

Machine Learning en la detección y predicción de enfermedades del ganado: una visión general

*Machine Learning in the detection and prediction of livestock diseases: an
overview*

*Aprendizado de Máquina na detecção e previsão de doenças do gado: uma visão
geral*

Marco Vieto-Vega^{1(*)}, Yaliska Moreno-Gonzalez²

Recibido: 28/03/2024

Aceptado: 09/10/2024

Resumen. - La detección temprana y la predicción de enfermedades en el ganado son esenciales para garantizar la salud y el bienestar de los animales, mejorar la productividad y reducir las pérdidas económicas. En este contexto, el Machine Learning (ML), un avance prominente dentro de la inteligencia artificial emerge como una herramienta revolucionaria para transformar el proceso de identificación y manejo de enfermedades en los animales. Esta tecnología permite desarrollar algoritmos complejos capaces de analizar grandes volúmenes de datos clínicos y ambientales, identificando patrones de alerta temprana en síntomas y comportamientos asociados a enfermedades. A través de modelos predictivos, el ML evalúa factores de riesgo y estima la probabilidad de aparición de enfermedades, lo que mejora significativamente la precisión diagnóstica y la efectividad de los tratamientos. Este artículo revisa de manera exhaustiva el uso de ML en la producción ganadera, abordando aplicaciones, modelos y técnicas de vanguardia para la detección y manejo sanitario del ganado, y plantea oportunidades para una gestión ganadera más eficiente y ética, considerando además los desafíos éticos y de privacidad inherentes a la implementación de estas tecnologías.

Palabras clave: Machine learning; predicción; ganadería; ciencia de datos.

(*) Autor de correspondencia

¹ Ingeniero en Sistemas y Computación. Investigador Independiente, Panamá, mv030790@gmail.com,

ORCID iD: <https://orcid.org/0009-0009-0752-0205>

² Ingeniera en Producción Animal (MSc). Facultad de Ciencias Agropecuarias, Universidad de Panamá, milena2y@gmail.com,

ORCID iD: <https://orcid.org/0000-0001-6643-7713>

Summary. - Early detection and prediction of diseases in livestock are essential to ensure animal welfare, improve productivity, and reduce economic losses in the livestock sector. In this context, Machine Learning (ML), a key advancement within artificial intelligence, emerges as a transformative tool for managing animal health. This technology enables the development of complex algorithms capable of analyzing large volumes of clinical and environmental data, identifying early warning patterns in symptoms and behaviors associated with diseases. Through predictive models, ML assesses risk factors and estimates the likelihood of disease occurrence, significantly enhancing diagnostic accuracy and treatment effectiveness. This article provides a comprehensive review of ML's use in livestock production, covering cutting-edge applications, models, and techniques for disease detection and management in livestock. It also highlights the ethical and privacy challenges that accompany the implementation of these technologies, aiming to pave the way for more efficient and responsible livestock management.

Keywords: Machine learning; prediction; livestock; data science.

Resumo. - A detecção e previsão precoce de doenças em animais de produção são essenciais para garantir o bem-estar animal, otimizar a produtividade e minimizar as perdas econômicas no setor pecuário. Nesse contexto, o Machine Learning (ML), um avanço importante dentro da inteligência artificial, surge como uma ferramenta transformadora para a gestão da saúde animal. Esta tecnologia possibilita o desenvolvimento de algoritmos complexos capazes de analisar grandes volumes de dados clínicos e ambientais, identificando padrões de alerta precoce em sintomas e comportamentos associados a doenças. Através de modelos preditivos, o ML avalia fatores de risco e estima a probabilidade de ocorrência de doenças, aumentando significativamente a precisão diagnóstica e a eficácia dos tratamentos. Este artigo oferece uma revisão abrangente do uso do ML na produção pecuária, abordando as aplicações, modelos e técnicas mais avançadas para a detecção e gestão de doenças no setor. Também discute os desafios éticos e de privacidade inerentes à implementação dessas tecnologias, com o objetivo de abrir caminhos para uma gestão pecuária mais eficiente e ética.

Palavras-chave: Aprendizado de máquina; previsão; pecuária; ciência de dados.

1. Introducción. - La agricultura y ganadería representan sectores fundamentales de la economía global y lo seguirá siendo a medida que la población mundial continúe creciendo. Las enfermedades del ganado representan una preocupación para la seguridad alimentaria mundial, las cuales impactan negativamente la producción y causan pérdidas económicamente significativas. La detección de patógenos se basa en métodos convencionales, como inspecciones visuales y análisis de laboratorio, que requieren tiempo y mano de obra intensiva, lo que retrasa el diagnóstico y eleva los costos de producción [1,2].

En la ganadería moderna, el monitoreo continuo de la salud animal es esencial, y el uso de tecnologías avanzadas con datos en tiempo real permite una gestión más proactiva. Al analizar estos datos mediante técnicas de ciencia de datos y Machine Learning (ML), es posible identificar tempranamente signos de enfermedades, facilitando intervenciones oportunas y reduciendo los costos asociados a diagnósticos tardíos [3].

El ML, una disciplina de la ciencia de datos que combina matemáticas, estadística y programación, desempeña un papel crucial en la extracción de información valiosa de grandes volúmenes de datos [4]. En la ganadería, el ML ha demostrado ser una herramienta poderosa, capaz de detectar patrones en los datos que son invisibles al ojo humano, permitiendo la predicción de enfermedades antes de que los síntomas sean evidentes [5]. Año tras año, el ML encuentra nuevas aplicaciones en campos científicos tan variados como la bioinformática [6,7], bioquímica [8,9], medicina [10,11], meteorología [12]–[14], robótica [15], acuicultura [16,17], demostrando su versatilidad y potencial. Su aplicación en la ganadería se suma a esta lista creciente, marcando un antes y un después en cómo se monitorean y tratan las enfermedades en los animales.

Este documento explora los modelos de ML más efectivos para detectar y predecir enfermedades en el ganado, destacando aplicaciones innovadoras y casos de estudio que evidencian el potencial de esta tecnología en el sector ganadero.

2. Una visión general sobre el ML. - El concepto de ML, introducido por Arthur Samuel en 1959, inauguró una era donde las computadoras pueden aprender de la experiencia, reduciendo la necesidad de programación específica para cada tarea [18]. En ese sentido, como subcampo de la inteligencia artificial, el ML se centra en algoritmos informáticos de autoaprendizaje, que mejoran a través de la experiencia, sin ser programados para ello [19]. Esto resulta en modelos capaces de clasificar, predecir y agrupar datos basados en patrones que emergen de ejemplos previos [20,21].

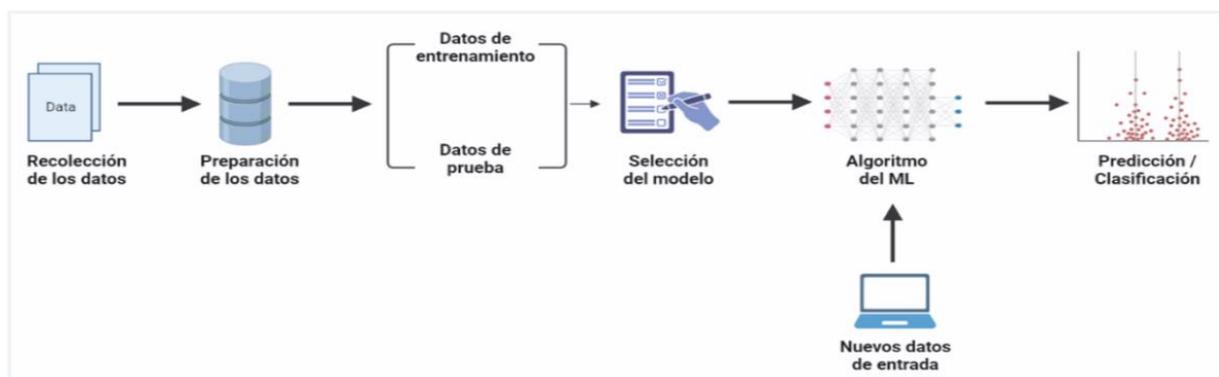


Figura 1. Flujo del trabajo del ML. Fuente: Elaboración propia

El rendimiento de los modelos de ML se mide mediante técnicas estadísticas y matemática, y tras el entrenamiento, se utilizan para analizar nuevos datos basándose en el conocimiento adquirido [20]. Este proceso, ilustrado en la Figura 1, es fundamental para entender cómo el ML aplica la experiencia previa a nuevas situaciones. Una vez que se completa el proceso de aprendizaje, el modelo entrenado se puede utilizar para clasificar, predecir o agrupar nuevos ejemplos (datos de prueba) utilizando la experiencia adquirida durante el proceso de entrenamiento [20]. La Figura 1 representa el proceso tradicional desde la perspectiva de ML.

2.1. Tipos de ML. - Existen tres categorías principales en ML, cada una con aplicaciones específicas en ganadería:

- **Aprendizaje supervisado:** se define como la tarea de ML empleada para inferir resultados a partir de datos etiquetados. Se usan datos de entrenamiento compuestos por datos de ejemplos, y mediante un algoritmo de aprendizaje supervisado, se analizan los datos obteniendo una función que permite inferir resultados a partir de nuevos datos [22].
- **Aprendizaje no supervisado:** se refiere a la tarea de ML encargada de obtener una función que represente el comportamiento o patrón oculto a partir de datos sin etiquetar. Como los datos no tienen etiquetas, no hay una evaluación de la precisión de los resultados del algoritmo [22].
- **Aprendizaje por refuerzo:** es similar al aprendizaje supervisado, pero no utiliza datos de entrenamiento. El algoritmo intenta aprender por ensayo y error, donde una secuencia de resultados satisfactorios refuerza (señalan) los resultados previstos correctamente [21].

La figura II muestra el flujo de los métodos de ML mencionados en esta sección.

2.2. Algoritmos de ML en ganadería. - A continuación, se describen algunos algoritmos clave de ML, destacando sus aplicaciones para la detección y monitoreo de enfermedades en el ganado.

Modelos bayesianos. Son un tipo de modelo estadístico que utiliza el teorema de Bayes y reglas matemáticas para mejorar nuestras predicciones a medida que obtenemos nueva información. Son útiles para tanto para clasificar como para predecir datos, y un ejemplo común es el Naive Bayes para el aprendizaje supervisado [24]. El Naive Bayes, una versión simplificada, es popular para clasificación y predicción, especialmente cuando se cuenta con múltiples indicadores de salud. En ganadería, ha sido empleado para clasificar condiciones de salud como mastitis y predecir riesgos futuros al detectar patrones específicos en datos de historial de salud y actividad.

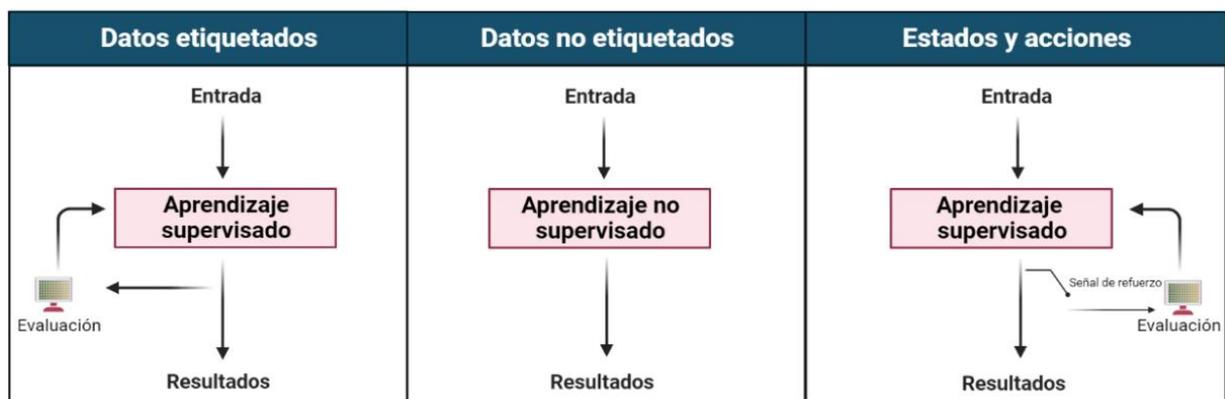


Figura II. Representación de los modelos de ML. Adaptado de [23]

Árboles de decisión. Son un tipo de algoritmo de clasificación y regresión que construyen un árbol de decisiones para llegar a una clasificación final. Se construyen en una estructura similar a un árbol [25], en la que cada nodo representa una decisión o punto de división y cada rama representa un posible resultado de esta división. Las hojas del árbol representan la predicción o clasificación final [26]. Son útiles para la detección de enfermedades, ya que permiten identificar fácilmente factores de riesgo en datos de salud animal, como indicadores de inflamación en análisis de leche. Además, los árboles de decisión brindan transparencia en los resultados, lo cual es importante para interpretar cómo cada factor influye en el diagnóstico final [46].

Redes neuronales (NN). Inspiradas en el cerebro humano, estas redes son sistemas de puntos interconectados que pueden aprender y tomar decisiones, imitando funciones como el reconocimiento de patrones [27]. Se dividen en dos categorías: NN tradicionales y NN profundas. Se usan tanto en aprendizaje supervisado como no supervisado y varían desde estructuras simples hasta redes profundas y complejas. En ganadería, las NN profundas se han utilizado para analizar imágenes termográficas y detectar anomalías en la temperatura corporal de los animales, ayudando en la

identificación temprana de infecciones. Las redes neuronales también se aplican para monitorear actividad y patrones de movimiento, detectando cambios en el comportamiento que podrían indicar estrés o enfermedades [45-48].

K-means clustering. Este algoritmo de agrupamiento, perteneciente al aprendizaje no supervisado, clasifica datos en grupos según la cercanía de los puntos entre sí. Se usan en tareas como agrupamiento de documentos y la segmentación y la compresión de imágenes [28]. Es particularmente útil para monitorear el comportamiento en grandes grupos de animales, agrupando patrones de actividad. En ganadería, K-means ayuda a identificar animales con comportamientos atípicos (por ejemplo, menor actividad o aislamiento), lo cual puede señalar problemas de salud tempranos [38,39].

Support Vector machines (SVM). Las máquinas de soporte vectorial son algoritmos de clasificación y regresión que maximizan la distancia entre clases de datos. Las SVM se introdujeron por primera vez en 1995 [29], sobre la base de la teoría del aprendizaje estadístico. Las SVM funcionan encontrando un hiperplano que separa dos clases de puntos de datos con el mayor margen posible [30], [31]. Los algoritmos SVM son empleados en el aprendizaje supervisado y los más utilizados incluyen la regresión de vectores de soporte [32], máquina de vectores de soporte de algoritmo de proyección sucesiva [33], entre otros. En la ganadería, se aplican para distinguir entre animales sanos y aquellos en riesgo de desarrollar enfermedades. Por ejemplo, en estudios de comportamiento, las SVM pueden separar animales con patrones de movimiento normales de aquellos que muestran signos de cojera o estrés, optimizando la intervención temprana.

Bosques aleatorios. Un bosque aleatorio combina múltiples árboles de decisión para mejorar la precisión y reducir el sobreajuste. Al utilizar un conjunto de árboles, este método aprende tendencias generales en los datos sin ser excesivamente sensible a variaciones específicas [34]. Los bosques aleatorios son efectivos para el análisis de datos complejos de salud animal, como registros de temperatura, producción de leche y frecuencia de visitas al bebedero. Esta técnica permite identificar patrones en grandes volúmenes de datos sin perder precisión en cada decisión individual, ayudando a detectar anomalías como variaciones en el consumo de agua o alimentación que indican posibles problemas de salud [45-48].

2.3. Ejemplos de aplicación del ML en la ganadería. - La implementación de ML en ganadería permite un monitoreo constante de la salud animal y la detección temprana de enfermedades, mejorando así la producción [36,37]. La Figura III muestra el flujo de trabajo para aplicar ML en ganadería de precisión, desde la recopilación y procesamiento de datos hasta el desarrollo y uso de modelos para monitoreo de salud y gestión eficiente de recursos.

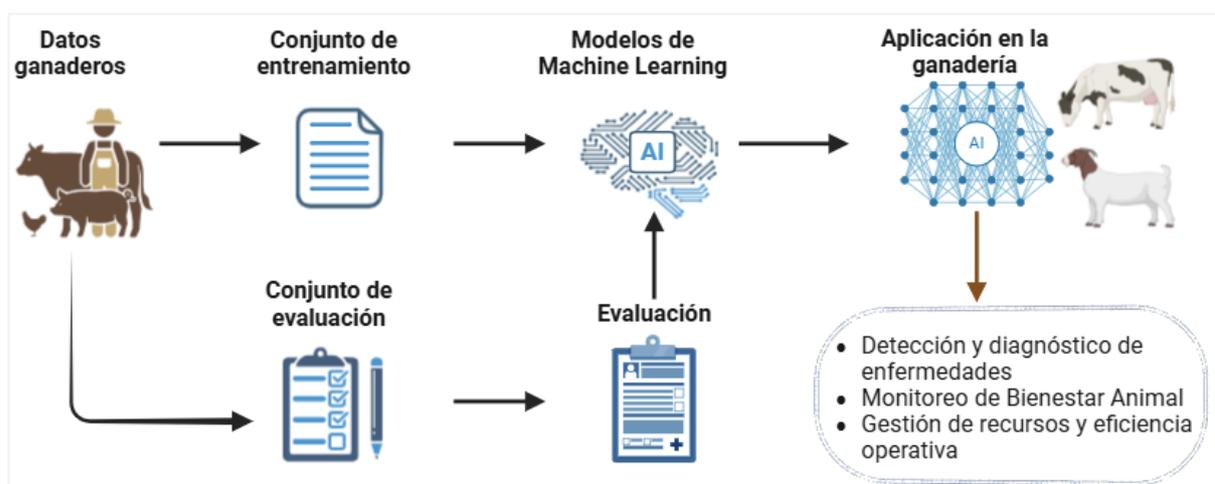


Figura III. Proceso de Implementación de ML en Ganadería de Precisión.

Fuente: Elaboración propia

2.3.1 Bienestar Animal. - Existe una preocupación constante por el bienestar de los animales ya que está estrechamente relacionado con la calidad del producto, la salud del consumidor y la eficiencia económica [38]. Para la evaluación del bienestar animal, existen varios índices, incluidos los indicadores de estrés fisiológico y

comportamiento.

Monitorear el comportamiento de los animales es clave para su bienestar, ya que enfermedades o estrés pueden alterar sus patrones de actividad. Algoritmos de ML, como K-means, permiten identificar cambios en el comportamiento, como la reducción de la actividad o el letargo, que pueden señalar problemas de salud inminentes [38]. Un estudio utilizó K-means para clasificar el comportamiento de aves de corral y detectar signos tempranos de enfermedad [39].

Igualmente, diversos modelos de ML han sido implementados en la producción animal para identificar enfermedades en el ganado, los cuales se detallarán a continuación.

2.3.2 Detección de Mastitis. - La mastitis bovina es la enfermedad con mayor impacto económico en las lecherías a nivel mundial [40], provocada por bacterias, virus y lesiones [41]. Tradicionalmente, esta enfermedad se diagnostica mediante métodos como el conteo de células somáticas y la prueba de mastitis de California; sin embargo, estas técnicas suelen ser subjetivas y requieren personal capacitado, lo cual limita su aplicabilidad a gran escala [42-44].

Modelos como redes neuronales y bosques aleatorios han demostrado eficacia en la detección temprana de mastitis, alcanzando una sensibilidad de hasta el 81% en estudios recientes [45-48]. Asimismo, la combinación de termografía infrarroja con redes neuronales ha logrado una precisión del 90% en la detección de áreas inflamadas, un indicio temprano de infección [49-50].

Además de la detección directa, el ML permite monitorear la salud del hato e identificar vacas en riesgo de desarrollar mastitis, facilitando la toma de medidas preventivas. Por ejemplo, se ha reportado que redes neuronales pueden predecir correctamente el riesgo de mastitis con una sensibilidad del 75% [49]. Otros enfoques en el diagnóstico de mastitis incluyen modelos bayesianos, árboles de decisión y modelos mixtos lineales generalizados, ampliando las opciones y aplicabilidad de los modelos de ML para su detección [46, 51, 52].

2.3.3 Detección de cojeras. - La cojera es una condición dolorosa en animales de producción, caracterizada por anomalías en la marcha debido a lesiones en las extremidades, que puede ser causada por lesiones, enfermedades o deficiencias nutricionales [53,54]. Esta afección provoca pérdidas económicas significativas, afectando la producción de leche, la fertilidad, y generando mayores costos de tratamiento, además de reducir el peso de los animales al sacrificio [55,56].

Para su detección, se han empleado algoritmos de ML como bosques aleatorios, árboles de decisión y el clasificador Naive Bayes, logrando identificar patrones asociados a la cojera de manera efectiva [57-59].

2.3.4. Detección de anemia en cabras y ovejas. - La infección por nematodos gastrointestinales es un problema significativo en la producción de carne de ovejas y cabras, causando impactos económicos directos e indirectos debido a la salud comprometida de los animales. Los animales infectados pueden presentar pérdida de peso subclínica, anemia, reducción de proteínas y disminución en el consumo de alimento debido a la anorexia; en casos graves, estas infecciones pueden llevar a tasas altas de mortalidad [60,61].

Tradicionalmente, se ha utilizado pruebas de sangre y heces para detectar estas infecciones, aunque resultan costosas y conllevan el riesgo de propagación de enfermedades. Esto ha impulsado la creación de métodos más eficaces y menos invasivos. Un ejemplo es el sistema FAMACHA, que evalúa el color de la membrana ocular para identificar animales en riesgo de anemia, facilitando un tratamiento adecuado sin procedimientos invasivos.

Un estudio reciente desarrolló un clasificador de ML basado en SVM para predecir qué animales necesitan tratamiento según su puntuación FAMACHA, alcanzando un 80% de precisión [62]. Este clasificador optimiza la detección temprana y el tratamiento de anemia en ovejas y cabras, contribuyendo a la mejora de su salud y productividad.

3. Estudios de casos en la detección de enfermedades en ganadería con ML. - Un estudio demuestra el uso de ML para detectar enfermedades en vacas lecheras mediante la espectrometría de infrarrojo medio (MIR) [64], en el cual

recolectaron y analizaron 1909 muestras de leche de 467 vacas en dos granjas de Nueva Zelanda. El espectrómetro MIR, una herramienta no invasiva que mide la absorción de luz en varias longitudes de onda, generó perfiles químicos de la leche, permitiendo la detección temprana de condiciones como la mastitis y la cojera sin necesidad de pruebas adicionales. Los datos espectrales fueron preprocesados mediante filtrado y normalización para reducir ruido y mejorar la consistencia. En el análisis se utilizaron algoritmos de ML como Random Forest, SVM y NN, evaluados mediante métricas como sensibilidad, especificidad y el coeficiente de correlación de Matthews (MCC). El modelo de NN fue el más efectivo, logrando una sensibilidad del 62%, una especificidad del 97%, un MCC de 0.57 y un AUC de 79%, destacándose por su balance entre precisión y capacidad de detección.

Otro estudio realizado en Francia investigó el uso de ML para identificar cambios de comportamiento en vacas lecheras con acidosis ruminal subaguda (SARA) [70]. Durante nueve semanas, monitorearon a 28 vacas Holstein con un sistema de posicionamiento en tiempo real para registrar su actividad. De las vacas, 14 fueron inducidas a SARA mediante un cambio dietético, mientras las otras mantuvieron una dieta controlada. Se probaron varios algoritmos de ML, como K-Nearest Neighbors para regresión (KNNR) y árboles de decisión. El KNNR detectó el 83% de episodios de SARA, aunque generó un 66% de falsos positivos. Esto sugiere la necesidad de datos más amplios y modelados individuales para mejorar la precisión en granjas comerciales.

Un estudio desarrollado en 2022 implementó un sistema prototipo de diagnóstico de enfermedades bovinas usando un sistema experto y procesamiento de imágenes con redes neuronales convolucionales (CNN) [71]. Este sistema, dirigido a enfermedades visibles como la enfermedad de la piel y el gusano anular, empleó teléfonos móviles para capturar imágenes y registrar síntomas visuales, además de datos textuales para síntomas detectables solo mediante palpación. Las imágenes fueron procesadas y clasificadas por un modelo CNN que logró un 95% de precisión. Aunque el sistema mostró efectividad en diagnósticos rápidos, tuvo limitaciones en diferenciar enfermedades con síntomas similares, como el gusano anular y el virus de la piel verrugosa. Este sistema tiene un alto potencial para mejorar el diagnóstico en áreas rurales con acceso limitado a veterinarios, especialmente en economías en desarrollo.

En Irlanda, se desarrolló un sistema IoT que combina fog computing y ML para la detección temprana de cojera en vacas lecheras [69]. En el ámbito de la ganadería de precisión, el fog computing permitió procesar los datos de sensores de actividad, posición y signos vitales en un servidor local cercano a la granja, lo que redujo la latencia y evitó la transmisión masiva de datos a un centro remoto. Este sistema monitoreó continuamente a 150 vacas mediante podómetros y sensores para capturar datos sobre pasos, tiempo de descanso y cambios de postura. Gracias al fog computing, el volumen de datos enviados a la nube disminuyó en un 84%, crucial en zonas con conectividad limitada. El modelo de ML, que usó algoritmos de agrupamiento y clasificación, detectó la cojera con un 87% de precisión, hasta tres días antes de su detección visual, superando métodos tradicionales en un 8%. Además, su diseño en microservicios facilita la integración con otros sistemas, ofreciendo una solución adaptable y escalable para distintos entornos agrícolas.

3.1. Limitaciones metodológicas. - Los estudios revisados sobre ML en la ganadería de precisión en la Sección 3, presentan limitaciones metodológicas que afectan la generalización de los resultados. Por ejemplo, un estudio con solo 5.4% de observaciones de vacas enfermas muestra un desbalance de clases, limitando la capacidad del modelo para aplicarse en otros sistemas de producción [64]. Futuras investigaciones con muestras balanceadas mejorarían su precisión y aplicabilidad en la industria ganadera.

Asimismo, la tecnología MIR combinada con ML es una herramienta eficaz y no invasiva para monitorear la salud del ganado, aunque su precisión depende de la calidad y consistencia de los datos. Variaciones en la recolección de muestras pueden afectar los resultados, destacando la necesidad de estudios adicionales para adaptar el modelo a distintos entornos ganaderos.

Otra limitación es la alta tasa de falsos positivos en algunos modelos, como en el caso de la detección de acidosis ruminal, lo cual puede reducir la confianza en estos sistemas [70]. Mejorar la especificidad de los modelos es clave para su adopción en granjas a gran escala.

Por último, el sistema basado en fog computing del estudio [69] requiere configuraciones específicas de cada granja, lo que limita su precisión en lugares sin calibración previa. Además, su implementación enfrenta desafíos en áreas con conectividad limitada, afectando su escalabilidad en regiones rurales.

Estas limitaciones resaltan la importancia de estudios futuros que utilicen metodologías más robustas y muestras representativas para mejorar la aplicabilidad de los modelos en contextos diversos de ganadería.

4. Comparativa del ML en ganadería y otros sectores. - En el desarrollo de aplicaciones de ML en ganadería y medicina humana, existen importantes paralelismos y diferencias. Ambos sectores buscan optimizar la salud y eficiencia, pero enfrentan desafíos específicos relacionados con los datos disponibles, el contexto de aplicación y las implicaciones éticas y de privacidad. Esta sección compara sus aplicaciones y explora posibles oportunidades de transferencia de conocimiento.

En detección de enfermedades y diagnóstico, el ML ha avanzado en medicina para identificar patologías complejas, como el cáncer y enfermedades cardiovasculares, mediante el análisis de imágenes y registros electrónicos [68]. Estos algoritmos destacan en mejorar la rapidez y precisión de los diagnósticos. En ganadería, aunque los datos provienen de sensores de salud y comportamiento animal, el objetivo es igualmente identificar problemas de salud en etapas tempranas para mejorar la productividad y el bienestar animal [64]. Ambos sectores buscan reducir la dependencia de métodos manuales, pero en ganadería la implementación debe adaptarse a entornos rurales y operar con menor supervisión directa.

Respecto a la personalización del tratamiento, el ML en medicina permite diseñar tratamientos individualizados analizando variaciones genéticas y respuestas específicas a medicamentos [66]. En ganadería, el ML puede personalizar el manejo de cada animal, adaptando la alimentación y los tratamientos para optimizar la salud del rebaño y reducir costos, aunque con menos datos clínicos. En ambos casos, la personalización mediante ML permite un manejo más eficiente y reduce el riesgo de complicaciones a largo plazo.

En optimización de recursos y eficiencia, el ML permite en medicina mejorar la administración de registros y flujos de trabajo hospitalarios, reduciendo la carga de los profesionales y mejorando la eficiencia [67]. En ganadería, los sistemas ML facilitan el monitoreo automático del ganado, minimizando la necesidad de inspecciones manuales. Este ahorro de tiempo y recursos es esencial en granjas de gran escala, optimizando la asignación de personal y permitiendo que los ganaderos se enfoquen en actividades de mayor valor añadido.

5. Impacto económico y perspectivas a futuro. - La implementación de ML en la ganadería de precisión tiene un gran potencial económico, aunque se requieren estudios a largo plazo en escenarios comerciales reales para evaluar sus beneficios completos. En general, el ML reduce costos de diagnóstico y tratamiento al permitir una detección temprana de enfermedades, disminuyendo así el uso de antibióticos y tratamientos en granjas de gran escala. También aumenta la productividad con decisiones de manejo basadas en datos, optimizando el uso de recursos del hato. Al automatizar el monitoreo y reducir la necesidad de inspecciones manuales, el ML ahorra mano de obra y mitiga riesgos económicos al prevenir brotes de enfermedades, protegiendo la estabilidad financiera de las granjas y reduciendo la mortalidad del ganado.

Para alcanzar estos beneficios, es clave la colaboración entre especialistas en ciencias de datos y ML, veterinarios, ingenieros zootecnistas, ingenieros de computación y productores. Cada grupo aporta conocimientos esenciales: los expertos en ML desarrollan algoritmos avanzados; los veterinarios y zootecnistas, comprensión de la salud y comportamiento animal; los ingenieros de computación, la implementación y optimización de sistemas; y los productores, experiencia directa en la gestión del ganado. Esta colaboración permite adaptar las soluciones de ML a las condiciones específicas de cada granja, logrando sistemas más confiables y efectivos.

6. Ética y privacidad. - El uso de ML en la ganadería de precisión plantea consideraciones éticas y de privacidad que son clave para una adopción responsable y equitativa. La recolección de grandes volúmenes de datos sobre la salud y el comportamiento animal requiere medidas de seguridad, como cifrado y almacenamiento seguro, para prevenir

accesos no autorizados y el mal uso de la información. La transparencia en el acceso y uso de datos permite a los productores mantener control sobre cómo se emplea la información generada en sus granjas, lo cual es fundamental para construir confianza y seguridad en estas tecnologías [65].

Además, es crucial que las decisiones automatizadas del ML, como alertas de salud o ajustes de manejo, sean comprensibles y permitan la intervención humana cuando sea necesario. Esto asegura que los sistemas complementen el juicio y la experiencia del productor en lugar de reemplazarlos, preservando el enfoque en el bienestar integral de los animales y evitando tratarlos solo como datos.

Finalmente, es importante que el acceso a estas tecnologías sea equitativo, ya que los costos y la complejidad pueden crear una brecha entre grandes y pequeñas operaciones. Para mitigar este desafío, es esencial desarrollar modelos escalables y accesibles, acompañados de políticas de apoyo y programas de capacitación que permitan a todos los productores beneficiarse del ML. Al abordar estos aspectos de seguridad, equidad y transparencia, el ML puede integrarse de manera ética en la ganadería, promoviendo la productividad y el bienestar animal sin comprometer la privacidad de los datos.

7. Conclusión. - La incorporación de ML en la ganadería de precisión muestra un gran potencial para transformar el diagnóstico y la prevención de enfermedades, optimizando tanto la salud animal como la rentabilidad de las granjas. Los algoritmos de ML analizan de forma automatizada y rápida grandes volúmenes de datos provenientes de sensores, registros médicos y patrones de comportamiento, permitiendo identificar correlaciones y señales tempranas de enfermedades que de otro modo serían difíciles de detectar. Esto no solo posibilita intervenciones rápidas y menos costosas, sino que también reduce la dependencia de tratamientos extensivos, mejorando la eficiencia operativa.

8. Perspectivas para investigaciones futuras

Para maximizar estos beneficios, es fundamental profundizar en áreas clave que permitan la implementación eficiente y confiable de ML en la ganadería:

- 1. Desarrollo de modelos más interpretables y específicos:** Los modelos deben ser más comprensibles y adaptables a las particularidades de la producción animal. Esto permitirá que veterinarios y productores confíen y apliquen los resultados de ML en su manejo diario, logrando intervenciones oportunas y ajustadas a cada caso.
- 2. Integración de datos heterogéneos:** La integración de diversas fuentes de datos, desde biometría y comportamiento hasta variables ambientales, ampliará la capacidad predictiva del ML, proporcionando una visión holística del estado de salud animal.
- 3. Aplicación de aprendizaje activo y continuo:** La incorporación de técnicas de aprendizaje activo permitirá que los modelos se adapten constantemente a nuevos datos y escenarios, como cambios estacionales o de manejo, mejorando su precisión y relevancia en tiempo real.
- 4. Evaluación económica a largo plazo:** Estudios futuros deberán abordar de forma integral los costos y beneficios de implementar ML en escenarios de producción real, evaluando el retorno de inversión y el impacto en la sostenibilidad de las granjas. Esta información facilitará una adopción más fundamentada y generalizada del ML en el sector ganadero.

En conjunto, el ML promete una ganadería de precisión más eficiente y sostenible. Su éxito dependerá de la colaboración entre científicos de datos, veterinarios y productores, quienes, al compartir conocimientos y experiencia, podrán adaptar estas tecnologías a las necesidades específicas del sector ganadero.

Referencias

- [1] J. Chen et al., "Retrospect and Risk Analysis of Foot-and-Mouth Disease in China Based on Integrated Surveillance and Spatial Analysis Tools," *Frontiers in Veterinary Science*, vol. 6, 2020. [Online]. Available: <https://www.frontiersin.org/articles/10.3389/fvets.2019.00511>. [Accessed April 24, 2023].
- [2] K. Džermeikaitė, D. Bačėninaitė, and R. Antanaitis, "Innovations in Cattle Farming: Application of Innovative Technologies and Sensors in the Diagnosis of Diseases," *Animals*, vol. 13, no. 5, Art. no. 5, Jan. 2023, doi: 10.3390/ani13050780.
- [3] S. Neethirajan, "The role of sensors, big data and machine learning in modern animal farming," *Sensors and Actuators B: Chemical*, vol. 29, p. 100367, Aug. 2020, doi: 10.1016/j.sbsr.2020.100367.
- [4] X. Kang, S. Li, Q. Li, and G. Liu, "Dimension-reduced spatiotemporal network for lameness detection in dairy cows," *Computers and Electronics in Agriculture*, vol. 197, p. 106922, Jun. 2022, doi: 10.1016/j.compag.2022.106922.
- [5] M. Marimuthu, M. Abinaya, K. S. Hariesh, K. Madhankumar, and V. Pavithra, "A Review on Heart Disease Prediction using Machine Learning and Data Analytics Approach," *International Journal of Computer Applications*, vol. 181, no. 18, pp. 20–25, Sep. 2018.
- [6] S. D. Mackowiak et al., "Extensive identification and analysis of conserved small ORFs in animals," *Genome Biology*, vol. 16, p. 179, Sep. 2015, doi: 10.1186/s13059-015-0742-x.
- [7] L. Kong et al., "CPC: assess the protein-coding potential of transcripts using sequence features and support vector machine," *Nucleic Acids Research*, vol. 35, no. Web Server issue, pp. W345–W349, Jul. 2007, doi: 10.1093/nar/gkm391.
- [8] A. Richardson, B. M. Signor, B. A. Lidbury, and T. Badrick, "Clinical chemistry in higher dimensions: Machine-learning and enhanced prediction from routine clinical chemistry data," *Clinical Biochemistry*, vol. 49, no. 16, pp. 1213–1220, Nov. 2016, doi: 10.1016/j.clinbiochem.2016.07.013.
- [9] J. Wildenhain et al., "Prediction of Synergism from Chemical-Genetic Interactions by Machine Learning," *Cell Systems*, vol. 1, no. 6, pp. 383–395, Dec. 2015, doi: 10.1016/j.cels.2015.12.003.
- [10] J. Kang, R. Schwartz, J. Flickinger, and S. Beriwal, "Machine Learning Approaches for Predicting Radiation Therapy Outcomes: A Clinician's Perspective," *International Journal of Radiation Oncology, Biology, Physics*, vol. 93, no. 5, pp. 1127–1135, Dec. 2015, doi: 10.1016/j.ijrobp.2015.07.2286.
- [11] H. Asadi, R. Dowling, B. Yan, and P. Mitchell, "Machine Learning for Outcome Prediction of Acute Ischemic Stroke Post Intra-Arterial Therapy," *PLOS ONE*, vol. 9, no. 2, p. e88225, Feb. 2014, doi: 10.1371/journal.pone.0088225.
- [12] A. Aybar-Ruiz et al., "A novel Grouping Genetic Algorithm–Extreme Learning Machine approach for global solar radiation prediction from numerical weather models inputs," *Solar Energy*, vol. 132, pp. 129–142, Jul. 2016, doi: 10.1016/j.solener.2016.03.015.
- [13] J. Rhee and J. Im, "Meteorological drought forecasting for ungauged areas based on machine learning: Using long-range climate forecast and remote sensing data," *Agricultural and Forest Meteorology*, vol. 237–238, pp. 105–122, May 2017, doi: 10.1016/j.agrformet.2017.02.011.
- [14] S. Cramer, M. Kampouridis, A. A. Freitas, and A. K. Alexandridis, "An extensive evaluation of seven machine learning methods for rainfall prediction in weather derivatives," *Expert Systems with Applications*, vol. 85, pp. 169–181, Nov. 2017, doi: 10.1016/j.eswa.2017.05.029.
- [15] K. Takahashi, K. Kim, T. Ogata, and S. Sugano, "Tool-body assimilation model considering grasping motion through deep learning," *Robotics and Autonomous Systems*, vol. 91, pp. 115–127, May 2017, doi: 10.1016/j.robot.2017.01.002.
- [16] C. Zhou et al., "Near infrared computer vision and neuro-fuzzy model-based feeding decision system for fish in aquaculture," *Computers and Electronics in Agriculture*, vol. 146, pp. 114–124, Mar. 2018, doi: 10.1016/j.compag.2018.02.006.
- [17] X. A. López-Cortés et al., "Fast detection of pathogens in salmon farming industry," *Aquaculture*, vol. 470, pp. 17–24, Mar. 2017, doi: 10.1016/j.aquaculture.2016.12.008.
- [18] A. L. Samuel, "Some Studies in Machine Learning Using the Game of Checkers," *IBM Journal of Research and Development*, vol. 3, no. 3, pp. 210–229, Jul. 1959, doi: 10.1147/rd.33.0210.
- [19] T. M. Mitchell, *Machine Learning*, New York: McGraw-Hill, 1997, in McGraw-Hill Series in Computer Science.
- [20] K. Liakos, P. Busato, D. Moshou, S. Pearson, and D. Bochtis, "Machine Learning in Agriculture: A Review,"

Sensors, vol. 18, no. 8, p. 2674, Aug. 2018, doi: 10.3390/s18082674.

- [21] "What is Machine Learning?" IBM. [Online]. Available: <https://www.ibm.com/topics/machine-learning>. [Accessed March 5, 2024].
- [22] D. Sharma and N. Kumar, "A Review on Machine Learning Algorithms, Tasks and Applications," 2017, vol. 6, pp. 2278–1323, Oct. 2017.
- [23] M. T. J. P., "Models for machine learning," *IBM Developer*, Dec. 5, 2017. [Online]. Available: <https://developer.ibm.com/articles/cc-models-machine-learning/#reinforcement-learning>. [Accessed December 20, 2023].
- [24] S. N. Peter Russell, *Artificial Intelligence: A Modern Approach*, Englewood Cliffs, N.J, 1995.
- [25] W. A. Belson, "Matching and Prediction on the Principle of Biological Classification," *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, vol. 8, no. 2, pp. 65–75, 1959, doi: 10.2307/2985543.
- [26] L. Breiman, *Classification and Regression Trees*, Routledge, 2017.
- [27] J. R. Quinlan, *C4.5: Programs for Machine Learning*, Morgan Kaufmann, 1993.
- [28] "What is Unsupervised Learning?" IBM. [Online]. Available: <https://www.ibm.com/topics/unsupervised-learning>. [Accessed November 29, 2023].
- [29] C. Cortes and V. Vapnik, "Support-vector networks," *Machine Learning*, vol. 20, no. 3, pp. 273–297, Sep. 1995, doi: 10.1007/BF00994018.
- [30] C.-C. Chang and C.-J. Lin, "LIBSVM: A library for support vector machines," *ACM Transactions on Intelligent Systems and Technology*, vol. 2, no. 3, p. 27:1-27:27, May 2011, doi: 10.1145/1961189.1961199.
- [31] J. A. K. Suykens and J. Vandewalle, "Least Squares Support Vector Machine Classifiers," *Neural Processing Letters*, vol. 9, no. 3, pp. 293–300, Jun. 1999, doi: 10.1023/A:1018628609742.
- [32] A. Smola et al., "Regression Estimation with Support Vector Learning Machines," 1996.
- [33] R. K. H. Galvão et al., "A variable elimination method to improve the parsimony of MLR models using the successive projections algorithm," *Chemometrics and Intelligent Laboratory Systems*, vol. 92, no. 1, pp. 83–91, May 2008, doi: 10.1016/j.chemolab.2007.12.004.
- [34] B. Liu, M. Ma, and J. Chang, Eds., *Information Computing and Applications*, Lecture Notes in Computer Science, vol. 7473, Berlin, Heidelberg: Springer Berlin Heidelberg, 2012, doi: 10.1007/978-3-642-34062-8.
- [35] R. García, J. Aguilar, M. Toro, A. Pinto, and P. Rodríguez, "A systematic literature review on the use of machine learning in precision livestock farming," *Computers and Electronics in Agriculture*, vol. 179, p. 105826, Dec. 2020, doi: 10.1016/j.compag.2020.105826.
- [36] L. Benos, A. C. Tagarakis, G. Dolias, R. Berruto, D. Kateris, and D. Bochtis, "Machine Learning in Agriculture: A Comprehensive Updated Review," *Sensors*, vol. 21, no. 11, p. 3758, May 2021, doi: 10.3390/s21113758.
- [37] A. I. Awad, "From classical methods to animal biometrics: A review on cattle identification and tracking," *Computers and Electronics in Agriculture*, vol. 123, pp. 423–435, Apr. 2016, doi: 10.1016/j.compag.2016.03.014.
- [38] D. Berckmans and M. Guarino, "From the Editors: Precision livestock farming for the global livestock sector," *Animal Frontiers*, vol. 7, no. 1, pp. 4–5, Jan. 2017,
- [39] Z. Feiyang, H. Yueming, C. Liancheng, G. Lihong, D. Wenjie, and W. Lu, "Monitoring behavior of poultry based on RFID radio frequency network," *International Journal of Agricultural and Biological Engineering*, vol. 9, no. 6, Dec. 2016, doi: 10.25165/ijabe.v9i6.1568.
- [40] H. Hogeveen, W. Steeneveld, and C. A. Wolf, "Production Diseases Reduce the Efficiency of Dairy Production: A Review of the Results, Methods, and Approaches Regarding the Economics of Mastitis," *Annual Review of Resource Economics*, vol. 11, pp. 289–312, 2019, doi: 10.1146/annurev-resource-100518-093954.
- [41] S. De Vliegher, L. K. Fox, S. Piepers, S. McDougall, and H. W. Barkema, "Invited review: Mastitis in dairy heifers: Nature of the disease, potential impact, prevention, and control," *Journal of Dairy Science*, vol. 95, no. 3, pp. 1025–1040, Mar. 2012, doi: 10.3168/jds.2010-4074.
- [42] Y. Wang, Q. Li, M. Chu, X. Kang, and G. Liu, "Application of infrared thermography and machine learning techniques in cattle health assessments: A review," *Biosystems Engineering*, vol. 230, pp. 361–387, Jun. 2023, doi: 10.1016/j.biosystemseng.2023.05.002.
- [43] C. J. Sanford et al., "Test characteristics from latent-class models of the California Mastitis Test," *Preventive Veterinary Medicine*, vol. 77, no. 1, pp. 96–108, Nov. 2006, doi: 10.1016/j.prevetmed.2006.06.006.
- [44] P. L. Ruegg, "A 100-Year Review: Mastitis detection, management, and prevention," *Journal of Dairy Science*, vol. 100, no. 12, pp. 10381–10397, Dec. 2017, doi: 10.3168/jds.2017-13023.

- [45] D. Cavero, K.-H. Tölle, C. Henze, C. Buxadé, and J. Krieter, "Mastitis detection in dairy cows by application of neural networks," *Livestock Science*, vol. 114, no. 2, pp. 280–286, Apr. 2008, doi: 10.1016/j.livsci.2007.05.012.
- [46] C. Kamphuis, H. Mollenhorst, J. A. P. Heesterbeek, and H. Hogeveen, "Detection of clinical mastitis with sensor data from automatic milking systems is improved by using decision-tree induction," *Journal of Dairy Science*, vol. 93, no. 8, pp. 3616–3627, Aug. 2010, doi: 10.3168/jds.2010-3228.
- [47] S. A. Naqvi, M. T. M. King, R. D. Matson, T. J. DeVries, R. Deardon, and H. W. Barkema, "Mastitis detection with recurrent neural networks in farms using automated milking systems," *Computers and Electronics in Agriculture*, vol. 192, p. 106618, Jan. 2022, doi: 10.1016/j.compag.2021.106618.
- [48] H. Motohashi, H. Ohwada, and C. Kubota, "Early Detection Method for Subclinical Mastitis in Auto Milking Systems Using Machine Learning," in *2020 IEEE 19th International Conference on Cognitive Informatics & Cognitive Computing (ICCC)*, Sep. 2020, pp. 76–83, doi: 10.1109/ICCC50026.2020.9450258.
- [49] S. Ankinakatte, E. Norberg, P. Løvendahl, D. Edwards, and S. Højsgaard, "Predicting mastitis in dairy cows using neural networks and generalized additive models: A comparison," *Computers and Electronics in Agriculture*, vol. 99, pp. 1–6, Nov. 2013, doi: 10.1016/j.compag.2013.08.024.
- [50] Y. Wang, X. Kang, Z. He, Y. Feng, and G. Liu, "Accurate detection of dairy cow mastitis with deep learning technology: a new and comprehensive detection method based on infrared thermal images," *animal*, vol. 16, no. 10, p. 100646, Oct. 2022, doi: 10.1016/j.animal.2022.100646.
- [51] L. Fadul-Pacheco, H. Delgado, and V. E. Cabrera, "Exploring machine learning algorithms for early prediction of clinical mastitis," **International Dairy Journal**, vol. 119, p. 105051, Aug. 2021, doi: 10.1016/j.idairyj.2021.105051.
- [52] M. Khatun et al., "Development of a new clinical mastitis detection method for automatic milking systems," *Journal of Dairy Science*, vol. 101, no. 10, pp. 9385–9395, Oct. 2018, doi: 10.3168/jds.2017-14310.
- [53] C. Foditsch et al., "Lameness Prevalence and Risk Factors in Large Dairy Farms in Upstate New York. Model Development for the Prediction of Claw Horn Disruption Lesions," *PLOS ONE*, vol. 11, no. 1, p. e0146718, Jan. 2016, doi: 10.1371/journal.pone.0146718.
- [54] F. C. Flower and D. M. Weary, "Gait assessment in dairy cattle," *Animal*, vol. 3, no. 1, pp. 87–95, Jan. 2009, doi: 10.1017/S1751731108003194.
- [55] L. Ózsvári, "Economic Cost of Lameness in Dairy Cattle Herds," *Journal of Dairy, Veterinary & Animal Research*, vol. 6, p. 00176, Dec. 2017, doi: 10.15406/jdvar.2017.06.00176.
- [56] E. Cha, J. A. Hertl, D. Bar, and Y. T. Gröhn, "The cost of different types of lameness in dairy cows calculated by dynamic programming," *Preventive Veterinary Medicine*, vol. 97, no. 1, pp. 1–8, Oct. 2010, doi: 10.1016/j.prevetmed.2010.07.011.
- [57] N. Volkmann, B. Kulig, S. Hoppe, J. Stracke, O. Hensel, and N. Kemper, "On-farm detection of claw lesions in dairy cows based on acoustic analyses and machine learning," *Journal of Dairy Science*, vol. 104, no. 5, pp. 5921–5931, May 2021, doi: 10.3168/jds.2020-19206.
- [58] S. Shahinfar, M. Khansefid, M. Haile-Mariam, and J. E. Pryce, "Machine learning approaches for the prediction of lameness in dairy cows," *Animal*, vol. 15, no. 11, p. 100391, Nov. 2021, doi: 10.1016/j.animal.2021.100391.
- [59] D. Warner, E. Vasseur, D. M. Lefebvre, and R. Lacroix, "A machine learning based decision aid for lameness in dairy herds using farm-based records," *Computers and Electronics in Agriculture*, vol. 169, p. 105193, Feb. 2020, doi: 10.1016/j.compag.2019.105193.
- [60] F. Mavrot, H. Hertzberg, and P. Torgerson, "Effect of gastro-intestinal nematode infection on sheep performance: A systematic review and meta-analysis," *Parasites & Vectors*, vol. 8, no. 1, p. 557, Dec. 2015, doi: 10.1186/s13071-015-1164-z.
- [61] A. C. de S. Chagas, O. Tupy, I. B. dos Santos, and S. N. Esteves, "Economic impact of gastrointestinal nematodes in Morada Nova sheep in Brazil," *Revista Brasileira de Parasitologia Veterinária*, vol. 31, p. e008722, Aug. 2022, doi: <https://doi.org/10.1590/S1984-29612022044>.
- [62] Montout, A. X., Bamber, R. S., Lange, D. S., Ndlovu, D. Z., Morgan, E. R., Ioannou, C. C.,
- [63] Dowsey, A. W., "Accurate and interpretable prediction of poor health in small ruminants with accelerometers and machine learning," bioRxiv, Aug 2020, doi: <https://doi.org/10.1101/2020.08.03.234203>.
- [64] Contla Hernández, B., Lopez-Villalobos, N., & Vignes, M. (2021). "Identifying health status in grazing dairy cows from milk mid-infrared spectroscopy by using machine learning methods." *Animals*, 11(8), 2154.
- [65] Neethirajan, S. (2023). "The significance and ethics of digital livestock farming." *AgriEngineering*, 5(1), 488-505.

- [66] Zhang, Y., Wu, M., Tian, G. Y., Zhang, G., & Lu, J. (2021). "Ethics and privacy of artificial intelligence: Understandings from bibliometrics." *Knowledge-Based Systems*, 222, 106994.
- [67] Secinaro, S., Calandra, D., Secinaro, A., Muthurangu, V., & Biancone, P. (2021). "The role of artificial intelligence in healthcare: a structured literature review." *BMC Medical Informatics and Decision Making*, 21, 1-23.
- [68] Kumar, Y., Koul, A., Singla, R., & Ijaz, M. F. (2023). "Artificial intelligence in disease diagnosis: a systematic literature review, synthesizing framework and future research agenda." *Journal of Ambient Intelligence and Humanized Computing*, 14(7), 8459-8486.
- [69] Taneja, M., Byabazaire, J., Jalodia, N., Davy, A., Olariu, C., & Malone, P. (2020). "Machine learning based fog computing assisted data-driven approach for early lameness detection in dairy cattle." *Computers and Electronics in Agriculture*, 171, 105286. doi: <https://doi.org/10.1016/j.compag.2020.105286>.
- [70] Wagner, N., Antoine, V., Mialon, M.-M., Lardy, R., Silberberg, M., et al. (2020). "Machine learning to detect behavioural anomalies in dairy cows under subacute ruminal acidosis." *Computers and Electronics in Agriculture*, 170, 105233. doi: [10.1016/j.compag.2020.105233](https://doi.org/10.1016/j.compag.2020.105233).
- [71] Lake, B., Getahun, F., & Teshome, F. T. (2022). "Application of artificial intelligence algorithm in image processing for cattle disease diagnosis." *Journal of Intelligent Learning Systems and Applications*, 14(4), 71-88.

Nota contribución de los autores:

1. Concepción y diseño del estudio
2. Adquisición de datos
3. Análisis de datos
4. Discusión de los resultados
5. Redacción del manuscrito
6. Aprobación de la versión final del manuscrito

MVV ha contribuido en: 1, 2, 3, 4, 5 y 6.

YMG ha contribuido en: 1, 2, 3, 4, 5 y 6.

Nota de aceptación: Este artículo fue aprobado por los editores de la revista Dr. Rafael Sotelo y Mag. Ing. Fernando A. Hernández Goberti.