

Aplicación de Deep Learning para el diagnóstico rápido y preciso de fracturas óseas en perros mediante imágenes radiográficas

Application of Deep Learning for the rapid and accurate diagnostic of bone fractures in dogs using radiographic images

Fernando Armijos-Aguilar^{*}, Iván Ramírez-Morales^{}, Lorena Zapata-Saavedra^{}

Facultad de Ciencias Agropecuarias, Universidad Técnica de Machala, Centro de Postgrados Universidad Técnica de Machala, Machala – El Oro, Ecuador.

^{*}Autor correspondencia: farmijos4@utmachala.edu.ec

RESUMEN

La radiografía continúa siendo la herramienta diagnóstica de mayor uso en la medicina veterinaria para la detección de fracturas óseas en perros. No obstante, su interpretación manual puede verse afectada por la experiencia del profesional, así como por factores como el cansancio o la sobrecarga laboral. En este contexto, el presente estudio evaluó el desempeño de un modelo de deep learning basado en la arquitectura YOLOv5, orientado al diagnóstico de imágenes radiográficas caninas divididas en dos categorías: presencia o ausencia de fracturas. El modelo alcanzó una precisión del 83.3%, superando significativamente a tres médicos veterinarios generales, quienes registraron porcentajes de acierto de entre el 40% y el 70%. Además, el sistema automatizado permitió reducir el tiempo promedio de diagnóstico en un 40%, logrando clasificaciones en cuestión de segundos. Esos resultados resaltan la viabilidad de la inteligencia artificial como herramienta para mejorar la precisión, la rapidez y la consistencia del diagnóstico en medicina veterinaria, especialmente en entornos con recursos humanos limitados. Se recomienda ampliar la base de datos y validar el modelo en contextos clínicos reales.

Palabras clave: Deep learning; radiología; inteligencia artificial; fracturas; Veterinaria

ABSTRACT

Radiography remains the most widely used diagnostic tool in veterinary medicine for detecting bone fractures in dogs. However, manual interpretation can be affected by the clinician's level of experience, as well as by factors such as fatigue or excessive workload. In this context, the present study evaluated the performance of a deep learning model based on the YOLOv5 architecture, aimed at diagnostic canine radiographic images divided into two categories: presence or absence of fracture. The model achieved an accuracy of 83.3%, significantly outperforming three general practice veterinarians, whose accuracy ranged from 40% to 70%. Furthermore, the automated system reduced the average diagnostic time by 40%, delivering classifications within seconds. These results highlight the feasibility of artificial intelligence as a tool to enhance diagnostic precision, speed, and consistency in veterinary medicine, especially in resource-constrained environments. Further dataset expansion and clinical validation are recommended.

Key words: Deep Learning; radiology, artificial intelligence, fractures, Veterinary Medicine

INTRODUCCIÓN

La inteligencia artificial ha evolucionado a lo largo del tiempo desde sus primeras conceptualizaciones hasta convertirse ahora en una herramienta práctica en múltiples campos. René Descartes y Charles Babbage sentaron las bases teóricas y prácticas, mientras que John McCarthy adoptó el término “inteligencia artificial” para describir máquinas capaces de realizar tareas que requieren razonamiento humano [1]. Desde la creación y formalización del pensamiento computacional hasta su aplicación en tareas complejas. Actualmente, la IA está presente en diversos sectores como la medicina, manufactura y banca, potenciando la conectividad global y la competitividad en un mundo cada vez más interconectado [2].

En particular, el *deep learning*, una rama de la IA, se ha destacado por su capacidad para aprender y reconocer patrones complejos en datos visuales, como imágenes médicas. Esta tecnología, que utiliza redes neuronales convolucionales (CNN), ha demostrado ser revolucionaria en el diagnóstico médico, brindando mayor precisión y rapidez en la detección de patologías tanto en humanos como en animales [3].

En el ámbito de la Medicina Veterinaria, la radiología es la técnica de diagnóstico más apropiada y utilizada para identificar fracturas óseas debido a su accesibilidad y costo reducido [4]. Sin embargo, la interpretación manual de las imágenes radiográficas depende en gran medida de la experiencia interpretativa del profesional, lo que puede incurrir en errores diagnósticos debido a factores como la fatiga, la variabilidad en la calidad de las imágenes y la carga laboral en las clínicas veterinarias. Estas limitaciones pueden alterar o retrasar el diagnóstico y llevar a no brindar atención adecuada para el paciente [2].

En los últimos años, la incorporación de técnicas y herramientas avanzadas de inteligencia artificial (IA), en particular el *deep learning*, han abierto nuevas posibilidades diagnósticas en las áreas de la salud. El *deep learning*, especialmente las CNN, ha demostrado una eficacia mayor en la detección y clasificación de patrones complejos en imágenes médicas humanas, reduciendo tanto el tiempo de diagnóstico como la incidencia de errores derivados de la interpretación visual [3].

Esta tecnología tiene el potencial de transformar la práctica veterinaria al proporcionar diagnósticos rápidos y precisos en la detección de fracturas óseas, mejorando así la toma de decisiones clínicas [3].

Estudios previos en medicina humana, como el modelo CheXNeXt de Rajpurkar *et al.* [5], han evidenciado que las CNN pueden igualar o incluso superar la precisión de radiólogos expertos en la identificación de patologías radiográficas, con tiempos de diagnóstico significativamente reducidos. En el contexto veterinario, donde las bases de datos radiográficas son limitadas, la implementación de CNN podría ajustarse mediante estrategias de aumento de datos y transferencia de aprendizaje. Aun así, existen barreras relacionadas con la calidad de los datos, la adaptabilidad a diferentes especies y la integración en el flujo de trabajo clínico [5].

El sistema esquelético de los perros es fundamental para la movilidad y la protección de órganos. Factores como la densidad ósea, la dieta y la actividad física influyen en la susceptibilidad

a fracturas, siendo más comunes las oblicuas, espirales y transversales [6]. Investigaciones como la de Mora-Tola *et al.* [7] destacan la relación entre los tipos de fracturas y las fuerzas biomecánicas que las provocan, además subrayan que ciertas razas grandes tienen mayor predisposición a fracturas debido a su peso y nivel de actividad.

Las radiografías son el método de diagnóstico más comúnmente usado para evaluación de fracturas, aunque, también existen herramientas avanzadas como la tomografía computarizada que ofrecen mayor detalle, pero su uso sigue siendo limitado en entornos clínicos veterinarios por razones de costo y disponibilidad [8].

El uso de *deep learning* en la radiología veterinaria ha revolucionado el análisis de imágenes médicas. Las CNN, en particular, destacan por su capacidad para procesar grandes volúmenes de datos y aprender patrones relevantes sin intervención manual [9]. Modelos como CheXNeXt han demostrado que estas redes pueden igualar o incluso superar a especialistas humanos en tareas específicas de clasificación, reduciendo además el tiempo de diagnóstico de manera significativa [10].

En Medicina Veterinaria, las CNN han sido adaptadas para abordar particularidades anatómicas y limitaciones de los datasets disponibles, empleando técnicas como el aumento de datos y el aprendizaje por transferencia [9]. Estas estrategias permiten superar las barreras asociadas con la diversidad limitada de las imágenes veterinarias, optimizando la precisión en la detección de fracturas [3].

Los modelos de *deep learning* presentan ventajas significativas frente a los métodos manuales tradicionales [11]. La precisión y sensibilidad logradas por las CNN superan las de los veterinarios en estudios controlados, destacándose también por su consistencia y reducción de errores diagnósticos [12]. Además, el tiempo de diagnóstico promedio con herramientas automatizadas es considerablemente menor, lo que mejora la eficiencia clínica, especialmente en entornos con alta carga laboral [13].

La adopción de la IA en medicina veterinaria plantea oportunidades y desafíos. Por un lado, sistemas como las CNN pueden integrarse fácilmente en el flujo de trabajo clínico, asistiendo tanto a expertos como a personal no especializado [14]. Por otro lado, aspectos como el sesgo en los datos, la calidad de las imágenes y la aceptación por parte de los profesionales veterinarios son cuestiones que deben abordarse [3].

Desde una perspectiva ética, el desarrollo de estos sistemas debe regirse por principios que aseguren la privacidad de los datos y el uso responsable de la tecnología. Iniciativas como la Declaración de Montreal para un Desarrollo Responsable de la IA promueven la transparencia y la regulación adecuada en el avance de estas tecnologías [15].

En este estudio, se plantea la implementación y evaluación de un modelo de *deep learning* para la detección de fracturas óseas en perros mediante imágenes radiográficas, con el objetivo de mejorar la precisión diagnóstica en comparación con los métodos tradicionales de interpretación manual; reducir el tiempo de diagnóstico, facilitando la toma de decisiones rápidas en entornos de alta demanda; y, minimizar los errores

Aplicación DEEP Learning en imágenes radiográficas / Armijos-Aguilar y cols.

diagnósticos, evaluando métricas como falsos positivos y negativos.

Se espera que la investigación contribuya a la optimización de la práctica veterinaria, mejorando la eficiencia clínica y el cuidado de los pacientes. Además, se analizará la aplicabilidad y viabilidad del modelo en centros veterinarios, considerando su integración en el flujo de trabajo actual y su impacto en la carga laboral de los Veterinarios.

MATERIALES Y MÉTODOS

Este estudio experimental y comparativo fue diseñado para desarrollar y evaluar un modelo de *deep learning* basado en CNN, específicamente YOLOv5, con el objetivo de diagnosticar imágenes radiográficas de perros según la presencia o ausencia de fracturas óseas. El enfoque incluyó la comparación del desempeño del modelo con la interpretación manual realizada por tres Veterinarios no especializados en radiología y un sujeto no veterinario asistido por IA. La metodología se diseñó cuidadosamente para garantizar la rigurosidad científica y la aplicabilidad de los resultados en contextos clínicos reales. El conjunto de datos utilizado en este estudio comprendió un total de 18.740 imágenes radiográficas en formato JPEG convertidas a partir de archivos DICOM, obtenidas de múltiples fuentes digitales. Estas incluyeron 1.070 imágenes recopiladas de dos clínicas veterinarias, 4.083 de una base de datos preexistente de imágenes de radiografías humanas que fueron usadas para complementar el entrenamiento y el restante 13.587 imágenes fueron generadas mediante técnicas de aumento de datos post entrenamiento que proporcionaron datos representativos de casos reales complementando el volumen necesario para el entrenamiento del modelo.

Se adoptaron criterios estrictos de inclusión y exclusión para asegurar la calidad del conjunto de datos. Solo se consideraron imágenes con diagnósticos confirmados de fracturas presentes o ausentes. Se excluyeron aquellas que presentaban baja calidad, artefactos visibles o lesiones no traumáticas como tumores, con el objetivo de evitar sesgos o resultados confusos durante el entrenamiento y la validación.

El preprocesamiento de las imágenes fue una etapa esencial en este estudio, ya que garantizó la uniformidad de los datos y mejoró la eficiencia del modelo. Cada imagen fue redimensionada a un tamaño estándar de 640x640 píxeles y sus valores de píxeles fueron normalizados a un rango de 0 a 1 para optimizar el rendimiento del modelo.

Para la base de datos utilizada en la presente investigación se realizó un etiquetado previo de las imágenes, clasificándolas en dos grupos "con fractura y sin fractura" como se muestra en la FIG.1, para ello se utilizó la plataforma Supervisely [16].



FIGURA 1. Etiquetado de imágenes radiográficas sin fractura y con fractura. Fuente: El autor

Además, se implementaron técnicas de aumento de datos para generar variaciones artificiales de las imágenes originales, lo que permitió expandir el conjunto de datos y mejorar la robustez del modelo frente a variaciones en las condiciones de las imágenes.

Estas técnicas incluyeron rotaciones aleatorias dentro de un rango de -15° a $+15^\circ$, espejado horizontal, ajustes aleatorios de brillo y contraste, así como zoom con una variación de hasta el 20%. Este proceso aumentó la cantidad de datos disponibles lo que ayuda a evitar el sobreajuste, un problema común en redes neuronales cuando los datos son limitados.

El preprocesamiento y la organización de los datos se llevaron a cabo utilizando Roboflow [17], una plataforma reconocida por su capacidad para gestionar grandes conjuntos de datos en proyectos de visión por computadora. Esta herramienta facilitó la automatización del preprocesamiento, permitiendo un flujo de trabajo eficiente y un manejo óptimo de los datos. Además, Roboflow proporcionó una infraestructura adecuada para entrenar el modelo de clasificación binaria con arquitecturas preentrenadas, optimizando su rendimiento en condiciones de datos heterogéneos.

El modelo desarrollado en este estudio se basó en YOLOv5, una red neuronal convolucional adaptada para la tarea específica de clasificación binaria. Este modelo utilizó una función de pérdida *Binary Cross-Entropy*, optimizada con el algoritmo Adam, que inició con una tasa de aprendizaje de 0,001. El entrenamiento se llevó a cabo durante un máximo de 50 épocas, con un tamaño de lote de 32 imágenes por iteración. Para evitar el sobreajuste, se implementó un mecanismo de detección anticipada o "early stopping", el cual interrumpía el proceso si no se observaban mejoras significativas en el desempeño del modelo durante 10 épocas consecutivas.

Para evaluar el rendimiento del modelo, se seleccionó un subconjunto de validación compuesto por 30 imágenes radiográficas, cuidadosamente seleccionadas de manera aleatoria y previamente clasificadas como "con fractura" o "sin fractura". Cada participante evaluó las imágenes de forma individual, determinando la presencia o ausencia de fracturas. Además, se registró el tiempo empleado por cada evaluador en la clasificación de las imágenes. Los resultados del modelo se compararon con los diagnósticos manuales utilizando métricas estándar ampliamente aceptadas en la evaluación de modelos de aprendizaje automático, como precisión, sensibilidad, especificidad, F1-Score y tiempo promedio de diagnóstico.

El análisis de errores se centró en la identificación y cuantificación de falsos positivos y falsos negativos. Los falsos positivos correspondieron a imágenes clasificadas erróneamente como “con fractura,” mientras que los falsos negativos representaron imágenes clasificadas incorrectamente como “sin fractura.” Este análisis permitió evaluar de manera crítica las limitaciones y fortalezas del modelo, así como identificar áreas para futuras mejoras.

La aplicabilidad clínica del modelo se evaluó considerando su capacidad para reducir significativamente el tiempo de diagnóstico, mejorar la precisión diagnóstica y ofrecer apoyo en entornos clínicos con recursos limitados. Aunque no fue necesario someter el estudio a un comité de ética, ya que las imágenes utilizadas eran anonimizadas y no involucraban procedimientos experimentales en animales vivos, se mantuvieron altos estándares éticos en el manejo de los

datos. Este enfoque asegura que los hallazgos del estudio sean relevantes tanto para la comunidad científica como para la práctica clínica veterinaria.

RESULTADOS Y DISCUSIÓN

El modelo alcanzó un desempeño destacado, como se resume en la TABLA I. Las métricas de precisión (83.3%) y especificidad (93.3%) fueron superiores a las de los tres evaluadores humanos (Veterinarios no especializados), cuyo desempeño osciló entre el 40% y el 70% en precisión. Estos resultados son coherentes con lo señalado por Rajpurkar *et al.*, [11], quienes evidenciaron que las CNN son capaces de igualar o superar a especialistas en la clasificación de imágenes médicas.

TABLA I					
La siguiente tabla muestra las métricas clave del rendimiento del modelo en comparación con evaluadores humanos					
Participante	Precisión (%)	Sensibilidad (%)	Especificidad (%)	F1-Score	Tiempo (min:seg)
Sujeto 1	40	53,3	26,7	0,46	9:18
Sujeto 2	70	86,7	53,3	0,77	11:45
Sujeto 3	66,7	66,7	66,7	0,67	7:16
Sujeto 4	83,3	73,3	93,3	0,78	5:49

Análisis de Precisión y Especificidad

La especificidad elevada del modelo (93.3%) implica su capacidad para identificar correctamente imágenes sin fracturas, minimizando falsos positivos. Este hallazgo es fundamental en la práctica clínica, ya que reduce intervenciones innecesarias que podrían derivar en costos adicionales o afectaciones al bienestar animal. Según McEvoy y Amigo [9], los sistemas basados en IA son particularmente efectivos en reducir este tipo de errores, lo que refuerza su utilidad como herramienta complementaria en el diagnóstico Veterinario.

Sensibilidad y Balance Diagnóstico

Aunque el sujeto 2 mostró la mayor sensibilidad (86.7%), el modelo alcanzó un equilibrio notable entre sensibilidad y especificidad. Esto es crucial, ya que evita tanto la omisión de fracturas (falsos negativos) como la clasificación errónea de imágenes normales como patológicas (falsos positivos). Tal equilibrio es esencial para garantizar la confiabilidad diagnóstica, como destacan Shen *et al.*, [10] en el análisis de redes neuronales convolucionales aplicadas al diagnóstico médico.

Reducción de Tiempos de Diagnóstico

El tiempo promedio de clasificación del modelo (5:49 minutos) fue menor que el de los evaluadores humanos, quienes tardaron entre 7:16 y 11:45 minutos en evaluar las 30 imágenes. Esta eficiencia representa una mejora del 40% respecto al promedio humano, lo cual tiene implicaciones directas en la carga laboral de las clínicas veterinarias. Lakhani y Sundaram, [13] ya habían destacado que las soluciones basadas en *deep learning* aumentan la precisión y optimizan la rapidez diagnóstica en entornos clínicos con alta demanda. Los tiempos de cada sujeto pueden ser observados en la FIG. 2.




FIGURA 2. Comparación de los tiempos de diagnóstico entre los sujetos experimentales. Fuente: El autor.

Comparación de errores diagnósticos

El modelo mostró una incidencia reducida de falsos positivos y negativos en comparación con los evaluadores humanos. Gulshan *et al.*, [18] enfatizaron la importancia de minimizar estos errores para evitar retrasos en el tratamiento o procedimientos innecesarios. La capacidad del modelo para manejar ambos tipos de errores resalta su robustez como herramienta diagnóstica confiable.

El modelo redujo falsos positivos y negativos frente a los evaluadores humanos, coherente con experiencias previas de visión por computador en animales de producción (implementaciones de YOLO) que evidencian transferibilidad a datos heterogéneos y escenarios reales [19]. Este desempeño se enmarca en la evolución de la IA y su adopción creciente en salud [20], sustentado por fundamentos de deep learning

Aplicación DEEP Learning en imágenes radiográficas / Armijos-Aguilar y cols.

que explican ganancias en precisión y generalización con arquitecturas profundas [21], y es consistente con resultados clínicos análogos de nivel especialista reportados en imágenes médicas humanas [22].

Aplicabilidad clínica y limitaciones

La participación de un sujeto no veterinario asistido por IA destaca la facilidad de implementación del modelo en entornos con personal no especializado. Sin embargo, el estudio presenta algunas limitaciones:

1. Uso exclusivo de clasificación binaria: No se segmentaron áreas específicas en las imágenes, lo que podría limitar su aplicabilidad en casos complejos.
2. Restricción del dataset: Aunque se emplearon técnicas de aumento de datos, la base de datos utilizada podría beneficiarse de una mayor diversidad y representatividad.
3. Falta de revisión ética: Aunque el estudio utilizó datos retrospectivos y anonimizados, una evaluación ética podría haber fortalecido su validez.

Los resultados de este estudio refuerzan las observaciones previas de Appleby y Basran, [3] sobre el impacto positivo de la IA en la Medicina Veterinaria, especialmente en el diagnóstico por imágenes. La capacidad del modelo para operar con datos heterogéneos y ofrecer resultados consistentes resalta su aplicabilidad en escenarios clínicos reales. Schmidhuber [14], señaló que los sistemas de IA basados en CNN pueden aprender patrones complejos, lo cual explica el éxito del modelo en este estudio.

Este modelo basado en *deep learning* mejoró la precisión y la especificidad diagnóstica y optimizó el tiempo de análisis, posicionándolo como una herramienta clave para modernizar el diagnóstico radiográfico en medicina veterinaria. Esto refuerza la viabilidad de la inteligencia artificial como apoyo en el diagnóstico de fracturas óseas en perros, con un impacto potencial en la eficiencia clínica.

Para maximizar el impacto clínico del modelo, se recomienda incorporar técnicas de segmentación para identificar áreas específicas de fracturas, tal como sugieren Shen *et al.* [10]. Además, ampliar el dataset con imágenes de diversas razas y patologías óseas, como proponen McEvoy y Amigo, [9]. Finalmente es importante validar el modelo en clínicas veterinarias reales para evaluar su desempeño en entornos operativos y su aceptación por parte del personal. La factibilidad de uso por personal no especializado asistido por IA exige salvaguardas éticas y legales claras incluso con datos retrospectivos y anonimizados [23]. Para maximizar impacto, es pertinente incorporar segmentación y explorar arquitecturas profundas para capturar patrones complejos en fracturas, reforzando la robustez del modelo observado en este estudio [24]; ello debe apoyarse en referencias anatómicas estandarizadas para etiquetas consistentes [25] y en evaluaciones comparativas con expertos que modelen incertidumbre y calibren el rendimiento de forma transparente [26].

CONCLUSIONES

El presente estudio, con el modelo basado en YOLOv5 logró una precisión del 83.3%, mientras que sus oponentes veterinarios obtuvieron resultados inferiores. Esto corrobora que la implementación de la IA y el *deep learning* pueden mejorar en gran manera la eficiencia y eficacia en el diagnóstico radiográfico de fracturas óseas en perros, cumpliendo con el objetivo de la presente investigación.

El modelo mostró un balance óptimo entre precisión, sensibilidad (73.3%) y especificidad (93.3%), reduciendo tanto falsos positivos como falsos negativos en comparación con los diagnósticos manuales. Además, su tiempo promedio de clasificación por imagen fue considerablemente menor al de los veterinarios, optimizando la rapidez diagnóstica.

El desempeño del modelo fue adecuado, mientras que la precisión de los Veterinarios varió considerablemente (40%-70%). Esto evidencia la capacidad del modelo para minimizar la variabilidad propia del diagnóstico manual, confirmando su confiabilidad como herramienta de apoyo en entornos clínicos.

El análisis de falsos positivos y falsos negativos mostró que el modelo presentó menos errores que los veterinarios, corroborando que el uso de *deep learning* puede mejorar la confiabilidad diagnóstica y disminuir el riesgo de diagnósticos incorrectos.

La capacidad del modelo para integrarse en el flujo de trabajo veterinario quedó demostrada al ser usado con éxito por un sujeto no veterinario asistido por IA, logrando un desempeño superior al de los evaluadores humanos. Esto resalta el potencial del modelo para ser utilizado en clínicas veterinarias, donde podría complementar la labor de profesionales y mejorar la eficiencia del diagnóstico, cumpliendo así el último objetivo específico.

Recomendaciones

A pesar de tener resultados positivos prometedores, se debe expandir el estudio con bases de datos más amplias y brindar mejoras al modelo para identificar patrones más complejos presentes en las imágenes. Así también, la implementación del modelo en casos clínicos reales requerirá evaluar su desempeño e impacto en la práctica profesional.

Conflicto de intereses

Los autores declaran no tener ningún conflicto de intereses en la publicación de este manuscrito.

REFERENCIAS BIBLIOGRÁFICAS

- [1] Couch JR. Artificial Intelligence: Past, Present and Future. J. SC Acad. Sci. [Internet]. 2023 [citado 08 Enero 2025]; 21(1):2. Disponible en: <https://goo.su/SYEdM>
- [2] Anwar SM, Majid M, Qayyum A, Awais M, Alnowami M, Khan MK. Medical Image Analysis using Convolutional Neural Networks: A Review. J. Med. Syst. [Internet]. 2018; 42(11):226. doi: <https://doi.org/gfghhd>

- [3] Appleby RB, Basran PS. Artificial intelligence in veterinary medicine. J. Am. Vet. Med. Assoc. [Internet]. 2022; 260(8):819–824. doi: <https://doi.org/p7f6>
- [4] Davenport T, Kalakota R. The potential for artificial intelligence in healthcare. Future Healthc. J. 2019; 6(2):94–98. doi: <https://doi.org/ggf26q>
- [5] Rajpurkar P, Irvin J, Zhu K, Yang B, Mehta H, Duan T, Ding D, Bagul A, Langlotz C, Shpanskaya K, Lungren MP, Ng AY. CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning. Cornell University: Arxiv; 2018 [citado 08 Enero 2025]. doi: <https://doi.org/g88dtm>
- [6] Lubinus Badillo F, Rueda Hernández CA, Marconi Narváez B, Arias Trillos YE. Redes neuronales convolucionales: un modelo de Deep Learning en imágenes diagnósticas. Revisión de tema. Rev. Colomb. Radiol. 2021; 32(3):5591–5599. doi: <https://doi.org/p7f7>
- [7] Mora-Tola MA, Carpio-Alemán FM, Mora-Tola JD, Román-Cárdenas FA. Characterization of fractures of the appendicular skeleton in dogs according to the AO classification. Polo Conoc. 2023 [citado 08 Enero 2025]; 8(3):2440–2457. Disponible en: <https://goo.su/4fgGIK6>
- [8] DeCamp CE, Johnston SA, Dejardin LM, Schaefer SL, Brinker, Piermattei and Flo's Handbook of Small Animal Orthopedics and Fracture Repair. 5th ed. St. Louis: Saunders; 2016.
- [9] McEvoy FJ, Amigo JM. Using machine learning to classify image features from canine pelvic radiographs: evaluation of partial least squares discriminant analysis and artificial neural network models. Vet. Radiol. Ultrasound. 2013; 54(2):122–126. doi: <https://doi.org/f4rr93>
- [10] Shen D, Wu G, Suk HI. Deep learning in medical image analysis. Annu. Rev. Biomed. Eng. 2017; 19(1):221–248. doi: <https://doi.org/gcgmb4>
- [11] Rajpurkar P, Irvin J, Ball RL, Zhu K, Yang B, Mehta H, Duan T, Ding D, Bagul A, Langlotz CP, Patel BN, Yeom KW, Shpanskaya K, Blankenberg FG, Seekins J, Amrhein TJ, Mong DA, Halabi SS, Zucker EJ, Ng AY, Lungren MP. Deep learning for chest radiograph diagnosis: a retrospective comparison of the CheXNeXt algorithm to practicing radiologists. PLoS Med. 2018; 15(11):e1002686. doi: <https://doi.org/gfnkcv>
- [12] Taha AA, Hanbury A. Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool. BMC Med. Imaging. 2015; 15(1):29. doi: <https://doi.org/gb343z>
- [13] Lakhani P, Sundaram B. Deep learning at chest radiography: automated classification of pulmonary tuberculosis by using convolutional neural networks. Radiology. 2017; 284(2):574–582. doi: <https://doi.org/gbp274>
- [14] Schmidhuber J. Deep learning in neural networks: an overview. Neural Netw. 2015; 61:85–117. doi: <https://doi.org/f6v78n>
- [15] Nature Machine Intelligence. A prize for discoveries past, present and future. Nat. Mach. Intell. [Internet]. 2019; 1(5):201. doi: <https://doi.org/p7hf>
- [16] Netter A, Noorzadeh S, Duchateau F, Abrao H, Desternes J, Peyras J, et al. Initial Results in the Automatic Visual Recognition of Endometriosis Lesions by Artificial Intelligence During Laparoscopy: A Proof-of-Concept Study. J Minim Invasive Gynecol. 2025 Sep 3. Online. doi: <https://doi.org/10.1016/j.jmig.2025.08.027>
- [17] Kukartsev VV, Ageev RA, Borodulin AS, Gantimurov AP, Kleshko II. Deep learning for object detection in images: development and evaluation of the YOLOv8 model using Ultralytics and Roboflow libraries. In: Silhavy R, Silhavy P, editors. Software Engineering Methods Design and Application. CSOC 2024. Lecture Notes in Networks and Systems. Cham: Springer; 2024. p. 630. doi: <https://doi.org/p7hg>
- [18] Gulshan V, Peng L, Coram M, Stumpe MC, Wu D, Narayanaswamy A, Venugopalan S, Widner K, Madams T, Cuadros J, Kim R, Raman R, C. Nelson P, Mega JL, Webster DR. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. JAMA. 2016; 316(22):2402–2410. doi: <https://doi.org/gcgk7d>
- [19] Guarnido-Lopez P, Ramirez-Agudelo JF, Denimal E, Benaouda M. Programming and setting up the object detection algorithm YOLO to determine feeding activities of beef cattle: A comparison between YOLOv8m and YOLOv10m. Animals. 2024; 14(19):2821. doi: <https://doi.org/p7hh>
- [20] Abeliuk A, Gutiérrez C. Historia y evolución de la inteligencia artificial. Rev. Bits Cienc. 2021; 21:14–21. doi: <https://doi.org/p7hj>
- [21] Bengio Y, LeCun Y, Hinton G. Deep learning for AI. Commun ACM. 2021; 64(7):58–65. doi: <https://doi.org/gkx7tb>
- [22] Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, Thrun S. Dermatologist-level classification of skin cancer with deep neural networks. Nature. 2017; 542(7639):115–118. doi: <https://doi.org/bxwn>
- [23] Gerke S, Minssen T, Cohen G. Ethical and legal challenges of artificial intelligence-driven healthcare. In: Bohr A, Memarzadeh K, editors. Artificial Intelligence in Healthcare. Amsterdam: Academic press; 2020. p. 295–336. doi: <https://doi.org/gxww>
- [24] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR); Las Vegas, NV, USA; 2016. p. 770–778. doi: <https://doi.org/gdcfkn>
- [25] Evans HE, de Lahunta A. Miller's Anatomy of the Dog. 4th ed. St. Louis: Saunders. Can. Vet. J. 2012; 57(4):381. Available in: <https://goo.su/yiOz0>
- [26] Irvin J, Rajpurkar P, Ko M, Yu Y, Ciurea-Illcus S, Chute C, Marklund H, Haghighi B, Ball R, Shpanskaya K, Seekins J, Mong DA, Halabi SS, Sandberg JK, Jones R, Larson DB, Langlotz CP, Patel BN, Lungren MP, Ng AY. CheXpert: A large chest radiograph dataset with uncertainty labels and expert comparison. Proc. AAAI. Conf. Artif. Intell. 2019; 33(01):590–597. doi: <https://doi.org/ghkh8x>