC) llevado a cabo en 2015, utilizó variables de emulación al validar cálculos, discretizar datos irregulares, disminuir falsos positivos y mejora la producción de la granja al superar la producción prevista [11].

En 2016, Luis Gómez Aguilar y Javier Sánchez Rosas del Instituto Politécnico Nacional, México, realizaron un estudio mediante visión artificial para vacunar huevos en sitio empleando IDE de Labview facilitando el procesamiento de imágenes variando los módulos de visión, obteniendo diferentes opciones de filtrado, imágenes RGB, binarización, entre otros. Además, se puede realizar un HMI's básico en el mismo entorno con la finalidad de tener más simple la interacción [12].

En el año 2018 en la universidad Keio de Japón se realizaron trabajos sobre las redes neuronales aplicadas a clasificar huevos de gallina, el uso de modelos de redes al entrenar programas para realizar tareas de separación e identificación dio como resultado una precisión mejorada al usar cuatro ángulos, más de doscientos fotogramas y analizar objetos tridimensionales [13].

En la Universidad ITMO en Rusia en el año 2018 se llevaron a cabo proyectos sobre indicadores de calidad de huevos de incubadora mediante visión por computadora, esto permitió acelerar el proceso de clasificación controlando el brillo, eliminando sombras y usando matrices al determinar posición de los huevos al pasar por la cinta transportadora [14].

Un estudio solventado en redes neuronales para analizar los cambios en la transmisión de luz entre huevos con el objeto de clasificarlos arrojó como resultado que los parámetros óptimos son limitados, se requiere mayor potencia de hardware al modelar e ingresar los datos correctos depende de un operador impidiendo que sea automático del todo [15]. De igual manera [16] al indagar en redes neuronales empleadas como medio de separación de huevos de aves en el departamento de biología e inteligencia artificial de la Universidad de Georgia, se encuentra que al entrenar la IA es posible diferenciar huevos con sangre, sucios o sanos.

Según Narushin, Romanov, James, Gang et al. [17] diseñaron un modelo para definir la geometría de los huevos de gallina, basándose en la ecuación de Hügelschäffer con la finalidad de obtener sus cualidades verificando sean aptos para ser comercializados en la industria alimenticia, se encontró que existe relación entre el contorno, área y volumen del huevo como predictores de su calidad.

En cambio, en [18] refiere que al concatenar visión artificial junto a redes neuronales se puede predecir el peso de los huevos con una precisión del 96%, en el modelo se utilizó un algoritmo de correlación entre su geometría/dimensiones.

Los trabajos previos emplear diversos métodos o modelos al clasificar huevos, detectar la fertilidad o identificar características en los huevos de gallina; en general la mayoría emplea redes neuronales al entrenar IA para detectar una a dos clases de huevos o incluso usa Logo Siemens midiendo parámetros indirectamente; entre sus limitaciones esta la precisión, tipos de clases, eficiencia y alcance de la visión artificial requiriendo sistemas de iluminación u otros implementos para procesar los datos como en el caso de Matlab u hardware mismo que exige un mayor costo.

La propuesta del presente proyecto es concatenar la versatilidad de la IA YoloV8 junto al Hardware Jetson Orin Nano profundizando el alcance de los trabajos anteriores al contar con una visión por computadora más sofisticada y un soporte más potente capaz de clasificar cuatro tipos de huevos de gallina con una eficiencia superior a la vez que se optimizan recursos haciendo un prototipo atractivo para la ovoscopía e industria avícola local.

2. CAPÍTULO II. METODOLOGÍA Y POBLACIÓN

En este apartado se detallan los lineamientos empleados al analizar los documentos referidos, recopilación de información y dejar en claro las bases para que la comunidad científica pueda analizar o verificar los hallazgos dirimidos al final del presente estudio.

2.1. Tipo de estudio

El proyecto maneja variables cuantitativas como son la cantidad de huevos, cantidad de imágenes, resolución de los fotogramas, tipos de clases de huevos, tiempo, ciclos de entrenamiento y coordenadas X, Y; a la vez variables no numéricas en los requerimientos como los colores para cada tipo de huevo y nivel de percepción.

Según Calle [32] el enfoque cuantitativo es objetivo, claro e inductivo al partir de la lógica, de operaciones matemáticas o parámetros comprobables; esta visión permite al investigador decidir qué procesos emplea al tratar la información, cómo comprobar sus hallazgos, qué relación existe entre las variables y en qué grado se alcanzan los objetivos; para este caso muy particular se enfoca en el nivel de éxito al clasificar los huevos, esta variable se mide en porcentaje por cada 100 huevos cuánto es el error y si está dentro de las condiciones aceptables. En el caso de las variables se analizan conforme aportan al desarrollo del proyecto como los fotogramas, ciclos de entrenamiento, costos, ajustes, tiempo u otros aspectos que faciliten mejorar la calidad del aporte práctico sin comprometer su accesibilidad (bajo presupuesto).

Tabla 2. Variables y unidades empleadas en el desarrollo del prototipo

Variable	Parámetro	Unidad de medida
Fotogramas	Cantidad de imágenes	U
Duración del video	Tiempo	minutos
Calidad de imagen	Resolución	Pixeles
Huevos de gallina	Cantidad	U
Clases de huevos	Sano, sucio, rugoso y quebrado	0 al 3
Aprendizaje	Ciclos de iteraciones	U
Tasa de éxito	Por cada 100 huevos detectados	Porcentaje %

La IA a diferencia del ser humano no se fatiga ni se equivoca intencionalmente o por cansancio de vista, pero se recalca que hay huevos que pueden estar sucios, quebrados o sanos en una parte mientras va rotando sobre la cinta transportadora; por ende, se coloca como regla que prevalece el color que se identificó primero, es decir, sí estuvo morado (quebrado), rojo (sucio) o rugoso (azul) por unos segundos se queda como tal para no ser confundidos como huevos sanos (verde) e induzca un bucle que altere constantemente el proceso de separación en los tipos de huevos. Es necesario enfatizar que la IA imita la visión humana pero no es exactamente igual, no piensa como tal, sino que emplea redes neuronales para tomar decisiones basadas en los algoritmos u ordenes que ejecuta su programación.

2.1.1. Tipo de investigación

El tipo de investigación es *cuasiexperimental*, debido a que, no se manipulan las variables del proyecto como cantidad de huevos, calidad o categoría, pero sí la configuración de los parámetros del modelo de aprendizaje y algunas condiciones como iluminación del lugar; se resalta que el desarrollo de un prototipo requiere ensayo y error al no existir un caso similar en el medio donde se lleva a cabo el proyecto.

2.2. Paradigma

El paradigma que compagina con el tipo de estudio es el positivista, debido a que, parte de propuestos lógicos (desarrollo) e hipótesis (a comprobar) criterios que deben validarse mediante la observación, datos, resultados, experiencia y el cumplimiento de las predicciones; es decir, cuán eficiente es el modelo, que tan fiable es su tasa de éxito, entrenamiento de YoloV8 permite clasificar los huevos con la misma o mayor precisión que un experto o requiere ajustes hasta satisfacer las condiciones de diseño.

De acuerdo con Walker [33] este enfoque se sustenta en las reglas, fundamentos e interrelaciones entre el proceso de desarrollo, como los criterios de programación, metodologías, necesidades, correcciones, calidad de datos e integridad de estos de modo que sistematiza al objeto de estudio facilitando entenderlo, darle coherencia, lógica y argumentar a través del proceso los resultados a obtener dejando en claro cómo se obtuvieron al procesar la información sobre la problemática.

La inteligencia artificial empleada es Yolo (You Only Look Once), según [34] al usar Yolo V8 para determinar el vigor de las semillas empleando tasa de germinación y prueba de tetrazolio, comúnmente se hace por inspecciones humanas que requieren mucho tiempo y no son tan eficientes en grandes áreas. Al automatizar el proceso a través de la visión por computadora examinando la morfología interna de las semillas empleando rayos X entrenando a la IA para desarrollar un módulo post-segmentación evaluando área total de semillas, área del embrión y endospermo demostrando un sólido desempeño de 95.6% con 1500 imágenes de entrenamiento.

La metodología seleccionada es la adecuada, puesto que se ha empleado en estudios similares y su adaptabilidad para ser entrenada en la clasificación de huevos facilita automatizar el proceso, servir de base para estudios similares o impulsar el uso de las IA para desempeñar tareas de visión e inspección en la industria local.

2.3. Población y muestra

Se toman cuatro videos de 2 minutos de duración, luego se los transforma a fotogramas con un total de 200 imágenes para el entrenamiento, en cada imagen se tiene en promedio 120 a 60 huevos e incluido espacios vacíos; dando un valor de 12000 huevos para ser clasificados en el entrenamiento.

Una vez que se ajusta la calidad de las imágenes en 640x640 figuras cuadradas se aumenta la cantidad de datos a 33468 imágenes para que la IA aprenda con más datos, mejores referencias y obtenga una tasa de éxito mayor al 95%; cabe recalcar que el proceso es interactivo e intuitivo corriendo el modelo en Python siendo probado en reiteradas ocasiones.

En el *Anexo 8* se evidencia que la producción de huevos conlleva errores, al haber huevos con sangre, descartados, rotos y se clasifican por peso más que por tipo haciendo necesario el aplicativo.

2.4. Métodos empíricos utilizados

Según [35] los métodos empíricos son aquellos que el autor emplea al interactuar con el objeto de estudio, es el cómo obtiene información; en este caso se emplea el método de modelación al emular la visión humana por medio de una inteligencia artificial y el método hipotético-deductivo dado que se parte de un supuesto regido por reglas o normas lógicas que debe ser validado por resultados o datos comprobables.

En [36] se indica que las IA se emplean en modelos predictivos como el desempeño de los estudiantes, empleando un enfoque sistemático basada en una base de datos de calificaciones, chatbots e incluso sistemas de vigilancia, aunque no sustituye la experiencia humana es posible realizar simulaciones en base a procesos analíticos obteniendo resultados similares, en la enseñanza e investigación dada la potencia de cómputo de los recursos e infraestructura tecnológica de hoy en día.

Según [37] el método hipotético deductivo es un referente clave al contrastar el problema con la solución y medir los resultados obtenidos; es decir, se valida el supuesto a través de la experimentación interactuando con el abstracto de la realidad directamente del problema; para este caso se alcanza cuando la tasa de éxito es superior o igual al 95% al ser comparada con el desempeño de un inspector de huevos de gallina calificado.

La relevancia de estos métodos consiste en su capacidad para sustentar el desarrollo del proyecto, permiten entender la parte metaheurística e investigativa del estudio facilitando que sea validado por otros autores reconocidos en la materia.

2.5. Técnicas estadísticas para el procesamiento de datos

En la parte estadística se emplean los siguientes métodos:

Tasa de éxito: Se realiza contabilizando los huevos por colores rojo (sucio), verde (sano), azul (rugoso) y celeste (roto) sobre el total de huevos contabilizados; es decir, de cada 100 huevos cuánto se identificaron correctamente al compararlos con la inspección del experto.

Gráficas, se emplean distintos gráficos tipo pastel, diagramas de barras y otros para resumir los resultados exportados a datos fáciles de interpretar.

Matrices, las coordenadas, clases de huevos, cantidad de fotogramas, entre otras variables se representan mediante matrices para serán interpretadas por la IA en forma matemática mientras se entrena e identifica cada huevo mediante una comparación; en el *Anexo 1* se aprecia las curvas de precisión obtenidas del modelo de clasificación.

Validación estadística de hipótesis, debido a la naturaleza del estudio se aplica la *prueba de hipótesis para proporciones* donde se determina si una diferencia en las proporciones de la muestra refleja una variación en la proporción de la población; para ello se basa en una distribución normal de la probabilidad donde el 75% o más de la tasa de éxito es el parámetro de validación.

Según Ortega, Ochoa, Molina et al. [38] esta prueba compara las posibilidades en los niveles de confianza para las proporciones; de modo que se tiene una prueba unilateral hacia la izquierda para una hipótesis nula mayor o igual al 75% de los casos al clasificar e identificar los huevos de gallina.

2.6. Metodología CRISP-DM

Es un proceso de minería de datos, enfocado en describir e integrar las etapas de un proyecto; en este caso se aplica al obtener las variables a configurar, elaborar el sistema operativo, diseñar modelo de entrenamiento, entrenar a la IA para detectar/clasificar los huevos de gallina y correr el programa en Jetson Orin Nano; sus siglas CRISP-DM derivan de su significado en el idioma inglés Cross-Industry Standard Process for Data Mining. Según Tamayo [38] la metodología comprende:

- 1) Fase de comprensión del negocio, donde se plantean los objetivos como clasificar huevos de gallina al pasar por la cinta transportadora;
- 2) Fase de comprensión de los datos; determinar que datos se deben registrar y procesar como tipos de huevos, color, visión por computadora, coordenadas e interpretación de estos;
- 3) Fase de preparación de los datos; los videos a grabar para desarrollar el modelo de aprendizaje; duración, cantidad de fotogramas y etiquetado;
- 4) Fase de modelado; entrenamiento de Yolo V8 para obtener tasa de éxito al clasificar los huevos en los fotogramas;
- 5) Fase de evaluación; puesta en marcha del modelo soportado por el hardware, ciclos de entrenamiento en el ordenador de escritorio y calibración de los parámetros del modelado como la configuración de la cámara, iluminación, altura, entre otros;
- 6) Fase de despliegue; puesta en marcha del aplicativo en la granja de huevos para validar los resultados al obtener una tasa de éxitos mayor o igual a la obtenida en las simulaciones

3. CAPÍTULO III. RESULTADOS

En este apartado se explica el desarrollo e implementación del prototipo desde la parte del software hasta los resultados de la puesta en marcha del aporte práctico. Se aplica la metodología CRISP-DM detallando cada una de las fases del método al implementar el prototipo.

3.1. Fase de comprensión del negocio

En esta fase se delinear los objetivos del proyecto en base al negocio como clasificar huevos, cuatro clases de huevos, colores a emplear, visita a la granja, buscar inteligencias artificiales enfocadas en identificar objetos y sobre todo conversar con el supervisor o dueño de la granja para entender los requerimientos (*Figura 6*), qué necesita automatizar, como son las etapas del proceso y con que elementos se dispone en el ámbito local.

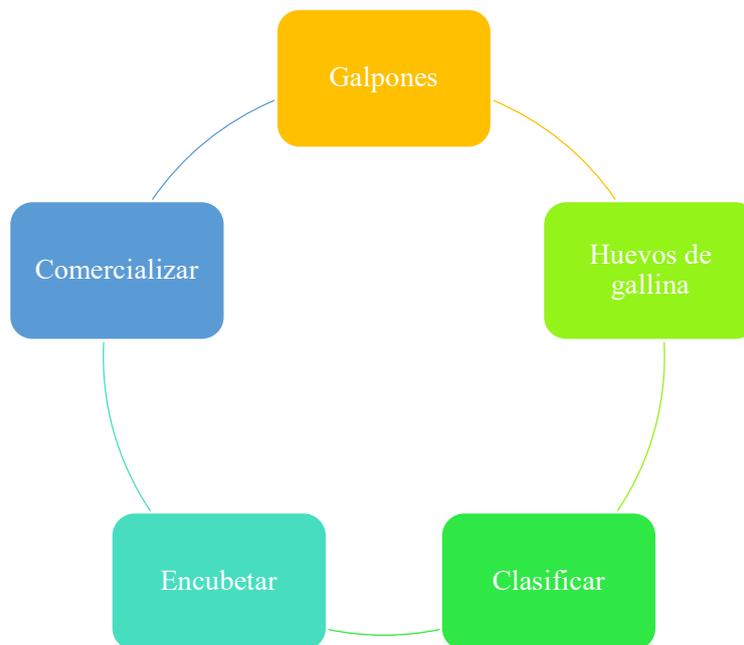


Figura 6. Proceso de comprensión del negocio

La granja cuenta con varios galpones cada uno con al menos 20 000 gallinas y otros con hasta 50 000 gallinas; cada uno se encuentra interconectado mediante bandas transportadoras hacia la planta de empacado donde operadores seleccionan los huevos en función de la clase y peso los encubetan para ser distribuidos a los camiones que los llevan a las tiendas.

Lo que se debe automatizar es el proceso de selección que no sea un operador el que los inspeccione individualmente para determinar su tipo sino que sea realizado por una IA que pinte en pantalla las clases de huevo mejorando el proceso haciéndolo más eficiente e incrementa tasa de éxito al evitar errores humanos.

3.2. Fase de comprensión de datos

Para esta metodología, se optó por la utilización de www.ultralytics.com YOLO (You Only Look Once) que es una herramienta inteligente IA avanzada para el entrenamiento del modelo de aprendizaje. Para esto fue necesario crear un datasheet propio de los huevos a identificar, con su respectivo etiquetado realizado en www.supervisely.com

La octava versión de Yolo permite detectar objetos en tiempo real, facilita diferenciar objetos y aprender a cómo seleccionarlos; este aplicativo no solo es una IA más flexible, sino que también aumenta la eficiencia, uso de recursos e incluye predicción siendo idónea para este estudio.

3.3. Fase de preparación de datos

Se aplica una metodología de carácter empírico, empleando un proceso de desarrollo lógico e iterativo al ser un proyecto inédito que no se ha realizado en el ámbito local; los pasos aplicados fueron los siguientes:

- Se inicia con la base de datos, transformando los videos a 200 fotogramas de resolución 1920 x 1080 a imágenes cuadradas de 640 x 640; a cada fotograma se lo rota 180 grados para obtener dos imágenes y luego a esas dos imágenes se les varía los parámetros de brillo e iluminación logrando mayor cantidad de imágenes en la base de datos (800 gráficas); en cada imagen hay en una media de 22 a 60 huevos de gallina (*Ver figura 7*).
- Luego del proceso de customizado (aumentación de imágenes) se importan a la web de Supervisely para el etiquetado, ahora existen dos archivos la imagen junto a su contraparte en coordenadas en archivo de texto con la ubicación x, y, z de cada tipo de huevo identificado

Class Balance

There are 4 annotation classes in the dataset. Inspect general statistics and imbalances for every class, highlight over- and under-represented classes in your dataset. Knowing class imbalance allows using custom batch sampling strategies for NN training to improve model accuracy, or adjusting the data acquisition process to balance the class distribution. Click any row to preview images that have objects of the selected class. Sort by column to find the most rare or prevalent classes.

Class	Images	Objects	Count on image average	Area on image average
sano mask	3546	64116	18.08	12.29%
sucio mask	3042	21816	7.17	4.71%
fugoso mask	2430	12456	5.13	3.46%
roto mask	1458	9702	6.65	4.44%

Figura 7. Cantidad de fotogramas por categoría

3.4. Fase de modelado

El producto del supervisely se exporta a VisualStudio, este da como resultado una carpeta que contiene las imágenes, coordenadas, ubicación y colores respectivos; luego se programa el modelo de entrenamiento mediante eras (veces que aprende), cabe destacar que se emplea la red neuronal YoloV8n (ver figura 8). El número de épocas depende de la potencia del hardware donde se entrena la IA, mientras más épocas más recursos exige, demora más hora y por ende, aprende mejor a clasificar los huevos.

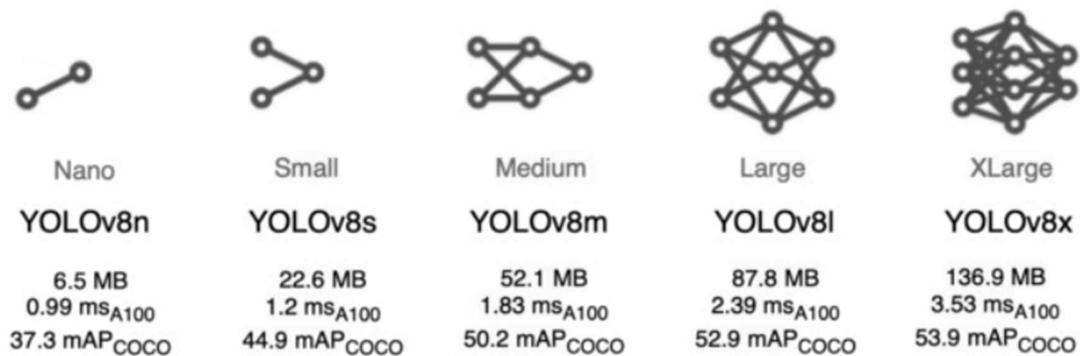


Figura 8. Tipo de red neuronal empleada en el proyecto

Para describir la metodología se aplica un entrenamiento de cinco épocas con 89 imágenes (Ver Figura 9), es análogo a las aulas de clase cada época es una vez que estudia los fotogramas comparando cada clase de huevo etiquetada; luego se programa el nivel de aceptación (95%) es decir, que a medida que cursa cada ciclo aumenta la probabilidad de éxito en clasificar, hasta obtener 99% al final. En el modelo usado en el prototipo se trabajó a 50 épocas empleando un ordenador de escritorio tardando alrededor de 12 horas en procesar el aprendizaje.

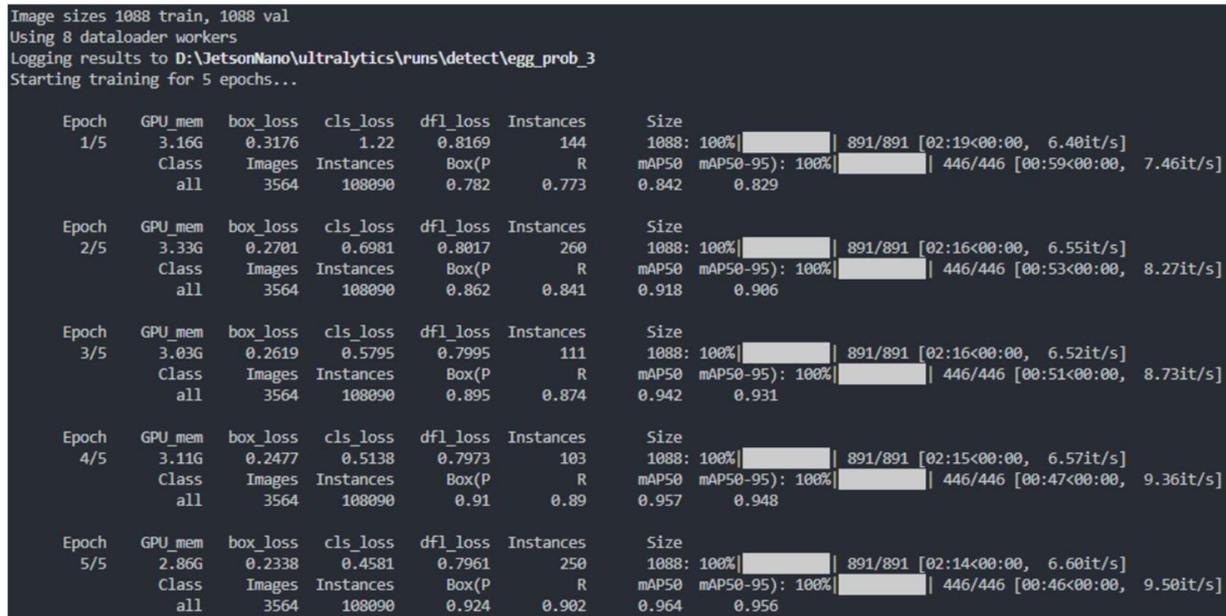


Figura 9. Entrenamiento de la IA mediante modelo de aprendizaje

Finalmente, se logra las curvas de precisión al identificar cada modelo y del VisualStudio se obtiene el archivo ejecutable para ser exportado al Jetson Nano; una vez que se carga el modelo se procede a evaluarlo mediante videos o en campo como se detalla en los siguientes apartados

3.5. Fase de evaluación

La predicción es para probar el modelo, mientras que el ejecutable es lo que se observa en producción en el campo. Una vez que se carga el ejecutable best.pt se llama la cámara en el puerto 0, luego se elige la resolución 960 x 960 pixeles, lo cual depende del tamaño de la pantalla que muestra las imágenes (ventana), lo ideal es que se coloque en Auto para que se ajuste a la mejor visualización posible. El Jetson Orin Nano puede trabajar hasta con tres cámaras para supervisar hasta tres líneas de transporte de huevos, esto facilita escalar a pequeñas o medianas granjas sin un costo adicional salvo las cámaras (\$90 Usd). El modelo entrenado se importa hacia el VisualStudio en el sistema operativo Linux, se indica las variables a mostrar como el peso de la

confianza (mayor a 0.90), clasificación (0 sano, 1 rugoso, 2 sucio y 3 roto), colores (verde, rojo, azul y morado) con estas variables se evalúa el modelo de predicción con imágenes o videos (Ver *figura 10*).

En el *Anexo 2* se observa la puesta en marcha del prototipo poniendo a prueba su eficiencia frente al director del proyecto.

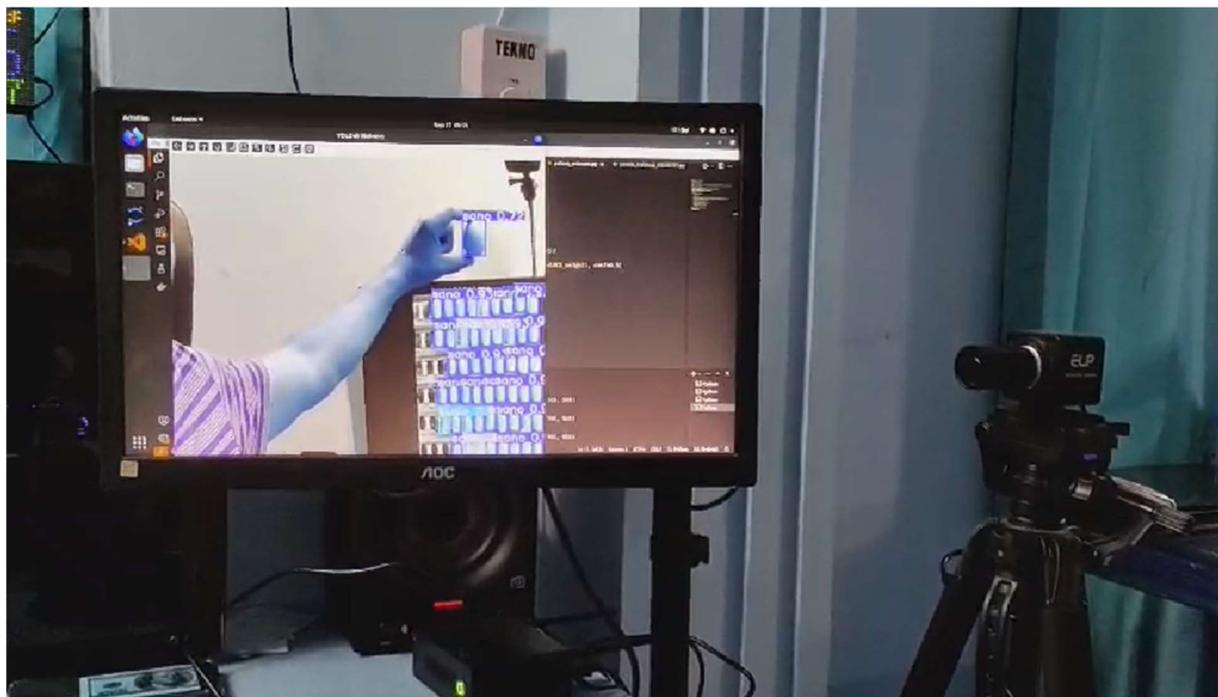


Figura 10. Evaluación del modelo entrenado en la detección de huevos de gallina

A continuación, se utiliza la función Tracked, la cual permite una ejecución en tiempo real que asigna un identificador numérico a cada huevo. Esto significa que cada objeto en la imagen mantiene la misma identificación (ID) mientras se encuentra en el campo visual. Esta característica es crucial ya que, aunque un huevo cambie de clasificación al rotar, su ID permanece constante, permitiendo así un seguimiento preciso de la clasificación y contabilidad de cada huevo.

Los FPS (fotogramas por segundo) varían según la capacidad de procesamiento del ordenador, pudiendo ser 60, 11, 10 u otros valores, mientras se analizan los huevos en la ventana de visualización. Una vez clasificados, los huevos se marcan con colores específicos y sus respectivas identificaciones y coordenadas se muestran en un monitor. Esto facilita al operador tomar las acciones necesarias: los huevos sanos continúan hacia la cubeta, los sucios se retiran para su limpieza, los rugosos se apartan para su venta a panaderías y los quebrados se dirigen a un depósito

mediante una rampa. En el caso de que un huevo presente múltiples categorías, se configura con un sistema de prioridades (sano=0, rugoso=1, sucio=2, roto=3), donde los valores superiores a 0 predominan.

Es importante señalar que la interfaz de la ventana incluye una línea naranja que divide el área en coordenadas X1, X2, Y1, Y2 (Ver figura 11). Esta línea es fundamental para contar los huevos al atravesarla, facilitar su localización en la pantalla y exportar estas coordenadas a un archivo de texto. Esto no solo permite un control de la producción por clases sino también la integración con otros sistemas o dispositivos de salida (como pantallas adicionales) si fuera necesario.

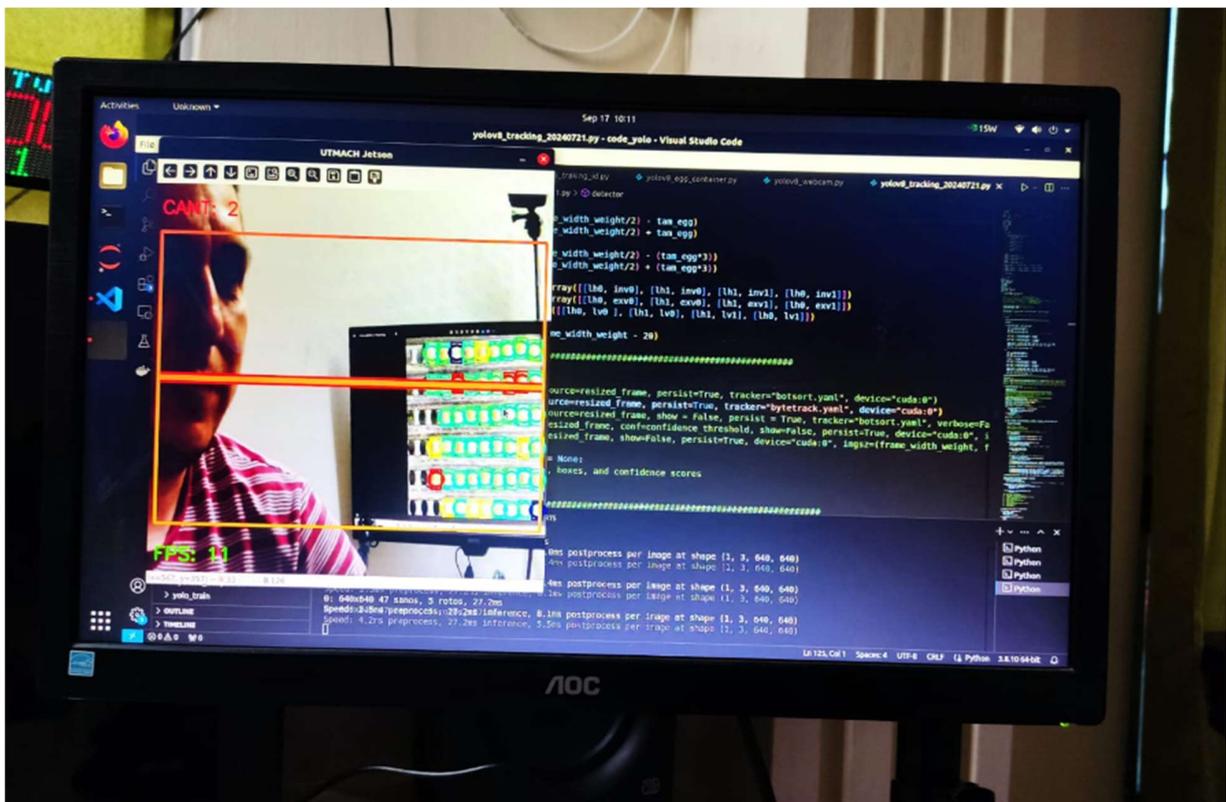


Figura 11. Puesta en marcha del modelo entrenado (ejecutable) con imágenes

El detalle del proceso metodológico describe paso a paso el desarrollo, ejecución, práctica y puesta en marcha del prototipo; destacando que es un método empírico del tipo pragmático donde sobre la marcha se busca soluciones e investiga hasta satisfacer los requerimientos, mismos que se analizan en el siguiente apartado.

En esta fase para el entrenamiento personalizado del modelo es necesario efectuar los siguientes pasos:

1. Prepara los conjuntos de datos anotados.
2. Configura los parámetros de entrenamiento en un archivo YAML
3. Utiliza el *Yolo Train* para iniciar el entrenamiento.

Para poder preparar los datos es necesario crear un datasheet personalizado. Se realizó un video a través de la banda transportadora en diferentes momentos para obtener las 4 clases principales que se presentan en la granja de gallinas (sano, sucio, rugoso, roto), tal como se aprecia en la figura 12.



Figura 12. Captura de los huevos de gallina en la banda transportadora

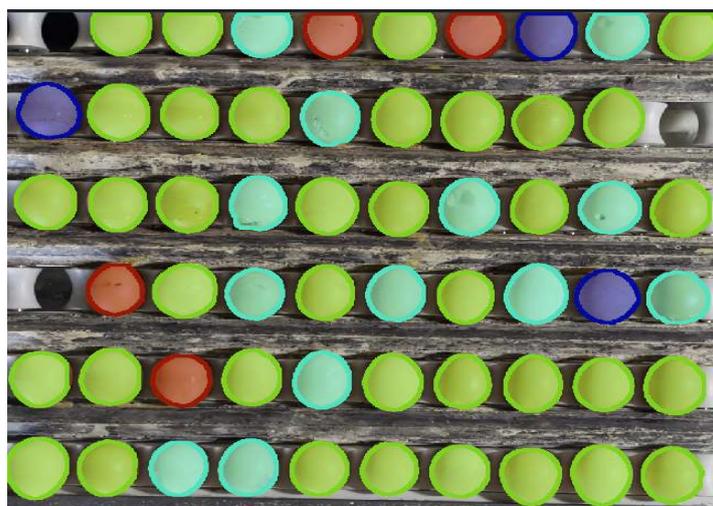


Figura 13. Etiquetado por colores de cada clase de huevo de gallina

Luego se realizó una conversión de video a frames (cuadros por segundo), no es otra cosa que el video convertirlo en un conjunto de imágenes y luego seleccionar manualmente las que representan las condiciones para el modelo de aprendizaje. En total se obtuvo un conjunto de 200 imágenes con una media de 60 a 120 huevos de gallina (objetos a clasificar) en cada fotograma. En estas imágenes se deben etiquetar individual cada tipo de huevo, para ello se utiliza el programa en línea www.supervisely.com que permite realizar el etiquetado en forma ágil y rápida.

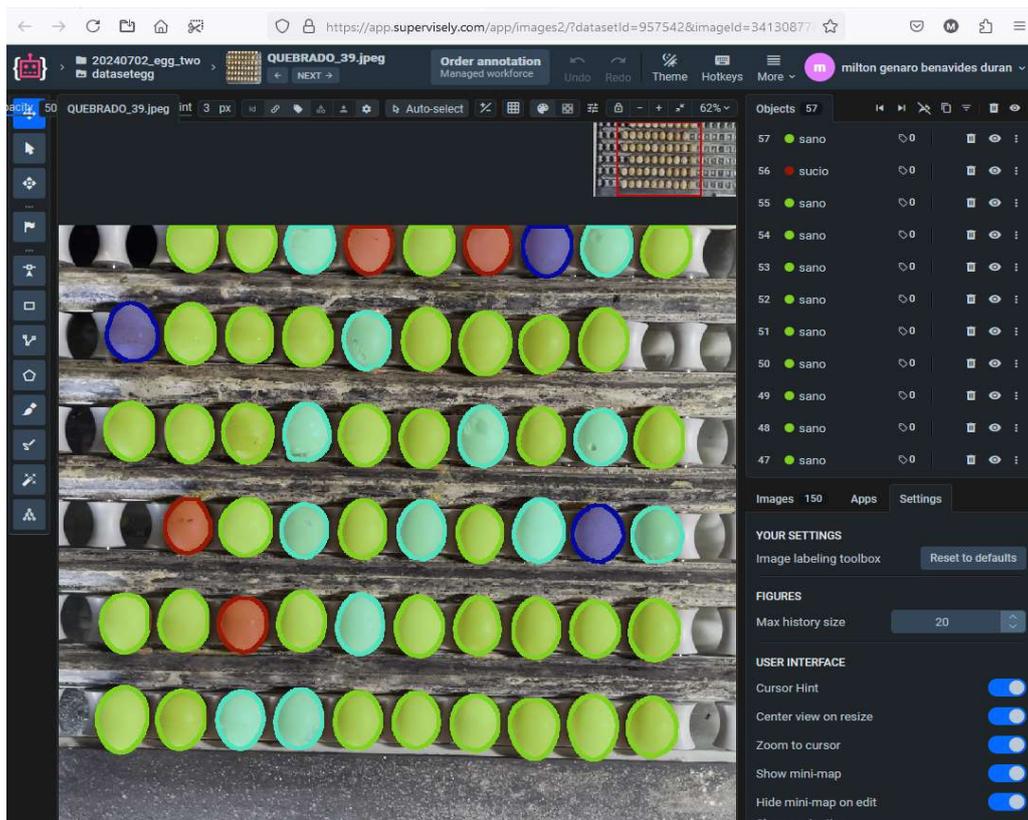


Figura 14. Proceso de etiquetado manual por color de cada clase de huevo

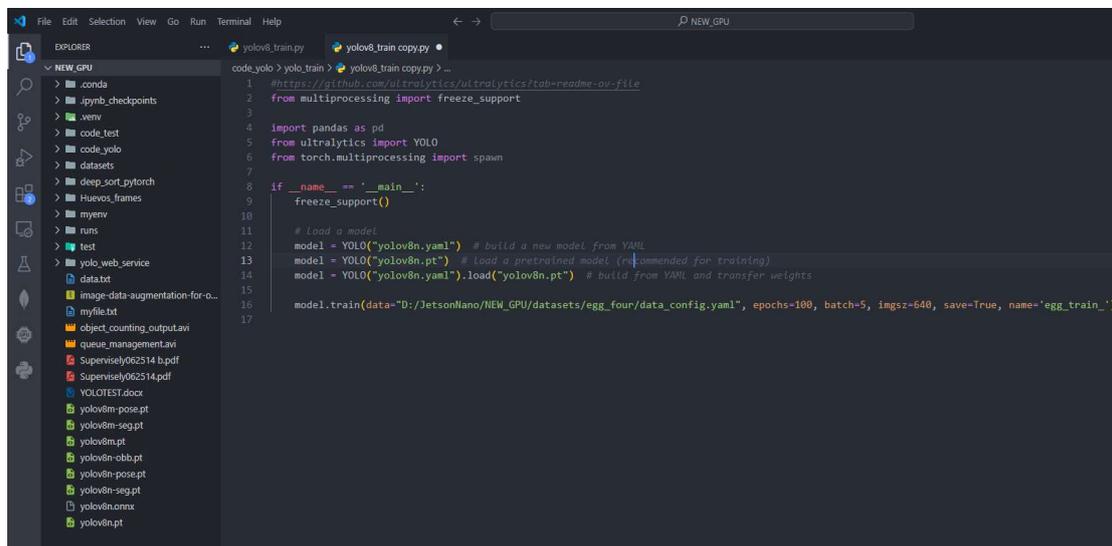
En la *figura 13* y *14* se detalla el procedimiento, seleccionar cada huevo como objeto, colorearlo verde para sanos, azul rugoso, morado roto y rojo sucio; al diferenciar cada huevo como aquello que se debe detectar e identificar el programa caracteriza cada grupo aprendiendo como catalogarlos a través de iteraciones. Estos *objetos* se mapean mediante coordenadas para distinguirlos al compararlos con nuevos huevos por clasificar.

```
data_config.yaml
1 path: D:/JetsonNano/NEW_GPU/datasets/egg_four
2 train: images/train
3 val: images/train
4
5 nc: 4
6 names: ['sano', 'roto', 'rugoso', 'sucio']
7
8 colors:
9 sano: [126, 211, 33]
10 roto: [80, 227, 194]
11 rugoso: [3, 11, 160]
12 sucio: [153, 25, 6]
```

Figura 15. Clasificación de los huevos por etiquetado en el software de programación

Una vez finalizado el proceso de etiquetar los fotogramas, se exporta el modelo en formato YOLOv8, se realizan las imágenes y anotaciones en Supervisley.com hacia el software VisualStudioCode (depurador y editor de código fuente para sistema operativo Windows) para compilar el programa que ejecutará el modelo de entrenamiento, este proceso se puede observar en las *figuras 15*.

Previamente a emplear Yolo Train se sugiere compilar en Python el módulo de entrenamiento instalado en Visual Studio Code por medio de Ultralytics (visión por computadora).



```
code_yolo > yolo_train > yolo8_train copy.py > ...
1 #https://github.com/ultralytics/ultralytics/blob/main/README.md
2 from multiprocessing import freeze_support
3
4 import pandas as pd
5 from ultralytics import YOLO
6 from torch.multiprocessing import spawn
7
8 if __name__ == '__main__':
9     freeze_support()
10
11     # Load a model
12     model = YOLO("yolov8n.yaml") # build a new model from YAML
13     model = YOLO("yolov8n.pt") # load a pretrained model (recommended for training)
14     model = YOLO("yolov8n.yaml").load("yolov8n.pt") # build from YAML and transfer weights
15
16     model.train(data="D:/JetsonNano/NEW_GPU/datasets/egg_four/data_config.yaml", epochs=100, batch=5, imgsz=640, save=True, name='egg_train_')
17
```

Figura 16. Depuración del código de entrenamiento en Visual Studio Code

El modelo importado desde Ultralytics.com se basa en el ejemplo ilustrado en la *figura 16*.

```

Single-GPU and CPU Training Example

Device is determined automatically. If a GPU is available then it will be used, otherwise training will start on CPU.

Python  CLI

from ultralytics import YOLO

# Load a model
model = YOLO("yolov8n.yaml") # build a new model from YAML
model = YOLO("yolov8n.pt") # load a pretrained model (recommended for training)
model = YOLO("yolov8n.yaml").load("yolov8n.pt") # build from YAML and transfer weights

# Train the model
results = model.train(data="coco8.yaml", epochs=100, imgsz=640)

```

Figura 17. Ejemplo del modelo importado

Fuente: [40]

Una vez compilado, probado y corrido (RUN) del programa, se pasa a la fase de aprendizaje, tal como se aprecia en la figura 17 donde se analizan inicialmente 200 imágenes en calidad de 1920 x 1080 pasando a ser dos fotogramas de 1080 x 1080 exportando un total de 640 x 640 imágenes de entrenamiento (figuras cuadradas); este proceso se llama “Aumentación” siendo aplicado a cada fotograma.

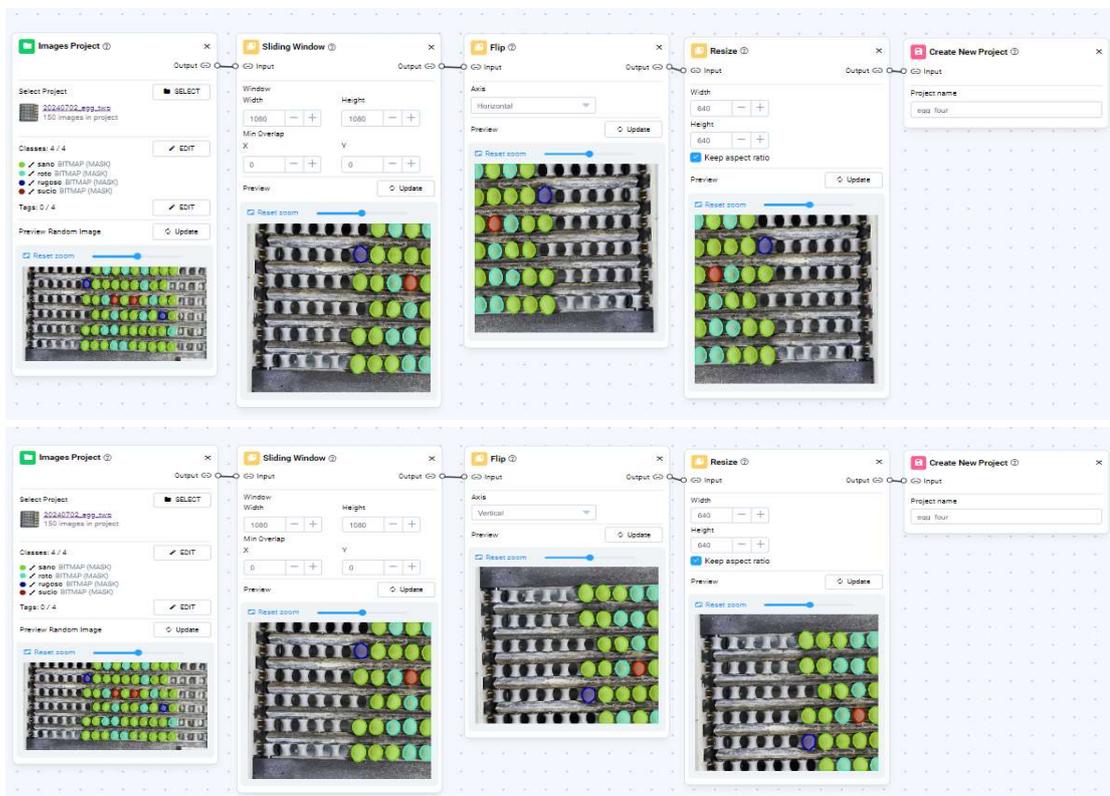


Figura 18. Proceso de aumentación con volteo vertical.

También es necesario configurar los cambios o movimientos por imagen (Ver figura 18), como las opciones de Rotar 90 grados, perspectiva transformación (convertir imagen a objetos), Random color (aumentar o variar tonalidades) y sus combinaciones facilitando que el programa aprenda con más fotografías a mayor calidad. En el Anexo 9 se aprecia este proceso al aumentar la cantidad de imágenes para el modelo de aprendizaje.

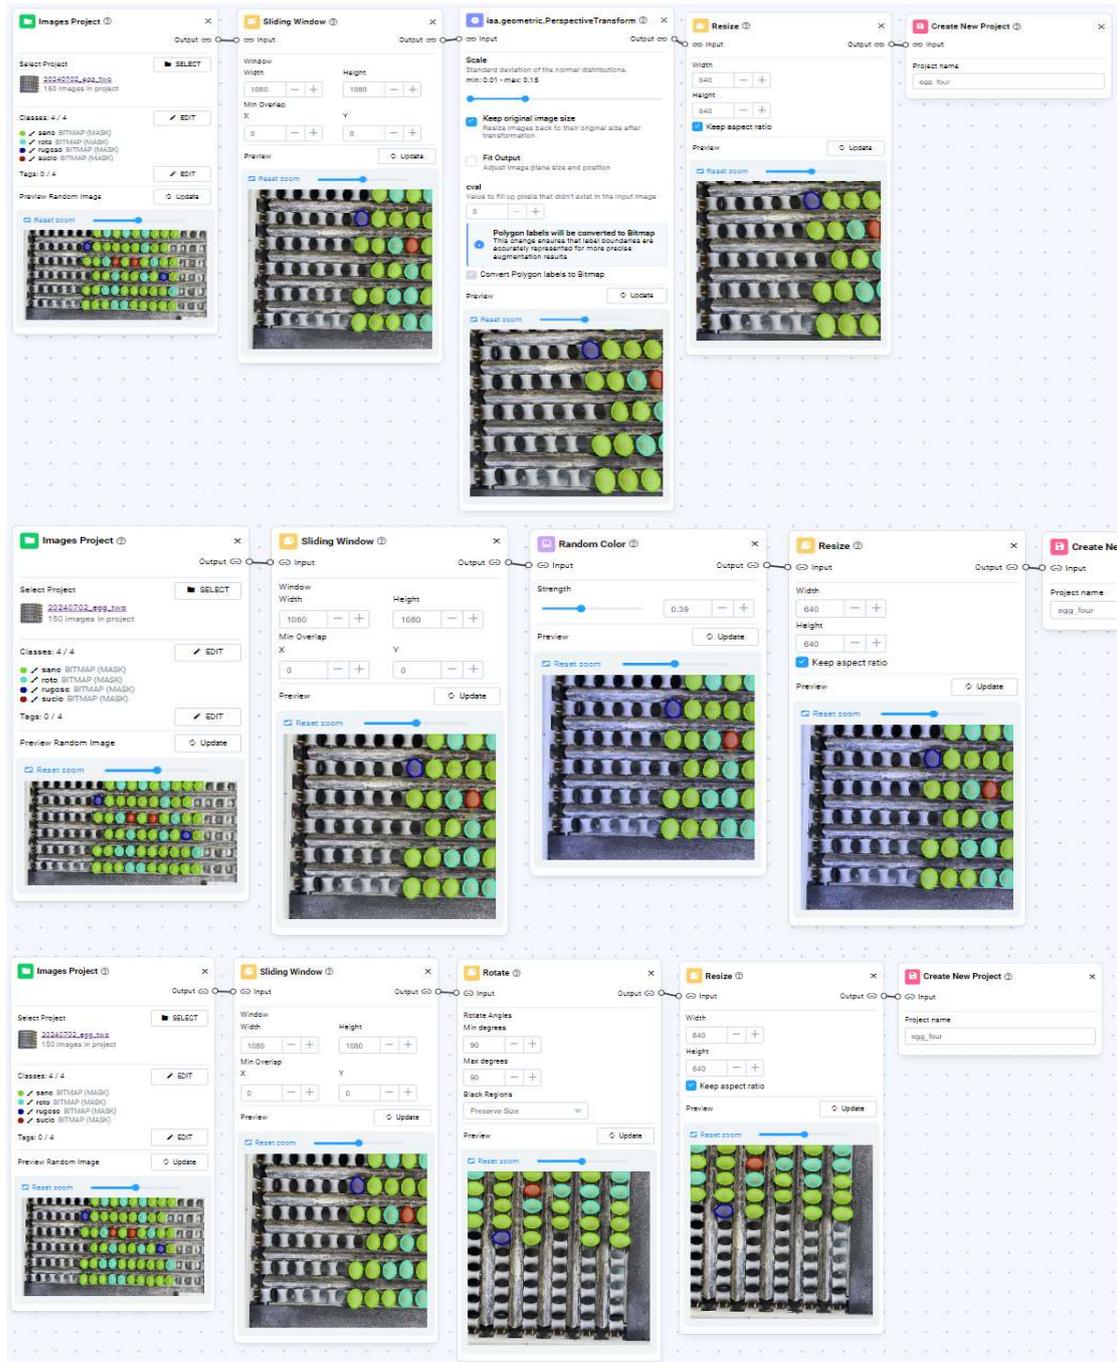


Figura 19. Opciones de imágenes en el modelo de entrenamiento

Al experimentar las opciones de combinaciones, mejoramiento de calidad y división en fotogramas se obtuvo de las 200 imágenes originales a un modelo de entrenamiento aumentado a 33468 figuras de referencia (Ver *figura 19*) para analizar e iterar aprendiendo a clasificar los huevos de gallina.

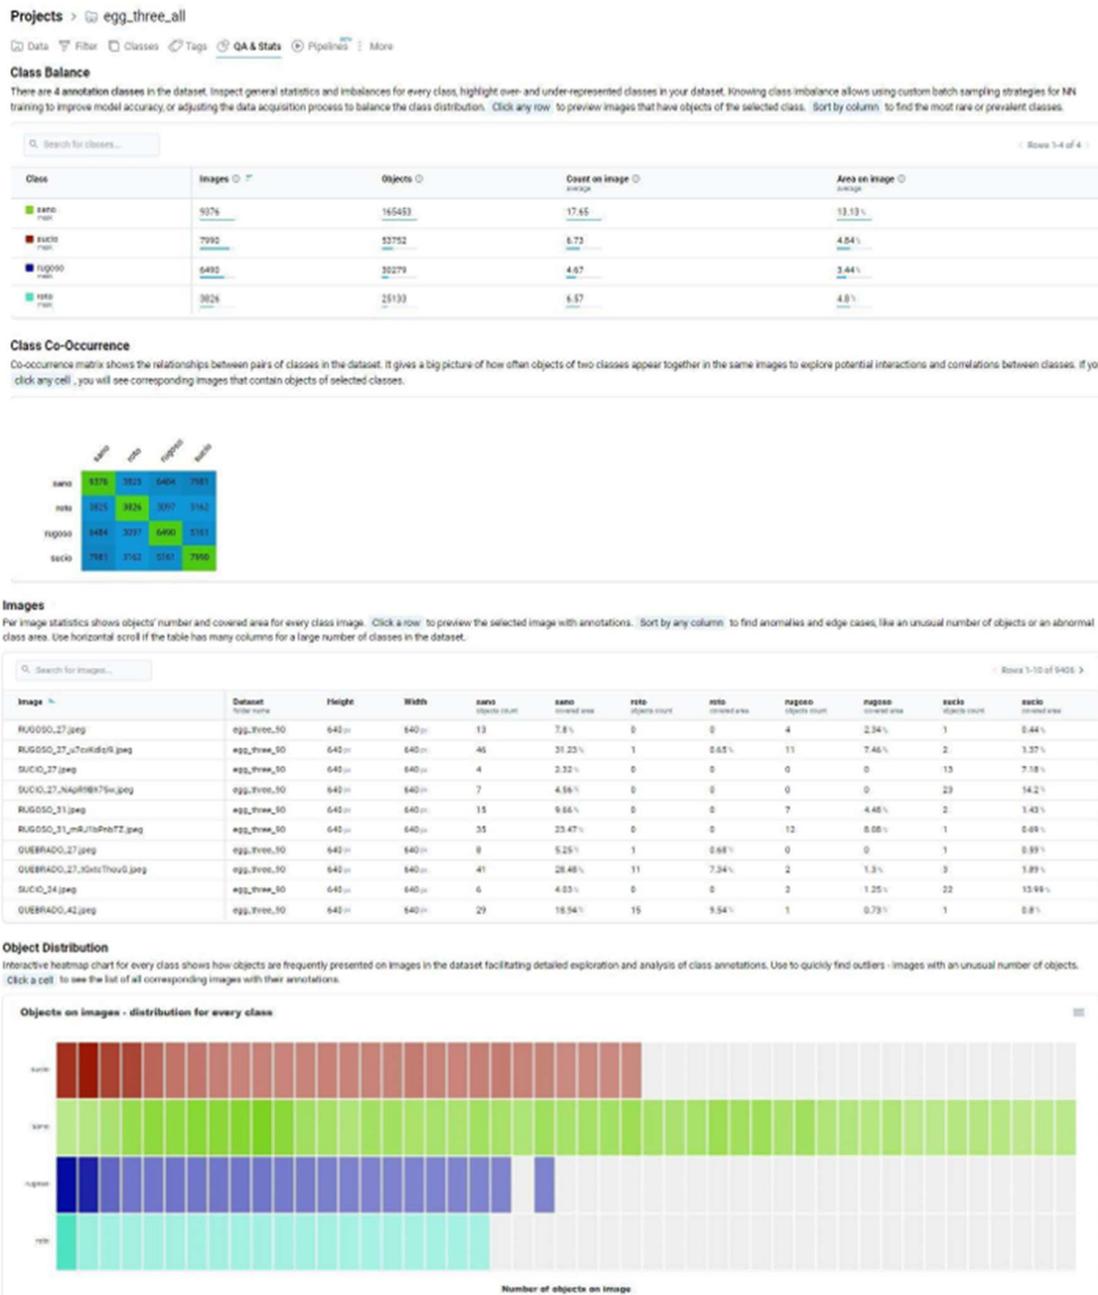


Figura 20. Fotogramas de entrenamiento (matriz de 33468 imágenes)

Objects

Table contains all 274617 objects and their geometrical properties. Click a row to preview an image with a specific label, search or use the pagination to navigate through all objects. Sort columns to find object outliers in the dataset.

Object ID	Class	Image name	Image size	Height	Height	Width	Width	Area
1	rugoso mask	RUGOSO_27.jpeg	640 x 640	56 px	8.75%	63 px	9.84%	0.66%
2	sano mask	RUGOSO_27.jpeg	640 x 640	55 px	8.59%	64 px	10%	0.63%
3	sano mask	RUGOSO_27.jpeg	640 x 640	54 px	8.44%	61 px	9.53%	0.6%
4	sucio mask	RUGOSO_27.jpeg	640 x 640	49 px	7.66%	62 px	9.69%	0.44%
5	sano mask	RUGOSO_27.jpeg	640 x 640	58 px	9.06%	65 px	10.16%	0.69%
6	sano mask	RUGOSO_27.jpeg	640 x 640	57 px	8.91%	64 px	10%	0.65%
7	rugoso mask	RUGOSO_27.jpeg	640 x 640	59 px	9.22%	65 px	10.16%	0.68%
8	sano mask	RUGOSO_27.jpeg	640 x 640	57 px	8.91%	69 px	10.78%	0.69%
9	sano mask	RUGOSO_27.jpeg	640 x 640	55 px	8.59%	67 px	10.47%	0.63%
10	sano mask	RUGOSO_27.jpeg	640 x 640	60 px	9.38%	68 px	10.62%	0.73%

Other Statistic

Datasets Images Image Tags Object Tags Objects Objects Area

	egg_three_augment	egg_three_fit_h	egg_three_fit_v	egg_three_0190	egg_three_normal	egg_three_90	Total
sano	43989 (61.22%)	30188 (39.85%)	15094 (39.85%)	7298 (60.48%)	4076 (39.63%)	4076 (39.63%)	165453 (60.23%)
roto	6501 (9.03%)	4634 (9.19%)	2317 (9.19%)	1099 (9.11%)	633 (9.26%)	633 (9.26%)	25133 (9.15%)
rugoso	7403 (10.30%)	5698 (11.30%)	2849 (11.30%)	1311 (10.87%)	790 (11.56%)	790 (11.56%)	30279 (11.09%)
sucio	13952 (19.42%)	9916 (19.66%)	4958 (19.66%)	2358 (19.54%)	1334 (19.32%)	1334 (19.32%)	53752 (19.57%)
Objects in dataset	71845	50436	25218	12066	6833	6833	274617

Figura 21. Estadísticas de la visión por computadora 274617 objetos (huevos clasificados)

En la figura 21 se aprecia los resultados del modelo de entrenamiento (Cuatro clases de huevos), a continuación, con el software VisualStudioCode se obtiene el datasheet personalizado preparado con la aumentación; se aplica un proceso de aprendizaje de 100 épocas (epoch), es decir, el modelo repasa 100 veces los fotogramas comparándolos con el modelo de etiquetado para aprender a clasificarlos; se elige 100 para obtener un nivel de confiabilidad aceptable. Los lotes o batch se definen como grupos de imágenes modeladas en el aprendizaje, como ejemplo sí se tienen 33468 imágenes a un lote de 50, se obtienen 33468/50 un total de 669 lotes.

El tamaño del lote depende de la potencia de procesamiento, tarjeta gráfica y recursos disponibles, haciendo pruebas para elegir el mejor tamaño del lote procurando que el procesador no se sature. En este caso a 100 epoch (épocas) y 50 lotes el entrenamiento tardó 4.23 horas; mientras que, en otras pruebas tomó alrededor de 18 horas al 80% de capacidad de la tarjeta gráfica.

```

98/100 2.38G 0.3 0.148 0.8024 519 640: 100% | 558/558 [01:37<00:00, 5.74it/s]
Class Images Instances Box(P R mAP50 mAP50-95): 100% | 279/279 [00:51<00:00, 5.37it/s]
all 8370 298562 0.999 0.993 0.995 0.972

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
99/100 2.35G 0.2989 0.1472 0.8015 480 640: 100% | 558/558 [01:34<00:00, 5.88it/s]
Class Images Instances Box(P R mAP50 mAP50-95): 100% | 279/279 [00:51<00:00, 5.37it/s]
all 8370 298562 0.999 0.993 0.995 0.972

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
100/100 2.38G 0.2989 0.1466 0.8019 491 640: 100% | 558/558 [01:34<00:00, 5.93it/s]
Class Images Instances Box(P R mAP50 mAP50-95): 100% | 279/279 [00:51<00:00, 5.37it/s]
all 8370 298562 0.999 0.993 0.995 0.972

100 epochs completed in 4.263 hours.
Optimizer stripped from D:\JetsonNano\ultralytics\runs\detect\egg_train_10\weights\last.pt, 6.3MB
Optimizer stripped from D:\JetsonNano\ultralytics\runs\detect\egg_train_10\weights\best.pt, 6.3MB

Ultralytics YOLOv8.2.35 Python-3.12.4 torch-2.3.1+cu118 CUDA:0 (NVIDIA GeForce GTX 1080 Ti, 11264MiB)
YOLOv8n summary (fused): 168 layers, 3006428 parameters, 0 gradients, 8.1 GFLOPs
val: Scanning D:\JetsonNano\NEW_GPU\datasets\egg_two\labels\train.cache... 8370 images, 0 backgrounds, 0 corrupt: 100% | 8370/8370
Class Images Instances Box(P R mAP50 mAP50-95): 100% | 558/558 [02:08<00:00, 4.33it/s]
all 8370 298562 0.999 0.994 0.995 0.974
sano 8370 179073 0.999 0.996 0.995 0.973
roto 3591 27446 0.999 0.993 0.995 0.974
rugoso 5999 34310 0.999 0.99 0.995 0.972
sucio 7545 57733 0.999 0.995 0.995 0.975

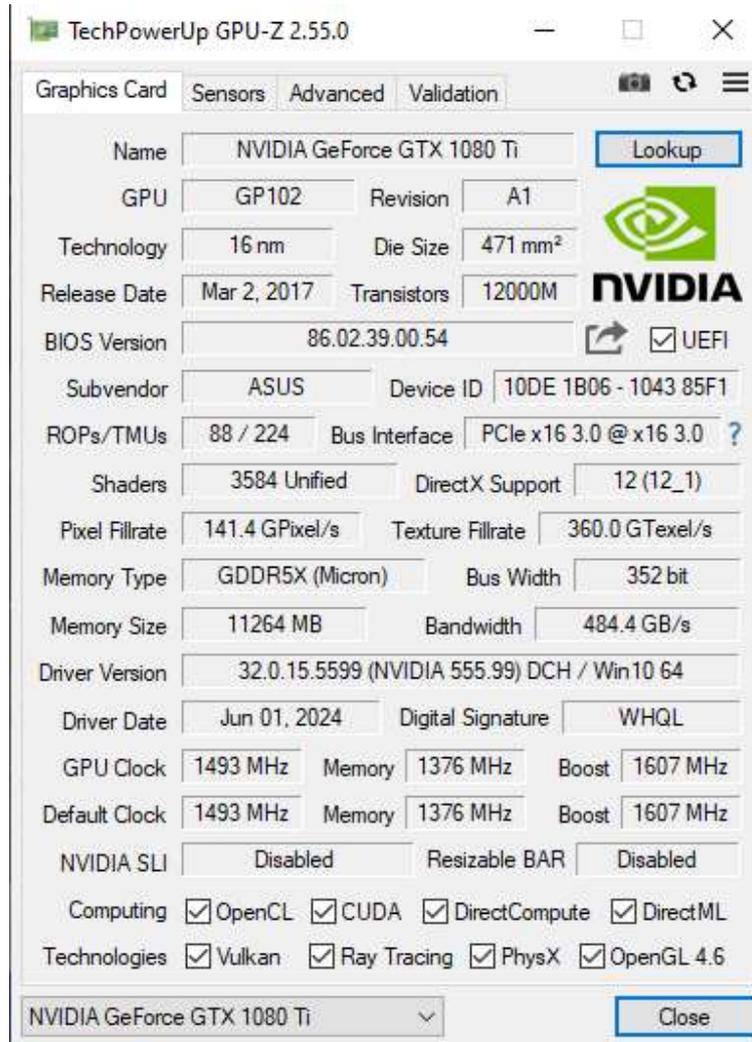
Speed: 0.3ms preprocess, 2.7ms inference, 0.0ms loss, 0.8ms postprocess per image
Results saved to D:\JetsonNano\ultralytics\runs\detect\egg_train_102
WARNING ⚠ updating to 'imgsz=640'. 'train' and 'val' imgsz must be an integer, while 'predict' and 'export' imgsz may be a [h, w] list or an
Validating D:\JetsonNano\ultralytics\runs\detect\egg_train_10\weights\best.pt...
Ultralytics YOLOv8.2.35 Python-3.12.4 torch-2.3.1+cu118 CUDA:0 (NVIDIA GeForce GTX 1080 Ti, 11264MiB)
YOLOv8n summary (fused): 168 layers, 3006428 parameters, 0 gradients, 8.1 GFLOPs
Class Images Instances Box(P R mAP50 mAP50-95): 100% | 279/279 [02:01<00:00, 2.29it/s]
all 8370 298562 0.999 0.993 0.995 0.972
sano 8370 179073 0.999 0.996 0.995 0.971
roto 3591 27446 0.999 0.993 0.995 0.972
rugoso 5999 34310 0.999 0.99 0.995 0.971
sucio 7545 57733 0.999 0.995 0.995 0.973

Speed: 0.2ms preprocess, 2.0ms inference, 0.0ms loss, 0.8ms postprocess per image

```

Figura 22. Configuraciones de lotes para los entrenamientos

En la figura 22 se aprecia los lotes y pruebas hasta dar con la mejor alternativa para el proceso de entrenamiento de la IA.



*Figura 23. Datos de la tarjeta gráfica del prototipo (AMD Ryzen 7 5700G, 3.8 Ghz) a 32 Gb RAM
Instalada*

Las prestaciones del hardware con el que se corre el modelo se detallan en la *figura 23*, luego de finalizar el aprendizaje se puede observar los resultados en función de las anotaciones e imágenes de los huevos (objetos) clasificados.

3.6. Fase de despliegue

En el proceso de entrenamiento, al realizar la actualización del modelo se logra una precisión de:

- ❖ Sano 0.995
- ❖ Roto 0.995
- ❖ Rugoso 0.995
- ❖ Sucio 0.995

Estos valores son virtuales al probar la IA con videos de prueba, al llevarla al campo se obtiene la precisión real con los ajustes necesarios y desempeño real bajo condiciones de funcionamiento no controladas.



Figura 24. Prueba del aplicativo y verificación del modelo de predicción

Al inicio del mecanismo se tiene un operador que identifica el galpón de donde viene la producción, va limpiando los huevos, luego pasan a un vibrador que los distribuye en filas, la banda los lleva hacia otro operador que retira los huevos rotos, se acomodan por tamaño (peso) para completar los 4.5 Kg por cubeta. Los huevos demasiado grandes de doble yema son rechazados, los huevos con pintas de sangre o a aquellos que presenten anomalías.

Al poner a prueba el prototipo se observó que la iluminación no era la misma que la presente en los videos de entrenamiento, debiendo ajustar el parámetro de sensibilidad evitando falsos positivos y en general se obtuvo una precisión del 95% al 99% en contraste con las simulaciones y huevos contados en la maquinaria (*Ver figura 24*).

De acuerdo con el inspector (experto en la producción/clasificación de huevos de gallina) el proceso es contar los huevos, separarlos, pesarlos y determinar los huevos por hora, por galpón, por día, rechazados y cuántas cubetas se llenan; en este caso la IA proporcionada facilita clasificarlos e indicar al operador cuáles sacar la colorear el objeto en pantalla; la maquinaria usada es la FORZA GT 100 de MOBA [41] con capacidad de 36000 huevos por hora, 1 carril transportador, 6 carriles de alimentación, mínimo 2 y máximo 18 líneas de empaquetado; su desventaja es el elevado costo, mantenimiento e imposibilidad de adaptarla a las nuevas necesidades, mejorar su eficiencia y escalable a medida que crece la granja; por ende, un prototipo con IA es una solución más accesible logrando una eficacia similar a un costo significativamente menor.

3.7. Presupuesto

El aplicativo debe ser de bajo presupuesto para que sea accesible en las empresas e industrias avícolas locales, en general cada línea de procesamiento de huevos de gallina cuesta en promedio \$70 000 Usd (dólares americanos) y un robot o instalación capaz de detectar/clasificar los tipos de huevos junto a un brazo mecánico que los separe cuesta en promedio alrededor de \$100 000 Usd; con estas referencias se diseña el prototipo para comparar el criterio de costos.

Tabla 3. Recursos necesarios para fabricar el prototipo

Recursos	Precio (\$ Usd)	Descripción
Nvidia Rapson Nano	400	Mini ordenador para correr el programa
Cámara	90	Con zoom óptico y resolución 1080
Trípode	30	Con base ajustable y extensible
Tarjeta gráfica Gpu Nvidia	200	GPU para realizar el entrenamiento en el computador
Desarrollo del aplicativo	500	Mano de obra calificada al programar el modelo
Modelo de entrenamiento	200	Recursos para entrenar a la IA y correr las simulaciones
Transporte, alimentos y otros	50	Costos de movilización y viáticos para probar el prototipo

El costo asciende a \$1470 Usd, es significativamente bajo al compararse con las máquinas e instalaciones comerciales en la industria avícola, en especial en las granjas de huevos de gallinas; además, es necesario destacar que su eficiencia en consumo, mantenimiento y escalabilidad es mayor a las máquinas prefabricadas, gracias a que se puede realizar de forma compacta, modular e integrar a nuevos sistemas o tarjetas capaces de comunicarse con las instalaciones ya existentes para optimizar sus procesos.

En [42] se vende una clasificadora de huevos de procedencia asiática con capacidad de 4000 huevos por hora, 220 voltios, 200 vatios y 1.5 m x 1.38 m x 0.98 m a un valor de \$3100 Usd para una cinta transportadora y no es adaptable a otras necesidades solo condiciones de fábrica; otra clasificadora de huevos en [43] en Alibaba.com permite hasta dos líneas 5000 huevos, cuatro clases y no es del todo automática requiere un operador que los retire e ingrese en las cubetas, costando alrededor de \$5000 Usd; ahora en comparación con el prototipo que es adaptable, escalable a otras líneas y se puede mejorar con brazo robótico son más costosas e incluso el proceso de compra o garantías complica su adquisición en contraste con alternativas locales; por ende, se destaca que prototipos similares existen a un costo mayor validando el monto de inversión en el proyecto; además puede ser replicado fácilmente a otras granjas o comercializado para cadenas de producción similares.

CAPÍTULO IV: DISCUSIÓN DE RESULTADOS

Se presentan los hallazgos y resultados obtenidos de la puesta en marcha del prototipo, realiza la comprobación de la hipótesis y discute los resultados con otros estudios o proyectos similares validando los hallazgos mediante los argumentos de otros autores.

4.1 Diseño de pruebas

En la práctica se dieron las siguientes observaciones:

4. La iluminación debe ser la adecuada, similar a la realizada en el entrenamiento
5. El color de los ejes rotatorios es amarillo, en el entrenamiento eran blancos causando falsos positivos, se debió subir el nivel de precisión a 0.9
6. La cámara debe tener zoom físico no solo digital y un estabilizador para no ser afectada por las vibraciones del separador de huevos
7. La producción de huevos es por hora y por galpones (España, Cuba, Canadá, Suiza)

En el *Anexo 7* se observan los resultados de la producción de la granja, siendo en promedio alrededor de 36000 huevos por hora, de los cuales aproximadamente 80 salen rotos y son descartados. En el *Anexo 3* se aprecia la instalación del prototipo sobre la banda transportadora para obtener la tasa de éxito real al categorizar los huevos.

4.1.1. Métricas de evaluación

Las redes neuronales se evalúan en función de la eficiencia de su aprendizaje, es decir, cuan efectivo es el modelo al clasificar huevos sobre una tasa del 100%; es necesario enfatizar que las clases se determinan por colores, estos se numeran del 0 al 3 y en de acuerdo con la cantidad de aciertos se obtiene un porcentaje referencial. Las métricas son:

- Huevos rotos
- Huevos sucios
- Huevos rugosos
- Huevos sanos
- Tasa de éxito
- Matriz de confusión

La matriz de confusión analiza el total de objetos con las imágenes de entrenamiento sobre la veracidad de la clasificación del modelo neuronal sobre un porcentaje del 100%.

4.2. Resultados

La diagonal de la matriz de confusión representa el acierto de cada clase; por ejemplo, si en la categoría "roto/roto" se han identificado correctamente 27,259 huevos (color azul), esto indica que estos objetos fueron clasificados como rotos con precisión. Sin embargo, también existen 8 huevos cuya clasificación entre "roto" y "sucio" no es clara para el algoritmo, reflejando una incertidumbre en la categorización. La matriz de confusión gradualmente aclara el color hacia el blanco, donde el valor de 1.7 indica la probabilidad de que un huevo pertenezca a una categoría u otra, acercándose a 1 cuando la predicción es más precisa.

Según el estudio [44], la matriz de confusión es crucial para evaluar la precisión de la clasificación de objetos mediante visión por computador. La diagonal principal de esta matriz muestra cuántos objetos fueron clasificados correctamente, es decir, donde la predicción coincide con la observación real (*Ver figura 25*). Los valores fuera de la diagonal representan las clasificaciones incorrectas. Una matriz donde los valores se aproximan a uno es indicativa de una alta precisión en la interpretación visual; en este caso, un valor de 1.7 se aproxima a 1, lo que es un indicador de un alto número de predicciones correctas.

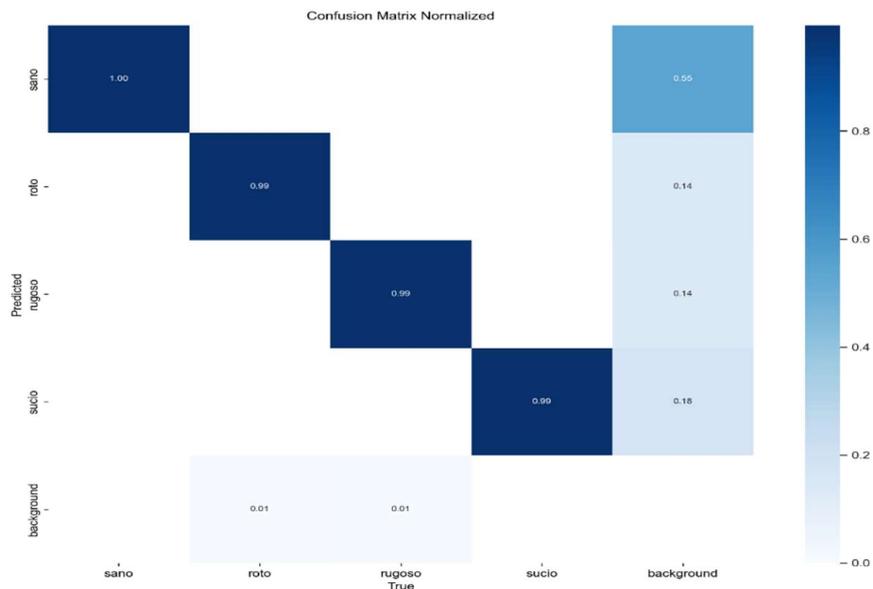


Figura 25. Matriz de confusión para huevos rotos (azules)

En el *Anexo 4* se evidencia la prueba e implementación del aplicativo; donde se entrena la modelo para lograr un nivel de precisión aceptable.

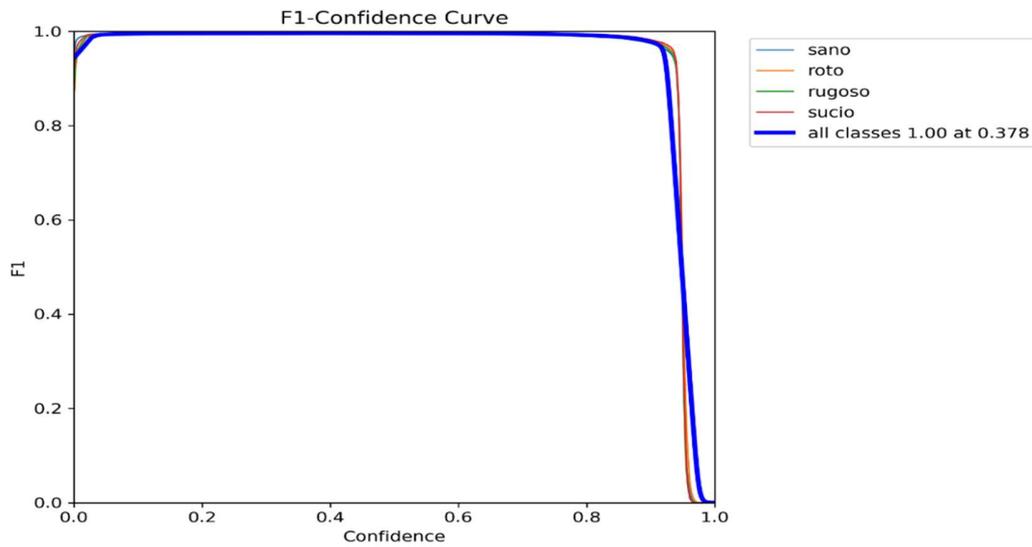
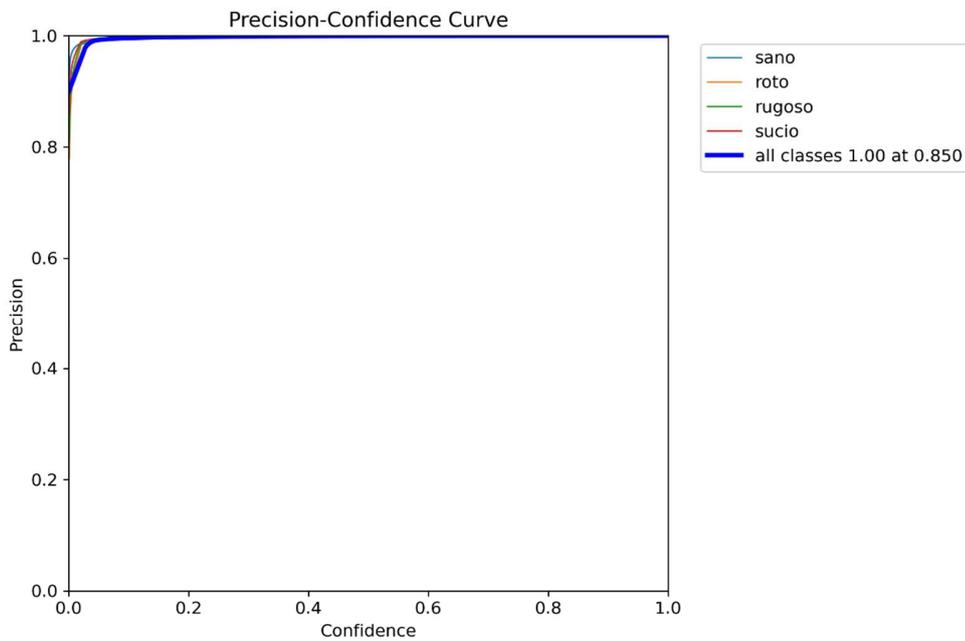


Figura 26. Matriz de confusión expresada en curvas de probabilidades

En los resultados de las cuatro categorías, se obtiene un valor de confianza elevado cercano a 1, es decir, el 100% de objetivos clasificados (Ver *figura 26* y *figura 27*), el rango es del 85% al 100% con una media del 95% de confiabilidad.



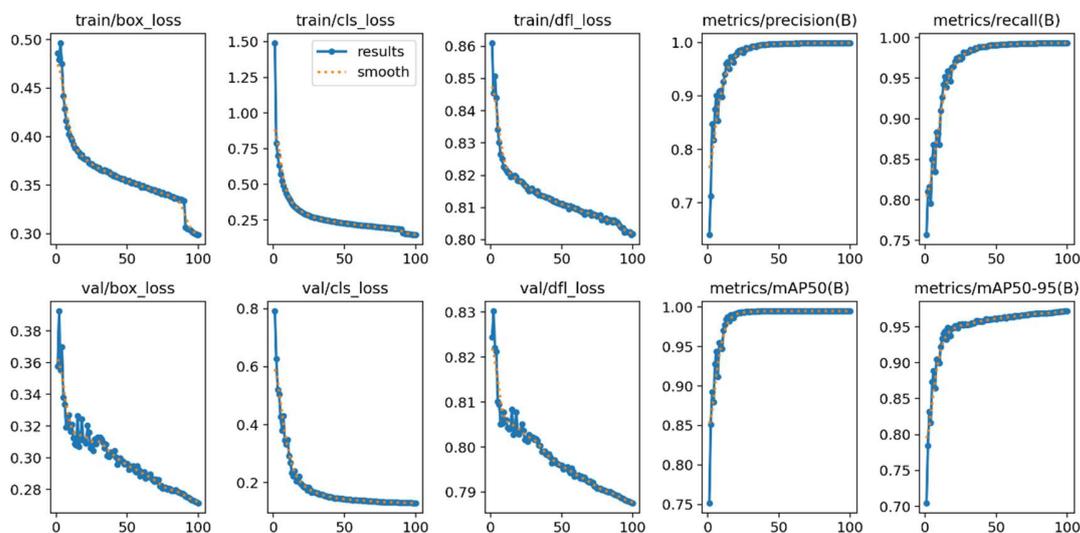


Figura 27. Métricas resultantes del proceso de aprendizaje (probabilidad y nivel de confianza)

En el Anexo 5 se observa la vista de la banda transportadora donde pasan y son recibidos los huevos de gallina a clasificar; esto es necesario para comparar la eficiencia del modelo evaluando si cumple con los requerimientos de diseño.

4.3. Prueba de hipótesis para proporciones

De acuerdo con el estudio [45] esta prueba también conocida como McNemar se aplica al comparar dos proporciones de datos en una misma población; es decir, se evalúa el efecto en el nivel de confianza antes y después del tratamiento de datos. Se agrupa las probabilidades bajo una distribución binomial; el estadístico es ρ donde $\rho' = \frac{x}{n}$, x es el número de aciertos mientras que n es el tamaño de la muestra analizada.

- ❖ *Hipótesis nula, H0*: El nivel de precisión alcanzado del prototipo implementado en hardware Nvidia, No supera el 95% de tasa de aciertos
- ❖ *Hipótesis Alternativa, H1*: El nivel de precisión alcanzado del prototipo implementado en hardware Nvidia, Supera al 95% de tasa de aciertos

Las hipótesis derivan directamente de la hipótesis general y se verifican en base a los resultados observados en campo al poner a prueba el modelo de clasificación por IA.

4.3.1. Criterio de selección del estadístico

Se debe calcular el valor del estadístico Z para elegir una región de rechazo o zona de aceptación, esto se aprecia en la *figura 28*.

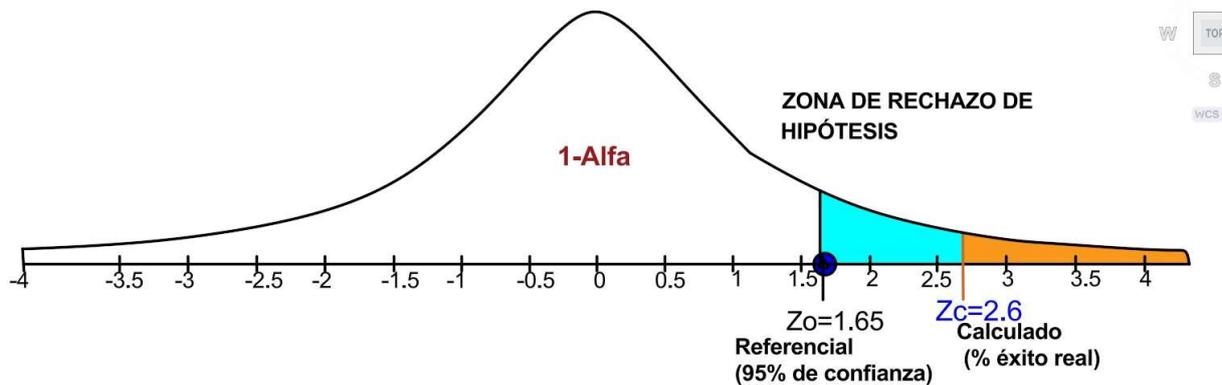


Figura 28. Zona de rechazo en función del estadístico Z

Fuente: [45]

El nivel de confianza es del 95%, por lo tanto, el nivel de significancia es de 0.05 es decir, α (Alpha). Se aplica la siguiente fórmula para calcular Z

$$z = \frac{\hat{p} - p_0}{\sqrt{\frac{p_0(1 - p_0)}{n}}}$$

Donde:

- ❖ \hat{p} es la proporción observada (0.99), se obtiene de la tasa de éxito referencial del supervisor que clasifica los huevos 99%
- ❖ p_0 es la proporción esperada según la hipótesis nula (0.95)
- ❖ n es el número total de observaciones (200 imágenes); de entre las cuales el modelo calcula el porcentaje de éxito siendo 99%

Al aplicar los valores se obtiene:

$$z = \frac{0.99 - 0.95}{\sqrt{\frac{0.95 * (1 - 0.95)}{200}}} = \frac{0.04}{0.015}$$

$$Z = 2.6$$

Para comprobar la hipótesis se aplica el siguiente criterio:

$$H_0: P_0 \leq 95\%$$

$$H_1: P_0 \geq 95\%$$

En base a los resultados, se rechaza la hipótesis nula H0

4.3.2. Conclusión de la prueba de hipótesis

El parámetro de prueba Z es 2.6 siendo mayor que el estadístico Zc de 1.65 para un nivel de confiabilidad del 95%.

$$Z_0 \geq Z_c, \text{ siendo } 2.6 \geq 1.65$$

Por lo tanto, se acepta H1 concluyendo que la probabilidad en la precisión del prototipo es *Superior al 95%* para las muestras tomadas (videos y en campo), respondiendo satisfactoriamente a las interrogantes del estudio.

4.4. Discusión de resultados

La ciencia [46] ha evidenciado que la revolución digital no solo afecta a los sectores tecnológicos sino también a los tradicionales como la ganadería. Aquí, la inteligencia artificial (IA) mediante visión computacional automatiza tareas como el conteo de ganado, específicamente ovejas, con una precisión del 99%, además de estimar otros parámetros como el peso de los animales. Este nivel de precisión se refleja también en la clasificación de huevos de gallina, alcanzando una confianza cercana al 99%, lo que demuestra la fiabilidad de estos sistemas.

Asimismo, Alanís y colaboradores [47] aplicaron el modelo YOLOv8 para clasificar tipos de vidrio, utilizando imágenes de 640 x 640 píxeles, 400 épocas de entrenamiento y diferenciando entre tres clases de vidrio, logrando una precisión del 88%. En comparación, este proyecto utilizó 100 épocas y clasificó cuatro tipos de huevos con una precisión del 95%. Esta diferencia en precisión puede atribuirse a factores como el tamaño de los objetos, la cantidad de datos disponibles, la potencia del hardware y las especificidades del modelo de entrenamiento. Sin

embargo, estos sistemas agilizan significativamente los procesos en comparación con el trabajo manual, optimizando recursos.

Por otro lado, Requena [48] usó YOLOv8 para analizar el comportamiento de las hormigas cortadoras de hojas, con y sin carga, empleando solo 40 imágenes para entrenamiento y alcanzando una precisión del 80%. La complejidad de distinguir múltiples objetos en una sola imagen llevó a la implementación de técnicas adicionales como BoT-SORT para seguimiento, Zero Shot para adaptación del modelo y Clipset para segmentar objetos en fotogramas, logrando resultados satisfactorios en el estudio automatizado del comportamiento de las hormigas bajo condiciones controladas.

De acuerdo con [49], los beneficios de la IA en la industria avícola, especialmente en la producción de huevos, incluyen una precisión mejorada en la detección de grietas, mayor eficiencia que los sistemas acústicos, menor tasa de falsos positivos, no requiere contacto físico y es escalable y adaptable. Esto contrasta con sistemas como Forza Gt, que son costosos, poco escalables y con altos costos de mantenimiento, haciendo de YOLOv8 una solución viable debido a su precisión, adaptabilidad y bajo costo de implementación. Esto se ilustra en el Anexo 6, donde el proceso de clasificación manual de huevos en una cinta transportadora se compara con la automatización.

En [50], se describe el desarrollo de un modelo de visión computacional para detectar grietas en la superficie de los huevos de gallina, utilizando un ordenador con procesador Intel i5 y Windows 10 de 64 bits, junto con una cámara de smartphone y el software CampStudio. Este sistema distingue fisuras, sangre o excrementos con una tasa de éxito del 96.52%, similar a los resultados obtenidos en este estudio (95% a 99%), confirmando que la visión computacional es una de las mejores soluciones actuales para la clasificación de huevos.

Finalmente, [51] describe un sistema para el control de calidad de alimentos por color, utilizando Python, una cámara web, Arduino Uno y OpenCV, logrando resultados positivos al diferenciar manzanas verdes de otras mediante LEDs de colores. Esto demuestra que los sistemas de visión computacional son escalables, adaptables a necesidades locales y competitivos en términos de costo, corroborando el uso beneficioso de IA y visión computacional con Python para el desarrollo de soluciones eficientes y escalables según las tareas requeridas.

Verma et al. [52] refiere que en las tecnologías de identificación de objetos destaca el modelo Yolo V8 en pruebas mediante la versión Yolo V5 y Yolo V7 destaca que V8 tiene una precisión 52.8%

mayor en ejecuciones de 60 cuadros por segundo (FPS), aunque requiere GPU (Tarjeta gráfica) para mantener un tamaño compacto al optimizar recursos de hardware, su principal ventaja es su compatibilidad con modelos existentes a un menor costo energético pero mayor precisión. En contraste con el proyecto se utiliza una Jetson Orin Nano siendo compacta, robusta y viene equipada con GPU de NVIDIA para el procesamiento de gráficos justificando la elección del hardware respecto al modelo Yolo V8.

Rathod et al. [53] en sus estudios sobre Yolo V8 en datos recopilados por drones mejorando la precisión en detección de objetos para el tráfico indio; su principal ventaja es el procesamiento, cambio de tamaño, filtro gaussiano (transforma señales en matrices numéricas), normalizar y aumento haciendo que se la conducción autónoma sea más segura, en general la respuesta fue de 0.86 milisegundos (ms) a 50 (ms) luego del entrenamiento con vehículos no tripulados (UAV). Es decir, no solo demuestra la versatilidad de Yolo para mejorar la precisión en visión computacional para detectar objetivos, sino que mejora la velocidad de respuesta siendo entrenada y mejorando su procesamiento con filtros demostrando su adaptabilidad a distintos escenarios de aprendizaje.

De la misma manera Karimi [54] en un estudio comparativo de redes de detección de objetivos a través de Yolo para diferenciar materiales de mampostería como piedra, ladrillo, adobe y teja empleando como referencia el hormigón; se obtiene una base de datos con 1213 ladrillos, 1116 hormigones, 955 abobes, 882 piedras y 208 imágenes para el modelo de aprendizaje; se logró una precisión media de 94.4% (hormigón), 93.9% (concreto y adobe), 92.7% (adobe), 87.2% (piedra), 83.4% (piedra y ladrillo), 81.6% (ladrillo) y 70.3% (teja); en análisis con el proyecto se aprecia que igualmente diferencia objetos en varias clases (4 clases contra 7 clases) logrando eficiencias similares (95% al 99%) en la mayoría de casos; esto hace hincapié en que con una buena base de datos, suficiente entrenamientos, ciclos de aprendizaje y condiciones de adaptación la IA es capaz de solventar problemas que antes no eran posibles o exigían grandes cantidades de trabajo, mano de obra calificada y tiempo siendo recursos difíciles de optimizar hasta ahora.

En [55], se detalla que para entrenar IA con el objetivo de detectar ciclistas en entornos urbanos y así reducir atropellos, se utilizaron tres arquitecturas: YOLOv7, YOLOv8 y YOLO-NAS, obteniendo tasas de éxito del 66%, 84% y 88% respectivamente.

La superioridad de YOLO-NAS se atribuye a su capacidad de optimizar el algoritmo, diseñar un esquema de detección personalizado e inferir objetos por partes (cabeza, torso/columna),

mejorando el desempeño y reduciendo los falsos positivos. Se destaca que YOLOv8 es ideal para la detección de objetos en Python, con múltiples escenarios de entrenamiento. Sin embargo, YOLO-NAS presenta mayores desafíos en términos de recursos y entrenamiento. Concluimos que YOLOv8 fue la opción más adecuada para la clasificación de huevos, como se evidencia en el Anexo 10, donde el modelo puede reconocer, localizar, colorear y seguir los huevos en movimiento sobre una cinta transportadora.

Tabla 4. Comparación de resultados en investigaciones similares

Modelo de Deep learnin	Caso de uso	Métrica Accuracy	Otras métricas
Yolo V7 [46]	Conteo de ganado y peso	Formas y cantidad	Peso
Yolo V8 [47]	Clasificar tipos de vidrio	Colores	Tamaño
Yolo V8 [48]	Comportamiento de hormigas cortadoras de hojas	Patrones de movimiento	Cantidad de hormigas
Yolo V8 [49]	Identificar grietas en huevos de gallina	Grietas	Tamaño y peso de los huevos
Redes neuronales CNN [50]	Grietas en huevos de gallinas	Grietas	Suciedad y fugas
Open CV y Arduino 1 [51]	Control de calidad en alimentos	Colores de manzanas	Clasificar alimentos por color
Yolo V7 [52]	Identificar objetos	Tamaño y forma	Cantidades
Yolo V8 [53]	Detectar objetos	Control de tráfico	Forma y velocidad
Yolo V8 [54]	Detección de materiales de mampostería	Materiales, colores y texturas	Cantidades y precisión
Yolo V8 [55]	Detectar ciclistas en entornos urbanos	Formas y tamaño	Identificar formas
Yolo V8 [56]	Identificar anti-espacios urbanos	Formas y áreas	Colores y texturas

En la tabla 4 se comparan los hallazgos de los diferentes estudios empleando visión por computadora y métricas en investigaciones referentes a detectar, clasificar o encontrar objetos; permitiendo dirimir criterios sobre la veracidad de los resultados citados en el presente trabajo.

Por otro lado, en [56] se realiza un estudio comparativo para detectar "anti-espacios" urbanos (espacios abandonados, vacíos y remanentes) en Mexicali, utilizando YOLOv4 y YOLOv5. Se clasifican los espacios con etiquetas de color (rojo para abandonados, verde para vacíos y morado

para remanentes) en diferentes resoluciones (550x550 y 1080x1080 para abandonados), obteniendo precisiones de 74.1% para vacíos y 48.5% para abandonados. La baja precisión en la detección de remanentes se debe a la escasez de datos y la similitud visual con otras estructuras. Este caso subraya que la cantidad de objetos por imagen, la resolución y el entrenamiento afectan significativamente la precisión. La detección de anti-espacios urbanos requiere mayor capacidad de procesamiento y un corpus de imágenes más extenso para diferenciar adecuadamente las clases. Así, al seleccionar YOLOv8, es crucial considerar la cantidad y calidad de las imágenes para el entrenamiento, la precisión en el etiquetado y la inclusión de variaciones para mejorar el modelo.

En general, se observa que la visión computadora usando YOLO, junto con sistemas de entrenamiento basados en etiquetado de imágenes y clasificación de objetos, ofrece una gran versatilidad, dependiendo de las condiciones del aprendizaje, la capacidad de procesamiento y los recursos disponibles. Aunque existen soluciones más avanzadas en el mercado, estas suelen ser mucho más costosas. En áreas como la industria avícola, el estudio del comportamiento de hormigas, la separación de vidrios y la gestión de infraestructura urbana, la clave está en optimizar recursos para lograr la máxima precisión al menor costo posible y asegurar la escalabilidad. Las publicaciones y documentos citados muestran resultados similares a los de este proyecto, confirmando la validez y relevancia de nuestros hallazgos en el campo.

CONCLUSIONES

El análisis de los documentos citados y de la literatura sobre modelos de visión computacional para la clasificación de huevos de gallina revela que la tecnología más efectiva es YOLO versión 8. Esta es compatible con el lenguaje de programación Python, ideal para el desarrollo de la aplicación. En las granjas avícolas, se manejan cuatro clases comerciales de huevos (sucios, rugosos, rotos y sanos), cada una de las cuales debe ser codificada con un color diferente para facilitar el entrenamiento de la IA mediante etiquetado digital. Los términos más relevantes para la búsqueda son "inteligencia artificial", "clasificación de objetos", "ovoscopia" y "modelo de aprendizaje", que proporcionaron acceso a artículos científicos relevantes que ayudaron en la redacción de este trabajo.

La base de datos inicial constaba de 200 imágenes, cada una con entre 60 y 120 huevos a clasificar. Para mejorar el modelo de aprendizaje, se incrementó a 640 x 640 imágenes de entrenamiento, etiquetadas mediante el programa Supervisely, lo que permitió exportar la base de datos al ejecutar el programa, obteniendo una tasa de éxito del 99% en la clasificación de huevos a través de videos. La datasheet se elaboró con videos de dos minutos, un video de prueba de diez minutos y se aplicó aumentación (rotación de imágenes, variación de iluminación, contraste y otros parámetros) para aumentar la cantidad de objetos disponibles para el entrenamiento del modelo.

La implementación y evaluación de la red neuronal se realizaron en las instalaciones de la familia Ramírez Morales en el cantón Piñas, provincia de El Oro. Los datos se recolectaron en tiempo real y fueron validados por un inspector experto en clasificación de huevos. Se hicieron ajustes para mejorar la robustez del modelo, considerando factores como el nivel de iluminación, la cantidad y calidad de los fotogramas de entrenamiento, el ajuste de precisión para evitar falsos positivos, el color de los rodillos giratorios de la cinta transportadora (blanco o amarillo) y la estabilidad de la cámara. La precisión del modelo resultó ser aceptable, con una capacidad de clasificación que oscila entre el 95% y el 98.5% tras tres pruebas de 10 minutos, además de grabarse videos para futuras bases de datos en proyectos e investigaciones similares.

El aplicativo desarrollado utiliza el hardware Jetson Orin Nano de NVIDIA, que soporta la red neuronal entrenada con YOLO V8, permitiendo la detección y clasificación de huevos en tiempo real con una tasa de éxito superior al 95%. El costo del sistema es de \$1,470 USD, significativamente más bajo en comparación con soluciones industriales que pueden costar hasta 30 veces más, pero estas últimas no son tan adaptables o programables para satisfacer las necesidades específicas de las granjas locales, como ajustar la cantidad de huevos a clasificar o incorporar nuevos tipos según las demandas del mercado. Además, el prototipo es replicable y puede operar en dos cintas transportadoras con un solo ordenador, simplemente añadiendo una cámara y su soporte, sin alterar significativamente la configuración, lo que optimiza costos y mejora la eficiencia de la clasificación en granjas locales.

RECOMENDACIONES

Se recomienda explorar y experimentar con otros modelos de inteligencia artificial en visión computacional, como SSD (Single Shot MultiBox Detector), Faster R-CNN (Region-based Convolutional Neural Networks), o RetinaNet, para comparar su tasa de éxito, efectividad y escalabilidad frente a YOLO V8. Esto proporcionará un análisis más amplio sobre cuál podría ser el modelo más adecuado para aplicaciones específicas en la industria avícola, especialmente en la detección y clasificación de huevos de gallina.

La base de datos actual, que utiliza videos de 10 minutos convertidos en fotogramas de 640 x 640 con entre 60 y 120 huevos por imagen, debe ser manipulada para experimentar con diferentes variables. Se sugiere ajustar la iluminación, los colores, las escalas, los matices y la cantidad de huevos para aumentar la robustez del modelo. Esta manipulación ayudará a que el modelo sea más resistente a variaciones ambientales y operativas, mejorando su capacidad de generalización en diferentes condiciones de las granjas.

En investigaciones posteriores, se puede utilizar el modelo de entrenamiento y el código desarrollados como base para incorporar nuevas funcionalidades. Un ejemplo sería integrar un brazo robótico que automáticamente separe los huevos según su categoría: los rotos a una zona de desechos, los sucios para ser limpiados manualmente por un operador, los rugosos a contenedores específicos, y los sanos continuando en la línea de producción. Esta automatización no solo optimizaría los costos y el tiempo de producción, sino que también introduciría soluciones tecnológicas accesibles y adaptables a las necesidades de las granjas avícolas locales, aumentando la eficiencia y la calidad del producto final.

Consideraciones futuras

Se aconseja aumentar los videos de entrenamiento a cinco, tres videos de 10 minutos a 640 pixeles y dos videos de 6 minutos a 1080 en distintas condiciones de iluminación, color de las bandas transportadoras y estabilidad de la cámara mejorando el modelo de entrenamiento.

Es preciso pensar en futuros estudios e investigaciones, los datos presentes sirvan de entrenamiento, se considere correr el programa en ordenadores más poderosos y anexar otras funcionalidades como un brazo robótico que separe los huevos empleando las coordenadas x, y que exporta el modelo desde la cinta transportadora.

El prototipo se puede diseñar de manera más robusta, hacer resistente a cambios y venderse como solución a las granjas avícolas que no dispongan del recurso suficiente para comprar Forza Gt ayudando a la industria local.

BIBLIOGRAFÍA

- [1] Instituto de Estudios del Huevo, 2009. [En línea]. Available: <chrome-extension://efaidnbnmnibpcjpcglclefindmkaj/https://www.institutohuevo.com/wp-content/uploads/2017/07/EL-GRAN-LIBRO-DEL-HUEVO.pdf>. [Último acceso: 2024].
- [2] Faborit, «El huevo, un ingrediente con muchas y buenas propiedades,» 2019. [En línea]. Available: <https://www.faborit.com/el-huevo-un-ingrediente-con-muchas-y-buenas-propiedades/>. [Último acceso: 2024].
- [3] Corporación Nacional de Avicultores del Ecuador, «Día Nacional del Huevo en Ecuador: Resaltan los beneficios de la proteína más noble,» *AviNews*, 2023. [En línea]. Available: <https://avinews.com/dia-nacional-del-huevo-en-ecuador-resaltan-los-beneficios-de-la-proteina-mas-noble/#:~:text=Desde%20el%202019%2C%20en%20Ecuador,noble%20y%20econ%C3%B3mica%20que%20existe..> [Último acceso: Julio 2024].
- [4] E. Ionita, «Mejora de la calidad del huevo en Ecuador,» *Veterinaria Digital*, 2022. [En línea]. Available: <https://www.veterinariadigital.com/noticias/mejora-de-la-calidad-del-huevo-en-ecuador/>. [Último acceso: Agosto 2024].
- [5] T. Pomares, «Clasificación de huevos por tamaño usando redes neuronales,» Universidad Miguel Hernández De Elche, Elche, España, 2020.
- [6] E. Rachmawanto, A. Sari, M. De Rosal y R. Villadelfiya, «Eggs Classification based on Egg Shell Image using K-Nearest Neighbors Classifier,» de *Conference: 2020 International Seminar on Application for Technology of Information and Communication (iSemantic)*, Sekretariat LPPM, Universitas Dian Nuswantoro, 2020.
- [7] Escuela de formación en inteligencia artificial en salud, «*healthdataminer.com*,» 2024. [En línea]. Available: <https://healthdataminer.com/data-mining/crisp-dm-una-metodologia-para-mineria-de-datos-en-salud/>. [Último acceso: Agosto 2024].
- [8] C. De Fatima Do Santos, D. Do Vale Nascimento y J. Cardoso, «A software for selection of eggs using digital image processing with customization between profits and quality,» de *8th Iberian Conference on Information Systems and Technologies (CISTI)*, Lisboa, Portugal, 2013.
- [9] M. Medina y J. Rosado, «Diseño e implementación de un prototipo que clasifique huevos de gallina según sus características,» Facultad De Ingeniería, Universidad Autónoma Del Caribe, Barranquilla, Colombia, 2014.
- [10] M. Navas y R. Vargas, «Diseño e implementación de un sistema de ovoscopia con visión artificial para la detección de huevos fértiles para Incubandina,» Universidad de las Fuerzas Armadas ESPE, Latacunga, Ecuador, 2014.
- [11] D. Enríquez y F. Obando, «Diseño, construcción y automatización de una máquina clasificadora para huevos por peso, en diferentes tamaños para 2000 huevos por hora de capacidad,» Universidad Politécnica Salesiana, Quito, Ecuador, 2015.
- [12] S. Vélez y S. Pazmiño, «Mejoramiento de ovoscopia con visión artificial,» *E-IDEA 4.0 Revista Multidisciplinar*. <https://doi.org/10.53734/mj.vol3.id167.>, vol. 3, n° 7, pp. 37-48, 2021.

- [13] S. Ryota, Y. Shusuke, S. Toru, H. Mototsugu y K. Tadahiro, «Convolutional neural network for industrial egg classification,» de *14th International SoC Design Conference, ISOCC 2017*, Seoul, Korea, 2018.
- [14] A. Vasileva, E. Gorbunova, A. Vasilev, V. Peretyagin, A. Chertov y V. Korotaev, «Assessing exterior egg quality indicators using machine vision,» *Br Poult Sci.* DOI: [10.1080/00071668.2018.1523535](https://doi.org/10.1080/00071668.2018.1523535), vol. 59, n° 6, pp. 636-645, 2018.
- [15] Q. Zhao, L. Ban, J. Zheng, G. Xu y Z. Q. L. Ning, «Uso potencial de técnicas espectroscópicas para evaluar huevos de mesa y huevos para incubar,» *Revista científica avícola mundial.* <https://doi.org/10.1017/S0043933919000424>, vol. 75, n° 3, pp. 445-456, 2019.
- [16] X. Yang, B. Bahadur, S. Subedi y L. Chai, «A Computer Vision-Based Automatic System for Egg Grading and Defect Detection,» *Animals.* <https://doi.org/10.3390/ani13142354>, vol. 13, n° 14, p. 2354, 2023.
- [17] V. Narushin, M. Romanov y G. L. G. D. James, «Digital imaging assisted geometry of chicken eggs using Hügelschäffer's model,» *Biosystems Engineering.* <https://doi.org/10.1016/j.biosystemseng.2020.06.008>, vol. 197, pp. 45-55, 2020.
- [18] V. Asadi y M. Raoufat, «Egg Weight Estimation by Machine Vision and Neural Network Techniques (A case study Fresh Egg),» *International Journal of Natural and Engineering Sciences.* <https://ijnes.org/index.php/ijnes/article/view/529>, vol. 4, n° 2, pp. 1-4, 2019.
- [19] A. Hernández y A. Medina, «El estudio del error humano en el contexto laboral,» *Revista Cubana de Salud y Trabajo*, vol. 24, n° 3, p. e393, 2023
- [20] M. Hernández, H. Barrios y O. González, «Variables fisiológicas y fanerópticas y su influencia sobre características del huevo en gallinas de patio (*Gallus gallus domesticus*) en comunidades de Moyogalpa y Altagracia, Isla de Ometepe, Nicaragua,» *La Calera.* <http://portal.amelica.org/ameli/jatsRepo/306/3062000010/index.html>, vol. 21, n° 36, 2021
- [21] C. Fárez y J. Quezada, «Estudio retrospectivo de la influencia del ciclo lunar sobre la producción de huevos fértiles en gallinas reproductoras pesadas en una granja comercial en el período 2016 a 2021,» Universidad de Cuenca, Facultad de Ciencias Agropecuarias, Cuenca, Ecuador, 2024.
- [22] J. Guillén, «Caracterización biométrica de huevos de gallina de granja que se comercializan en tiendas mayoristas de la ciudad de Ayacucho, 2019.,» Universidad Nacional de San Cristobal de Huamanga, Ayacucho, Perú, 2021.
- [23] J. Ramírez, «Aprendizaje Automático y Aprendizaje Profundo,» *Ingeniare. Revista chilena de ingeniería.* <http://dx.doi.org/10.4067/S0718-33052021000200180>, vol. 29, n° 2, pp. 181-183, 2021.
- [24] J. Dong, X. Li, L. Zhao y K. Chao, «Predicción de huevos de gallina infértiles antes de la eclosión mediante el método Naïve-Bayes combinado con espectroscopia de transmisión de infrarrojo cercano visible,» *Cartas de espectroscopia.* <https://doi.org/10.1080/00387010.2020.1748061>, vol. 53, n° 5, pp. 327-336, 2020.
- [25] L. González, «Visión Computacional,» AprendeIA, 2021. [En línea]. Available: https://aprendeia.com/vision-computacional/#google_vignette. [Último acceso: 2024].
- [26] X. Basogain, «Redes Neuronales Artificiales Y Sus Aplicaciones,» 2019. [En línea]. Available: chrome-

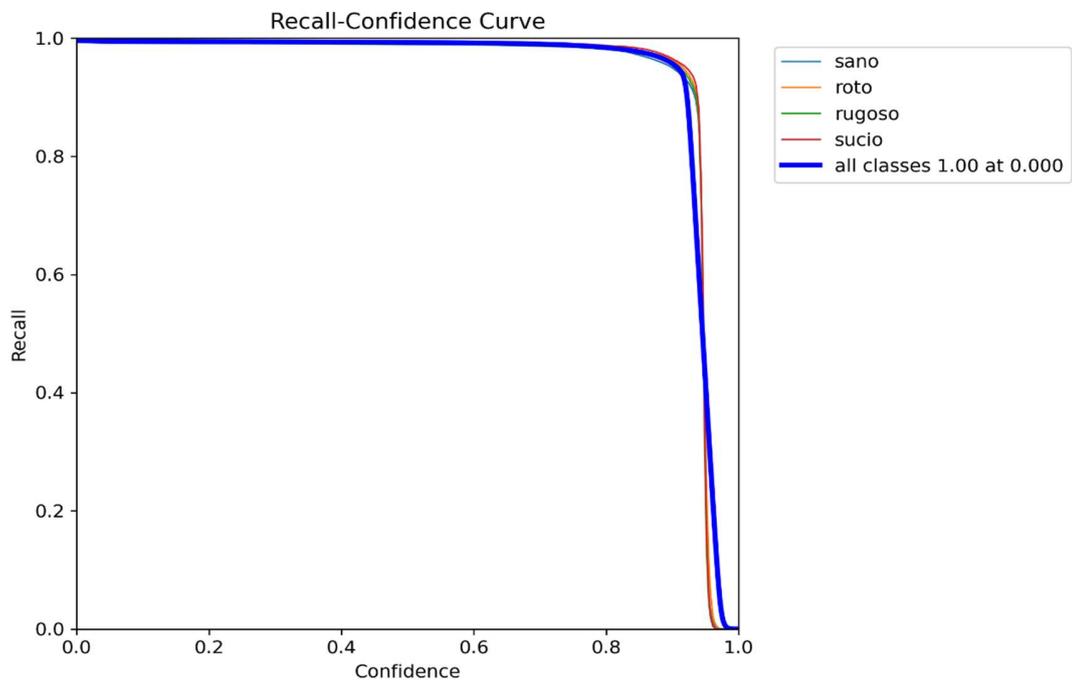
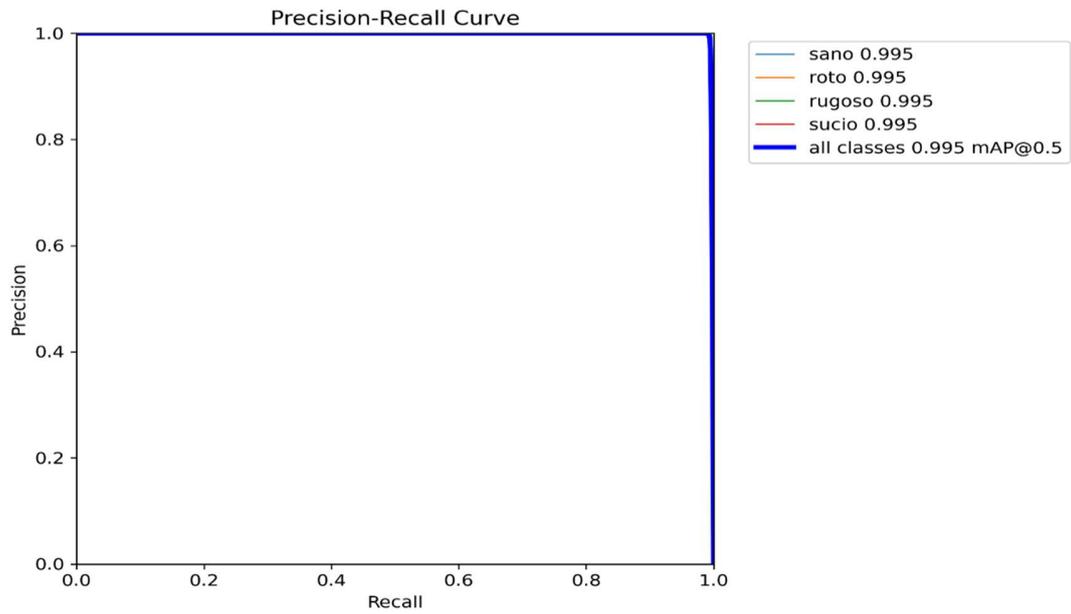
- extension://efaidnbmnnnibpcajpcglclefindmkaj/https://ocw.ehu.eus/pluginfile.php/40137/mod_resource/content/1/redes_neuro/contenidos/pdf/libro-del-curso.pdf. [Último acceso: 2024].
- [27] L. Perez, «Descubre la Inteligencia Artificial: Etiquetado de Imágenes,» Mayo 2023. [En línea]. Available: <https://neuroflash.com/es/blog/descubre-la-inteligencia-artificial-etiquetado-de-imagenes/>. [Último acceso: Agosto 2024].
- [28] Amazon, «NVIDIA Jetson Orin Nano Developer Kit,» 2024. [En línea]. Available: <https://www.amazon.com/-/es/NVIDIA-Jetson-Orin-Nano-Developer/dp/B0BZJTQ5YP?th=1>. [Último acceso: 2024].
- [29] YoloV8, «Explora los modelos YOLOv8,» 2024. [En línea]. Available: <https://yolov8.com/>. [Último acceso: 2024].
- [30] Supervisely OÜ, «Unified OS/Platform,» 2024. [En línea]. Available: <https://supervisely.com/>. [Último acceso: 2024].
- [31] Python Software Foundation, «Python,» 2024. [En línea]. Available: <https://www.python.org/>. [Último acceso: Agosto 2024].
- [32] S. Calle, «Diseños de investigación cualitativa y cuantitativa,» *Ciencia Latina Revista Científica Multidisciplinar*. https://doi.org/10.37811/cl_rcm.v7i4.7016, vol. 7, n° 4, pp. 1865-1879, 2023.
- [33] W. Walker, «Una síntesis crítica mínima de las portaciones de los paradigmas interpretativo y sociocrítico a la investigación educacional,» *Enfoques*, vol. XXXIV, n° 2, pp. 14-33, 2022.
- [34] D. Amaral, E. Goncalves, D. Gomes y H. Fernandes, «Aplicación de YOLO-V8 y análisis morfológico por rayos X para evaluar el vigor de semillas de *Brachiaria brizantha* cv. Xaraés,» *AgriEngineering.10.20944/preprints202401.0931.v1*, vol. 6, pp. 869-880, 2024.
- [35] A. López y G. Ramos, «Acerca de los métodos teóricos y empíricos de investigación: significación para la investigación educativa,» *Revista Conrado*. <https://conrado.ucf.edu.cu/index.php/conrado/article/view/2133>, vol. 17, n° S3, pp. 22-31, 2021.
- [36] J. Sanabria, Y. Silveira, D. Pérez y M. Cortina, «Incidencias de la inteligencia artificial en la educación contemporánea,» *Comunicar*. <https://doi.org/10.3916/C77-2023-08>, vol. XXXI, n° 77, pp. 97-107, 2023.
- [37] F. Sánchez, «Fundamentos epistémicos de la investigación cualitativa y cuantitativa: Consensos y disensos,» *Revista Digital de Investigación en Docencia Universitaria*, vol. 13, n° 1, p. 2019, 2019.
- [38] E. Ortega, C. Ochoa y A. Molina, «Pruebas para muestras relacionadas. Variables cualitativas,» *Evidencias en pediatría*, vol. 19, n° 10, pp. 1-7, 2023.
- [39] S. Tamayo, «Desarrollo de un modelo de machine learning para predecir el rendimiento académico de los estudiantes universitarios en términos de aprobación o reprobación de materias utilizando la metodología CRISP-DM,» Pontificia Universidad Católica del Ecuador, Quito, Ecuador, 2023.
- [40] Ultralytics YOLOv8 Modes, Model Training with Ultralytics YOLO, » 2023. [En línea]. Available: <https://docs.ultralytics.com/modes/train/#key-features-of-train-mode>. [Último acceso: 2024].

- [41] Moba, «Forta GT,» 2024. [En línea]. Available: <https://www.moba.net/page/es/Products/Detail/forta-gt/1537>. [Último acceso: 2024].
- [42] scikit-learn 0.24.1, «Matriz de confusión,» 2024. [En línea]. Available: https://qu4nt.github.io/sklearn-doc-es/auto_examples/model_selection/plot_confusion_matrix.html. [Último acceso: 2024]
- [43] Zhengzhou Wenming Machinery LTD , «Máquina clasificadora de huevos de gallina comercial a la venta,» 2023. [En línea]. Available: https://wmmachinery.com/es-es/products/egg-grading-machine-for-sale?srsltid=AfmBOorTFBzgRym9WSG6lQ4gNmTLtYX4OZrKma-aL4q7Sie3_HmTcRhA. [Último acceso: 2025].
- [45] C. Ochoa, M. Molina y E. Ortega, «Inferencia estadística: contraste de hipótesis.,» *Evidencias En Pediatría*, vol. 16, n° 11, pp. 125-128, 2020.
- [46] A. Barrezueta y E. Córdoba, «Desarrollo de un asistente virtual de información utilizando PNL y machine learning para la Universidad Técnica de Machala.,» Universidad Técnica de Machala, Machala, Ecuador, 2022.
- [47] Desde_la_Ciencia, «Cuenta dedicada a la divulgación científica.,» 2024. [En línea]. Available: <https://www.facebook.com/reel/1396819684342143>. [Último acceso: 2024].
- [48] L. Alanís, B. Muñoz, J. Sánchez, C. Aguilar, J. Pérez y G. Pérez-Sánchez, «Reconocimiento Y Detección De Fragmentos De Vidrio Mediante El Uso De Yolov8 (Glass Fragment Recognition And Detection Using Yolov8),» *Pistas Educativas*. <https://pistaseducativas.celaya.tecnm.mx/index.php/pistas/article/view/3455>, vol. 45, n° 147, pp. 219-235, 2024.
- [49] A. Requena, J. González y J. Ruiz, «Sistema de Seguimiento y Análisis de Comportamiento de Hormigas mediante técnicas de Visión por Computador,» Universidad de Málaga, Málaga, España, 2023.
- [50] Sanovo Technology Group, «Visión por computadora basada en IA para la detección de grietas,» 2023. [En línea]. Available: <https://www.sanovogroup.com/es/news/news/revolutionizing-egg-quality-assurance/>. [Último acceso: 2024].
- [51] R. León, A. Corcuera, H. Díaz, C. Díaz y T. Vera, «Diseño de un algoritmo de visión artificial para detectar rajaduras en los huevos de gallina en control de calidad para las empresas avícolas,» de *21st LACCEI International Multi-Conference for Engineering, Education, and Technolog*, Buenos Aires, Argentina, 2023.
- [52] L. Villareal, «Prototipo para la detección y clasificación de productos alimenticios mediante visión artificial en base al color,» *Revista Conectividad*, vol. 5, n° 2, pp. 46-62, 2024.
- [53] R. Verma, S. Vishwakarma y R. Bodade, «MILITARY-EYES: Un enfoque de detección de objetos optimizado e hiperajustado en tiempo real, adaptado a conjuntos de datos militares,» *Revista de Investigación IETE*, vol. 1, n° X, pp. 2-15, 2024.
- [54] V. Rathod, D. Rana, R. Mehta y V. Nath, «Un enfoque de visión artificial para la detección, clasificación y seguimiento de vehículos a partir de datos de UAV para el análisis del tráfico indio.,» *Revista internacional de patrimonio arquitectónico*, vol. 3, pp. 1-17, 2024.
- [55] N. Karimi, M. Mishra y P. Lourenço, «Detección automatizada de grietas superficiales en construcciones históricas con diversos materiales mediante la red YOLO basada en

- aprendizaje profundo,» *Revista internacional de patrimonio arquitectónico*, pp. 1-17, 2024.
- [56] M. Arias, J. Rodríguez, M. Quintero, P. Ortiz y L. Gómez, «Comparación de arquitecturas YOLO para la detección de ciclistas urbanos en un entorno de vehículos autónomos,» *Revista Colombiana De Tecnologías De Avanzada (RCTA)*, vol. 1, n° 43, pp. 64-72, 2024.
- [57] J. Martínez y H. De la Torre, «Detección de anti-espacios urbanos usando YOLO: Caso de estudio Mexicali,» *Research in Computing Science*, vol. 15, n° 9, pp. 21-33, 2023.
- [58] S. Luna, «La realidad fotoficcionalada. Propuesta de análisis metodológico del trabajo artístico de Joan Fontcuberta y estudio de caso de la obra Prosopagnosia,» *Rev. Arte , Individuo y Sociedad, avance en línea*. <https://dx.doi.org/10.5209/aris.85767> , pp. 1-13, 2023.

ANEXOS

Anexo 1. Curvas de precisión del modelo de clasificación de huevos de gallina



Anexo 2. Prueba del prototipo en campo junto al tutor del proyecto



Anexo 3. Instalación del prototipo en sitio (banda transportadora de huevos)



Anexo 4. Evidencia de haber probado y entrenado el prototipo



Anexo 5. Vista de la banda transportadora y recibidora de huevos



Anexo 6. Vista del proceso de clasificación de huevos en la granja



Anexo 7. Producción total diaria de huevos (36449 por hora) hasta 136000 al día

FECHA	PROVEEDORES	TOTAL DE HUEVOS	HUEVOS DE MESA	HUEVOS RECHAZADOS	HUEVOS AÑADIDOS DE FORMA MANUAL	DOWN DATA
29 ago 2024	7	97910	97628	62	0	
28 ago 2024	8	133015	132872	143	0	
27 ago 2024	6	127885	127039	146	0	
26 ago 2024	5	138651	138493	158	0	
25 ago 2024	6	134488	134289	159	0	
24 ago 2024	6	127646	127352	144	150	
23 ago 2024	7	134900	134678	192	30	
22 ago 2024	5	136726	136573	153	0	
21 ago 2024	7	137291	136830	191	270	
20 ago 2024	5	132138	131840	178	120	
19 ago 2024	8	137761	137360	151	270	
18 ago 2024	6	139400	138948	152	0	
17 ago 2024	7	134434	134002	162	270	
16 ago 2024	5	142523	142355	158	30	

Anexo 8. Datos de la producción neta de huevos (con sangre, por peso, líneas y descartados)

Proveedor	
Nombre de abastecedor	CUBA
Fecha	29 ago 2024
Inicio	07:40
Fin	09:11
Huevos de mesa	625 62.8 gr 99.9 %
Huevos rechazados	24 64.9 gr < 0.1 %
Huevos añadidos de forma manual	0 0 %
Total	36649 62.8 gr 100 %
Huevos de mesa	
PE-	32 41.2 gr < 0.1 %
PE+	87 47.5 gr 0.2 %
PAR	4227 55.5 gr 11.5 %
M-	3064 58.3 gr 8.4 %
M→	5537 60.0 gr 15.1 %
M←	6475 62.0 gr 17.7 %
L-	13998 65.6 gr 38.2 %
L+	2815 70.8 gr 7.7 %
JUM	390 76.1 gr 1.1 %
Total	36625 62.8 gr 99.9 %
Huevos rechazados	
OW	16 95.4 gr < 0.1 %
UW	1 30.8 gr < 0.1 %
U	7 -0.0 gr < 0.1 %
Total	24 64.9 gr < 0.1 %

Anexo 10. Evaluación del modelo entrenado mediante imágenes de huevos de gallina

