

Anomaly detection to rule out chickens using convolutional neural networks

¹Carlos Redondo, Ingeniero Mecatrónico ²Alberto Max Carrasco, Master en Sistemas Mecatrónicos

Facultad de Ingeniería, Universidad Tecnológica Centroamericana (UNITEC), Honduras,
redondo.carlos@unitec.edu, alberto.carrasco@unitec.edu.hn

Abstract– In the poultry industry, early detection of diseases in poultry is crucial to prevent economic losses and ensure food safety. This article focuses on the detection of abnormalities in broilers using convolutional neural networks (CNNs). There are four types of abnormalities that affect birds, small chickens, contaminated chickens, limping chickens, and suffocated chickens. These anomalies can lead to premature chicken recalls and economic losses in the industry. In addition, related work that has addressed similar problems using technologies such as machine learning and computer vision is mentioned. Despite the advances, the technical limitations that need to be overcome to successfully implement these solutions in the poultry industry are highlighted.

Keywords-- Poultry production, anomaly detection, broilers, convolutional neural networks, feed.

Detección de anomalías para descartar pollos mediante redes neuronales convolucionales

¹Carlos Redondo, Ingeniero Mecatrónico ²Alberto Max Carrasco, Master en Sistemas Mecatrónicos

Facultad de Ingeniería, Universidad Tecnológica Centroamericana (UNITEC), Honduras,

¹redondo.carlos@unitec.edu, ²alberto.carrasco@unitec.edu.hn

Abstract– *En la industria avícola, la detección temprana de enfermedades en las aves de corral es crucial para evitar pérdidas económicas y garantizar la seguridad alimentaria. Este artículo se centra en la detección de anomalías en pollos de engorde utilizando redes neuronales convolucionales (CNN). Se presentan cuatro tipos de anomalías que afectan a las aves, pollos pequeños, pollos contaminados, pollos con cojera y pollos asfixiados. Estas anomalías pueden provocar la retirada prematura de pollos y pérdidas económicas en la industria. Además, se mencionan trabajos relacionados que han abordado problemas similares utilizando tecnologías como el aprendizaje automático y la visión por computadora. A pesar de los avances, se destacan las limitaciones técnicas que deben superarse para implementar con éxito estas soluciones en la industria avícola.*

Keywords-- *Producción avícola, detección de anomalías, pollos de engorde, redes neuronales convolucionales, alimentos.*

I. INTRODUCCIÓN

En la industria avícola, garantizar la calidad de los pollos durante el proceso de engorde de 30 a 40 días es vital, y la detección de anomalías es un componente clave de esto. El proyecto propone aprovechar la inteligencia artificial, específicamente las redes neuronales convolucionales (CNN), para mejorar la eficiencia y la precisión de la detección de anomalías. Es esencial tener en cuenta factores como la edad de las aves, ya que las enfermedades pueden manifestarse de manera diferente a medida que crecen. El objetivo es identificar y eliminar los pollos con condiciones como cojera o asfixia al principio del proceso para evitar la propagación de enfermedades y mantener la salud y la calidad de todo el lote. Las redes neuronales convolucionales (CNN) se destacan como una poderosa herramienta en la visión por computadora, particularmente para analizar datos espaciales como imágenes. Estas redes utilizan convoluciones para extraer características cruciales de las imágenes, lo que las hace ideales para tareas como el reconocimiento de objetos y, en este caso, la detección temprana de enfermedades en aves de corral. Se espera que los modelos desarrollados logren una precisión impresionante, especialmente en la distinción de diferencias sutiles como el tamaño de los pollos, asegurando una identificación precisa y una acción rápida. Más allá de la prevención de enfermedades, el proyecto hace hincapié en el impacto más amplio en la eficiencia y la sostenibilidad de la industria avícola. La

combinación de tecnología de visión artificial y algoritmos de aprendizaje automático se considera fundamental para el bienestar de las aves y la sostenibilidad general de la producción avícola. Se prevé que este enfoque innovador revolucione las prácticas de la industria, empoderando a los agricultores para mitigar las pérdidas económicas, garantizar la calidad de los alimentos y navegar por los desafíos del sector avícola de manera efectiva. En la era actual de la automatización y la inteligencia artificial, este sistema representa un avance significativo hacia un futuro más eficiente, confiable y tecnológicamente avanzado para la industria avícola [1].

A. PRODUCCIÓN AVÍCOLA

La En el campo de la producción avícola, los brotes de enfermedades en las aves de corral son una preocupación mundial debido a la importancia de la industria avícola para satisfacer las necesidades mundiales de proteínas. Estos brotes pueden causar pérdidas financieras considerables a los agricultores y provocar inseguridad alimentaria. La detección temprana de enfermedades es crucial no solo para la industria avícola sino también para la salud humana, como se enfatizó durante la pandemia de COVID-19. En la actualidad, la detección temprana a menudo depende de la experiencia de los agricultores, lo que puede resultar en pérdidas significativas, para abordar este problema, se propone un sistema automatizado basado en una red neuronal convolucional que utiliza imágenes. Este método, conocido como redes neuronales convolucionales ajustadas, Además, se enfatiza su usabilidad práctica en términos de eficiencia, confiabilidad, facilidad de uso y costos [1]. En el contexto de las granjas de pollos de engorde, se destaca que estas operaciones se centran en la cría de pollos para la producción de carne. Las instalaciones varían en tamaño y diseño y se utilizan para albergar y criar pollos en diferentes sistemas de producción, desde su llegada como pollitos de un día hasta el momento de su captura para su procesamiento en los mataderos. El objetivo principal de estas granjas es la producción eficiente y comercial de carne de pollo [2]. También se abordan las razones por las que los pollos a menudo se descartan, principalmente relacionadas con su entorno de desarrollo, como la densidad de población, la iluminación, la calidad del aire, la temperatura, la humedad, la calidad de la cama y la ventilación. Además, la calidad de los alimentos y el agua puede influir en el bienestar de los pollos, junto con los problemas de salud y las enfermedades que afectan a estas aves. Comprender estos factores es crucial para minimizar el descarte de pollos y optimizar el proceso de producción [3].

B. DETECCIÓN DE ANOMALÍAS EN POLLOS DE ENGORDE CHICKENS

En la producción de pollos de engorde, es común que los pollos presenten anomalías que pueden afectar su desarrollo y salud [3]. A continuación, se describen cuatro tipos comunes de anomalías y su impacto en la producción.

Un problema común en la cría de pollos de engorde es la presencia de pollos pequeños que no crecen adecuadamente. Esto puede deberse a problemas en el proceso de alimentación que afectan a su crecimiento y desarrollo. La prueba del cultivo, que consiste en comprobar si el buche del pollo está vacío, es una forma de determinar si un pollo está comiendo correctamente. Los pollos pequeños a menudo se sacrifican, ya que es posible que no alcancen el tamaño y el peso deseados [4]. La figura 1 muestra un ejemplo de un pollo pequeño.



Figura 1: Pollo pequeño

La contaminación de los pollos puede ocurrir por diversas razones, como la contaminación del agua o del bebedero, la persistencia de patógenos en el medio ambiente, la introducción de enfermedades por parte de la fauna silvestre o incluso la contaminación a través de la ropa y el calzado de los trabajadores. La implementación de medidas de bioseguridad y prácticas adecuadas de limpieza y desinfección es esencial para prevenir la contaminación de los pollos. Los pollos a menudo se contaminan al ingerir sustancias no relacionadas con su comida, como los gusanos que se encuentran en el suelo [5]. La Figura 2 muestra un ejemplo de un pollo contaminado.



Figura 2: Pollo contaminado

Los pollos de engorde pueden desarrollar cojera y anomalías en la marcha debido a diversos trastornos musculoesqueléticos, tanto infecciosos como no infecciosos. Estos trastornos pueden ser causados por factores genéticos, problemas de alimentación, falta de higiene, problemas de iluminación, mala calidad de la ropa de cama o factores ambientales y de manejo. La calidad de la cama puede contribuir al desarrollo de cojera en los pollos [2]. La figura 3 muestra un ejemplo de un pollo con cojera.



Figura 3: Pollo con Cojera

Los pollos en las granjas de pollos de engorde pueden asfixiarse por varias razones, como el hacinamiento excesivo que restringe el espacio para respirar, la mala ventilación que conduce a la acumulación de gases nocivos, las condiciones extremas de temperatura y humedad que causan estrés por calor, las partículas en el aire que dificultan la respiración, las enfermedades respiratorias que obstruyen las vías respiratorias, el hacinamiento excesivo que ejerce presión sobre los pollos y los problemas de calidad del aire como la alta concentración de amoníaco. Los pollos asfixiados a menudo intentan enterrar sus picos en el suelo en busca de oxígeno [6]. La figura 4 muestra un ejemplo de un pollo asfixiado.

C. REDES CONVOLUCIONALES (CNN) PARA



Figura 4: Pollo Asfixiado

DETECCIÓN DE ANOMALÍAS

La Una red neuronal convolucional (CNN) es una herramienta eficaz para analizar datos con estructura espacial, como imágenes. Las CNN se utilizan principalmente en problemas de visión por computadora, lo que las hace ideales para detectar anomalías en pollos a partir de imágenes. Estas redes se basan en la aplicación de convoluciones en al menos una de sus capas, lo que les permite identificar características abstractas a medida que procesan datos más profundos. En el caso de detectar anomalías en pollos, las CNN se pueden utilizar para analizar imágenes de pollos y determinar si presentan alguna de las anomalías [7].

Se han realizado investigaciones previas en el campo de la detección de enfermedades y anomalías de las aves de corral utilizando diversas tecnologías. Los siguientes son resúmenes de algunos trabajos relacionados:

Un modelo de red neuronal llamado ResNeXt50-3A logró una precisión del 97,4% en la detección de enfermedades en pollos a través del análisis fecal [9].

La propuesta implicó la creación de una nueva raza de pollos, IPB-D1, que combina rasgos deseables de las razas locales con genes de crecimiento rápido para mejorar la genética, el crecimiento y la resistencia a enfermedades en los pollos [10].

Se logró una precisión del 99,15% en la identificación de enfermedades en pollos a partir de imágenes de heces utilizando tecnología de visión por computadora y modelos como Autoencoders [11].

Se desarrollaron algoritmos de aprendizaje automático que pueden identificar con precisión el sexo de las aves y predecir enfermedades en las aves de corral, mejorando la calidad y la eficiencia en la industria avícola [12] [13].

Se utilizó el Análisis Jerárquico de Procesos (AHP) y el método Fuzzy C-Means para evaluar la salud y el tamaño de los pollos de engorde en las granjas, con el objetivo de mejorar la selección de pollos de alta calidad [14] [15].

Se empleó tecnología de diagnóstico automatizado para monitorear la enfermedad del pullorum en la cría de pollos KUB, proporcionando información valiosa para el desarrollo de sistemas mecatrónicos para el control y la prevención de enfermedades [16].

Se utilizó un algoritmo de seguimiento de objetos y un modelo de detección preentrenado para analizar el movimiento de las aves en los videos de vigilancia, lo que permitió la recopilación de datos sobre el comportamiento de las aves [17].

En China, se propuso un "sistema de alerta temprana para el estrés y la salud de los pollos de engorde", utilizando tecnología de diagnóstico, visión por computadora y aprendizaje automático para detectar enfermedades en los pollos y mejorar la eficiencia de la producción [18].

A pesar de los avances en la detección de anomalías en pollos de engorde, existen algunas limitaciones técnicas que deben abordarse en futuras investigaciones. Estas limitaciones pueden incluir la necesidad de mejorar la precisión de la detección de enfermedades, implementar sistemas de alerta

temprana más eficientes y superar los desafíos técnicos en la identificación de anomalías a partir de imágenes.

I. METODOLOGÍA

Para En este apartado se detallará la metodología utilizada para llevar a cabo la investigación con el fin de detectar anomalías a lo largo del periodo. La metodología es esencial para garantizar que los resultados sean precisos, confiables y relevantes para los objetivos establecidos.

El enfoque de esta investigación se basa en la aplicación de tecnologías de inteligencia artificial, concretamente utilizando Redes Neuronales Convolucionales (CNN), para la detección temprana de anomalías en pollos de engorde durante el proceso de cría. Este enfoque se basa en la capacidad de CNN para analizar datos con estructura espacial, como imágenes, lo cual es crucial en el contexto de la producción avícola. La implementación de este enfoque tiene como objetivo mejorar la eficiencia y la precisión en la identificación de condiciones anormales, contribuyendo así a la salud y la calidad del producto final.

Las técnicas aplicadas en esta investigación se centran en el desarrollo e implementación de un sistema de detección basado en Redes Neuronales Convolucionales. Un instrumento notable es la plataforma "RoboFlow", que aprovecha las capacidades de modelos de algoritmos como YOLO para el análisis y la detección de objetos en imágenes. YOLO fue elegido por su capacidad para manejar algoritmos de detección de objetos, lo que permite una detección de anomalías más rápida. Los algoritmos de aprendizaje automático se utilizarán para entrenar a la red neuronal en la identificación de anomalías específicas, como pollos pequeños, contaminados, cojeando y asfixiados. Los materiales esenciales para la ejecución de esta investigación incluyen hardware para el procesamiento eficiente de datos, software de desarrollo y entrenamiento para redes neuronales como "RoboFlow", y conjuntos de datos de imágenes que reflejan situaciones reales en granjas avícolas. Además, se utilizarán recursos de programación y análisis estadístico para evaluar la eficacia del sistema.

A. Preparación de datos

En esta fase, la preparación de datos es crucial para el desarrollo de redes neuronales, ya que garantiza una mayor seguridad de los resultados, una mejor comprensión y una mayor certeza de los resultados. El enfoque es en la recopilación de 1000 imágenes para el entrenamiento del modelo YOLO, que se utilizarán en la plataforma RoboFlow. Toda la colección de imágenes será propiedad del autor, sin uso de conjuntos de datos existentes.

B. Carga y procesamiento de datos

Se consideraron varias etapas para el procesamiento de datos para garantizar mejores resultados utilizando la plataforma RoboFlow con el algoritmo del modelo YOLO.

Carga de imágenes: En esta etapa se suben a la base de datos las imágenes de las anomalías de los pollos, y se les asignan sus correspondientes etiquetas. Las etiquetas son anotaciones que contienen información sobre las clases de objetos y las coordenadas de los límites. Validación y organización: Después de cargar los datos, RoboFlow almacena los archivos (imágenes) y los organiza en una estructura que se considera más adecuada para entrenar el modelo. El etiquetado adecuado y las anotaciones precisas son cruciales como se muestra la Figura 5..

Procesamiento: La plataforma RoboFlow permite la preparación de todos los datos recopilados antes de que se utilicen para mejorar el modelo de algoritmo preferido.




Figura 5: Etiquetado de imágenes

C. Selección y configuración del modelo

En esta etapa, se selecciona y configura el modelo para la red. Selección del modelo YOLOv8: Se elige la versión 8 del modelo YOLO por ser la que mejor se adapte a los requisitos y objetivos del proyecto. La elección del modelo específico depende de factores como la velocidad de inferencia necesaria, la precisión deseada y los recursos de hardware disponibles. Se elige la versión 8 de YOLO porque representa la última iteración disponible en RoboFlow.

Configuración del modelo: Después de seleccionar la versión del modelo, los parámetros se configuran para que se ajusten mejor a las necesidades del proyecto. RoboFlow ofrece una interfaz intuitiva para esta configuración.

D. Entrenamiento, validación y ajuste de modelos

En esta etapa, el modelo YOLO se ajusta a los datos de entrenamiento para aprender a detectar anomalías en pollos. Antes del entrenamiento, se configuran los parámetros y las opciones de la plataforma RoboFlow, incluida la elección del modelo YOLO, la configuración de los parámetros de entrenamiento, la función de pérdida y otros ajustes específicos del modelo. Se definen las imágenes que se utilizarán para el entrenamiento y la validación. El entrenamiento se produce en iteraciones, donde el modelo ajusta sus ponderaciones para minimizar la función de pérdida mientras se atraviesa el conjunto de datos de entrenamiento. Durante este proceso, el modelo compara sus predicciones con anotaciones reales,

calculando la pérdida. Después En cada iteración, el rendimiento del modelo se evalúa en el conjunto de datos de validación para medir la precisión, la recuperación y otras métricas, lo que garantiza la generalización a los datos no vistos durante el entrenamiento. En caso de resultados insatisfactorios en la validación, la configuración del modelo o los parámetros se pueden ajustar a través de experimentos iterativos para optimizar el rendimiento.

E. Métricas de evaluación

En esta sección, se explican las métricas de evaluación utilizadas por RoboFlow, incluidas las pérdidas de cajas, clases y objetos, y cómo se calculan los mAP, la precisión y la recuperación como se muestra en la Figura 6. Pérdida de caja: evalúa la precisión en la ubicación y el tamaño de los cuadros delimitadores predichos por el modelo para los objetos de una imagen. Mide la discrepancia entre las coordenadas predichas y las reales; Una pérdida más baja indica una mejor capacidad del modelo para localizar objetos con precisión. Pérdida de clase: mide la precisión del modelo en la asignación de etiquetas de clase correctas a las detecciones. Una pérdida más baja indica una mayor capacidad del modelo para identificar tipos específicos de objetos en la imagen. Pérdida de objetos: refleja cómo el modelo intenta detectar la presencia o ausencia general de objetos.




Figura 6: Métricas de evaluación

III. RESULTADOS Y ANÁLISIS

En esta etapa, se presentan los resultados de todos los incrementos realizados desde el principio hasta el final, logrando un mPA del 70%. La investigación empleó una metodología incremental [19, 20, 21, 22].

A. Resultados iniciales

La primera iteración arrojó malos resultados con un mPA bajo debido a un etiquetado inadecuado de los objetos, derivado de la falta de comprensión de la apariencia física de las anomalías en los pollos. La iteración implicó los siguientes aumentos:

Tratamiento:

- Cambiar tamaño: Estirar a 640x640 Aumentos:
- Escala de grises: se aplica al 25% de las imágenes
- Ruido: Hasta el 5% de los píxeles

Esta configuración dio como resultado un mPA del 51,1 %, una precisión del 65,5 % y un bajo recuerdo del 45,5 %. El conjunto de datos incluía 1786 imágenes. La Figura 7 posteriores muestran los gráficos de entrenamiento.




Figura 7: Resultado de entrenamiento

B. Segundos resultados

La segunda iteración mostró una mejora en los resultados de mAP atribuida a un mejor etiquetado de objetos (Figura 8). La iteración incluyó:

Tratamiento:

- Cambiar tamaño: Estirar a 640x640 Aumentos:
- Escala de grises: se aplica al 25% de las imágenes
-

Esta configuración logró un mPA del 59,1 %, una precisión del 57,4 % y una recuperación del 60,3 %, utilizando un conjunto de datos de 1144 imágenes. Se ilustran los gráficos de entrenamiento.




Figura 8: Resultado de entrenamiento

C. Tercer resultado

El aumento del número de imágenes dio lugar a resultados mejorados de mAP con las siguientes características:

Tratamiento:

- Orientación automática: Aplicado
- Cambiar tamaño: Estirar a 640x640
- Escala de grises: Aumentos aplicados:
- Rotación de 90°: en el sentido de las agujas del reloj, en sentido contrario a las agujas del reloj
 - Escala de grises: se aplica al 25% de las imágenes
 - Brillo: Entre -25% y +25%
 - Exposición: Entre -25% y +25%
 - Ruido: Hasta el 5% de los píxeles

Esta configuración dio como resultado un mPA del 65,2 %, una precisión del 62,9 % y un recuerdo del 58,2 %. El conjunto de datos constaba de 2885 imágenes, con gráficos de entrenamiento proporcionados (Figura 9).



Figura 9: Resultado de entrenamiento

D. Cuarto resultado

Para esta iteración se realizó un incremento más donde se obtuvo una mejora de las tres métricas, manejando un mejor etiquetado y una revisión exhaustiva de cada clase y en base a que se cargaron datos lo que era el incremento de imágenes al ser varias etiquetas es más difícil mantener un resultado igual para todas como, Es mejor hacerlo por separado y luego juntarlos en una sola red, luego, se muestra la configuración con la que se entrenó la red.

Tratamiento:

- Cambiar tamaño: Estirar a 640x640
- Orientación automática: Aplicado

Mejoras:

- Ruido: Hasta el 5% de los píxeles
- Exposición: Entre -5% y +5%

Con esta configuración obtuvimos el resultado de un mPA del 70,2%, una precisión del 70,2% y un recuerdo del 70,3%. y el banco de imágenes utilizado de la cantidad de 2942 imágenes. En la Figura 10 se muestran las parcelas de entrenamiento.




Figura 10: Resultado de entrenamiento

E. Resultado final

Para esta iteración, se manejó un mejor etiquetado y una revisión exhaustiva de cada clase en base a los resultados cuartos, se muestra la configuración con la que se entrenó la red.

Tratamiento:

- Orientación automática: Aplicado

Aumentos:

- Rotación: Entre -45° y +45°.
- Tono: Entre -25° y +25°
- Exposición: Entre -5% y +5% o Ruido: Hasta 5% de píxeles
- Ruido: Hasta el 5% de los píxeles

Con esta configuración obtuvimos el resultado de un mPa del 74,4%, una precisión del 73,0% y un recuerdo del 70,0% y el banco de imágenes utilizado de la cantidad de 2928 imágenes. En la Figura 11 se muestran las parcelas de entrenamiento




Figura 11: Resultado de entrenamiento

F. Gráfico comparativo de 4 iteraciones

Una representación gráfica de las cuatro iteraciones ilustra la eficacia de la metodología incremental (Figura 12). Progresar del 50 % al 70 % de eficacia en cuatro iteraciones subraya el valor del enfoque. El análisis de cada iteración informó incrementos, lo que resultó en mejores resultados.

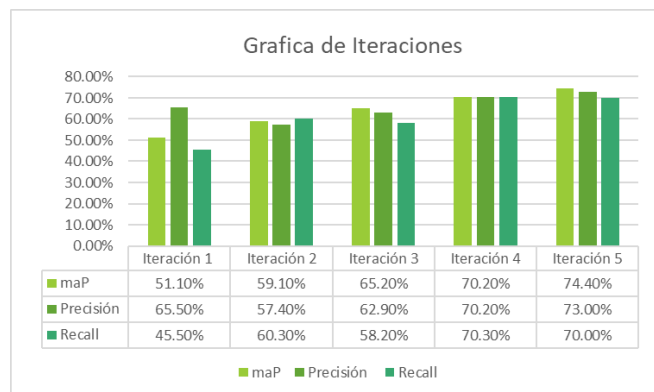


Figura 12: Grafica de entrenamientos

IV. CONCLUSIÓN

Se ha logrado con éxito la identificación y documentación detallada de anomalías comunes durante el período de engorde de pollos. Se ha prestado especial atención a la comprensión de la naturaleza y manifestación de estas anomalías, cruciales para el desarrollo de un sistema de detección eficaz. Se ha llevado a cabo la selección y configuración de una red neuronal específica, YOLOv8. Este modelo fue elegido por su capacidad para manejar algoritmos de detección de objetos, desempeñando un papel vital en la identificación temprana de anomalías en el proceso de engorde de pollos. La metodología incremental aplicada en el desarrollo de sistemas ha demostrado ser eficaz en la mejora continua de la detección de anomalías. La eficacia de la red neuronal se ha evaluado utilizando métricas como mAP, precisión y recuperación. A través de

múltiples iteraciones, se ha logrado un sólido 70% de mAP, lo que indica un fuerte rendimiento en la detección temprana de anomalías.

La iteración constante y el ajuste de los parámetros, incluidas las técnicas de procesamiento de datos y el aumento, han sido esenciales para el éxito del modelo. La metodología incremental no solo mejoró la precisión del sistema, sino que también proporcionó información valiosa sobre la naturaleza y la variabilidad de las anomalías en el contexto avícola. El análisis detallado de cada iteración con gráficos visuales ha permitido una comprensión profunda del rendimiento del modelo en diferentes etapas de desarrollo. La investigación ha desarrollado con éxito un sistema robusto basado en inteligencia artificial, utilizando específicamente redes neuronales convolucionales, para la detección temprana de anomalías en aves de engorde. Este enfoque no solo cumplió con los objetivos establecidos, sino que superó las expectativas al lograr una efectividad del 70% en la detección de anomalías, mejorando así la salud y la calidad del producto avícola final en la industria.

REFERENCES

- [1] «SmartPoultry: Detección temprana de enfermedades avícolas a partir de imágenes fecales capturadas con teléfonos inteligentes». Accedido: 2 de octubre de 2023. [En línea]. Disponible en: <https://ieeexplore.ieee.org/document/10202054/>
- [2] «chapitre_aw_broiler_chicken.pdf». Accedido: 1 de noviembre de 2023. [En línea]. Disponible En: https://www.woah.org/fileadmin/Home/esp/Health_standards/tahc/current/chapitre_aw_broiler_chicken.pdf
- [3] A. Meluzzi y F. Sirri, «Bienestar de los pollos de engorde», Ital. J. Anim. Sci., vol. 8, ene. 2010, doi: 10.4081/ijas.2009.s1.161.
- [4] E. Agropedia, «Pollos de engorde: conoce su cría, razas y alimentación», Agrotendencia.tv. Accedido: 1 de noviembre de 2023. [En línea]. Disponible en: <https://agrotendencia.tv/agropedia/avicultura/cria-de-pollos-de-engorde/>
- [5] D. Brito, M. Martínez, y C. Perea, «Manejo sanitario de pollos de engorde en granjas de Cundinamarca, Colombia», Rev. Sist. Prod. Agroecol., vol. 8, pp. 95-119, jun. 2017, doi: 10.22579/22484817.697.
- [6] C. Torres-Vinueza, L. Ron Garrido, y J. Grijalva, «Evaluación de factores de riesgo que afectan la mortalidad en pollos de engorde durante el proceso de traslado granja-planta de faenamiento en el centro norte de la región interandina», Siembra, vol. 8, abr. 2021, doi: 10.29166/siembra.v8i1.2559.
- [7] O. Montesinos-López, A. Montesinos, y J. Crossa, «Convolutional Neural Networks», 2022, pp. 533-577. doi: 10.1007/978-3-030-89010-0_13.
- [8] S. Albawi, T. A. Mohammed, y S. Al-Zawi, «Understanding of a convolutional neural network», en 2017 International Conference on Engineering and Technology (ICET), hace 2017. 2017, págs. 1-6. doi: 10.1109/ICEngTechnol.2017.8308186.
- [9] X. Chen y X. Yang, «Chicken Estire Disease Recognition Model Based on Improved ResNeXt50», J. Phys. Conf. Ser., vol. 2562, n.o 1, p. 012009, ago. 2023, doi: 10.1088/1742-6596/2562/1/012009.
- [10] M. Kholil, H. P. Waspada, y R. Akhsani, «Clasificación de enfermedades infecciosas en pollos basada en imágenes de heces mediante aprendizaje profundo», en 2022 International Conference on Electrical and Information Technology (IEIT), septiembre de 2022, pp. 362-365. doi: 10.1109/IEIT56384.2022.9967850.
- [11] K. H. Nguyen, H. V. N. Nguyen, H. N. Tran, y L.-D. Guo, «Combinación de Autoencoder y el modelo Yolov6 para la clasificación y detección de enfermedades en pollos», en Actas de la 8ª Conferencia Internacional sobre Tecnología de la Información Inteligente 2023, en ICIIT '23. Nueva York, NY, EE.UU.: Asociación de Maquinaria de Computación, jul. 2023, págs. 132-138. doi: 10.1145/3591569.3591591.

- [12] T. S, V. J, y S. K, «GLCM and K-Means based Chicken Gender Classification», en 2021 Smart Technologies, Communication and Robotics (STCR), octubre de 2021, pp. 1-5. doi: 10.1109/STCR51658.2021.9588864.
- [13] T. Joel, B. S. Dharshini, D. D. Gangaaraam, Poojitha, y N. Kumar, «Un método novedoso para detectar y predecir enfermedades emergentes en pollos de aves de corral basado en el modelo MobileNet», en 2023 Conferencia Internacional sobre Avances en Computación, Comunicación e Informática Aplicada (ACCAI), mayo de 2023, pp. 1-8. doi: 10.1109/ACCAI58221.2023.10200749.
- [14] D. Gustian, A. Darmawan, M. I. Tohir, D. Supardi, S. Nurjanah, A. P. Junfhrana, «Selección de pollos de engorde de calidad mediante la técnica de minería de datos», en 2019 International Conference on ICT for Smart Society (ICISS), nov. 2019, págs. 1-6. doi: 10.1109/ICISS48059.2019.8969819.
- [15] A. Bonde et al., «PigNet: Failure-Tolerant Pig Activity Monitoring System Using Structural Vibration», en Actas de la 20ª Conferencia Internacional sobre Procesamiento de la Información en Redes de Sensores (co-ubicada con CPS-IoT Week 2021), en IPSN '21. Nueva York, NY, EE. UU.: Asociación de Maquinaria Informática, mayo de 2021, pp. 328-340. doi: 10.1145/3412382.3458902.
- [16] A. Y. Arifin, W. Suwito, y Andriani, «La transmisión de Salmonella pullorum en la granja de pollos KUB en Sleman, Yogyakarta», AIP Conf. Proc., vol. 2628, n.o 1, p. 090001, jun. 2023, doi: 10.1063/5.0144001.
- [17] «Detección del movimiento de las aves de corral para el análisis del comportamiento de las aves de corral mediante el algoritmo de seguimiento multiobjeto (MOT) | Publicación de la Conferencia IEEE | IEEE Xplore». Consultado: 6 de octubre de 2023. [En línea]. Disponible en: <https://ieeexplore.ieee.org/document/9467144>
- [18] H. Zhang y C. Chen, «Design of Sick Chicken Automatic Detection System Based on Improved Residual Network», en 2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC), junio de 2020, pp. 2480-2485. doi: 10.1109/ITNEC48623.2020.9084666.
- [19] M. S. Fuentes, N. A. L. Zelaya, y J. L. O. Ávila, «Coffee Fruit Recognition Using Artificial Vision and neural NETWORKS», en 2020 5th International Conference on Control and Robotics Engineering (ICCRE), abril de 2020, pp. 224-228. doi: 10.1109/ICCRE49379.2020.9096441.
- [20] E. M. T. Caballero y A. M. R. Duke, «Implementation of Artificial Neural Networks Using NVIDIA Digits and OpenCV for Coffee Rust Detection», en 2020 5th International Conference on Control and Robotics Engineering (ICCRE), abril de 2020, pp. 246-251. doi: 10.1109/ICCRE49379.2020.9096435
- [21] J. Sánchez-Palma and J. L. Ordoñez-Ávila, "A PID Control Algorithm With Adaptive Tuning Using Continuous Artificial Hydrocarbon Networks for a Two-Tank System," in IEEE Access, vol. 10, pp. 114694-114710, 2022, doi: 10.1109/ACCESS.2022.3217209.
- [22] R. Espinal-Lanza, M. E. Perdomo, J. Sanchez-Palma and J. L. Ordoñez-Avila, "Comparison of Deep Learning Technologies Applied to the Recognition of Defects in Cocoa Beans," 2023 IEEE 41st Central America and Panama Convention (CONCAPAN XLI), Tegucigalpa, Honduras, 2023, pp. 1-6, doi: 10.1109/CONCAPANXLI59599.2023.10517568.