

Árboles de decisión para la predicción del estro en el ganado bovino

Decision Trees for Estrus Prediction in Bovine Cattle

✉ Neylis Chávez Millares*, ✉ Yusney Marrero García and ✉ Lilibeth Mercedes González Ruiz

Universidad Agraria de La Habana, San José de Las Lajas, Mayabeque, Cuba. E-mail: yusneym@unah.edu.cu; lilibeth@unah.edu.cu

*Autora para correspondencia: Neylis Chávez Millares, e-mail: neyliscm@gmail.com

RESUMEN: La Inteligencia Artificial permite la transformación de la reproducción bovina ya que brinda herramientas para la detección temprana del estro incluyendo los árboles de decisión. En Cuba, se está introduciendo la Inteligencia Artificial como parte del proceso de transformación digital. En esta investigación, se planteó como objetivo: determinar el algoritmo de aprendizaje automático más adecuado para la predicción del estro en el ganado bovino perteneciente a la Granja Universitaria “El Guayabal”. Para el análisis de selección se identificaron tres herramientas de aprendizaje automático: Random Forest, XGBoost y CART donde se tuvo en cuenta las particularidades de cada algoritmo. El análisis reveló que CART es la opción más adecuada para el escenario de investigación, destacando por su bajo consumo de recursos, flexibilidad y precisión en el procesamiento de conjuntos de datos de tamaño pequeño a moderado. **Palabras clave:** aprendizaje automático, inteligencia artificial, regresión, CART, estro.

ABSTRACT: Artificial Intelligence enables the transformation of bovine reproduction by providing tools for early estrus detection, including decision trees. In Cuba, Artificial Intelligence is being introduced as part of the digital transformation process. In this research, the objective was to determine the most appropriate machine learning algorithm for predicting estrus in cattle belonging to the “El Guayabal” University Farm. Three machine learning tools were identified for the selection analysis: Random Forest, XGBoost, and CART, taking into account the particularities of each algorithm. The analysis revealed that CART is the most suitable option for the research scenario, standing out for its low resource consumption, flexibility, and accuracy in processing small to moderate-sized data sets. **Keywords:** Machine Learning, Artificial Intelligence, Regression, CART, Estrus.

INTRODUCCIÓN

La Inteligencia Artificial (IA) ha transformado diversos sectores, incluida la ganadería (Parrado-Alvarez et al., 2019). Este ámbito depende en gran medida de la eficiencia reproductiva y de la sostenibilidad de sus sistemas productivos y reproductivos. En las últimas dos décadas, el desarrollo de algoritmos avanzados, sensores de precisión y plataformas de análisis de datos ha permitido enfrentar desafíos históricos en el manejo reproductivo del ganado, integrando soluciones basadas en IA (Hinestroza, 2018; Souza y de Oliveira, 2022). Entre los procesos más relevantes destacan la detección temprana del estro, la mejora genética, el monitoreo de la gestación, entre otros.

En Cuba se promueve el proceso de transformación digital, dentro del cual se contempla la incorporación de la IA en los sectores priorizados del país (Caballero et al., 2024). Un ejemplo de ello es la ganadería, donde se presta especial atención a la reproducción con el propósito de

incrementar la actividad ganadera. La Granja Universitaria “El Guayabal”, perteneciente a la Universidad Agraria de La Habana (UNAH), constituye un espacio clave para el desarrollo de diversas investigaciones, algunas de las cuales incorporan tecnologías de IA como parte del proceso de transformación digital. Una de las actividades más importantes de la granja es la inseminación artificial en bovinos, por ello, la detección del estro representa un papel importante en la eficiencia reproductiva (Bekara y Bareille, 2019). Actualmente, la identificación del estro en la granja constituye un desafío debido al déficit de personal. Debido a esto, se buscan alternativas para facilitar el trabajo de los especialistas.

Por tanto, se plantea como objetivo de la presente investigación: determinar el algoritmo de aprendizaje automático más adecuado para la predicción del estro en el ganado bovino perteneciente a la Granja Universitaria “El Guayabal”.

Recibido: 03/09/2025

Aceptado: 31/01/2026

Conflicto de intereses: Los autores de este trabajo declaran no presentar conflicto de intereses.

Contribución de los autores: **Conceptualización:** Neylis Chávez, Yusney Marrero. **Curación de datos, Análisis formal, Metodología, Escritura, borrador original:** Neylis Chávez. **Investigación, Supervisión, Escritura, revisión y edición:** Neylis Chávez, Yusney Marrero, Lilibeth González.

La mención de marcas comerciales de equipos, instrumentos o materiales específicos obedece a propósitos de identificación, no existiendo ningún compromiso promocional con relación a los mismos, ni por los autores ni por el editor.



Este artículo se encuentra bajo los términos de la licencia Creative Commons Attribution-NonCommercial (CC BY-NC 4.0).
<https://creativecommons.org/licenses/by-nc/4.0/>



DESARROLLO DEL TEMA

Inseminación artificial en bovinos y detección del estro

La inseminación artificial surgió con el propósito de mejorar la reproducción animal, controlar enfermedades y preservar la diversidad genética (Hafez y Hafez, 2000; Foote, 2002; Thibier, 2005). Desde sus inicios, ha evolucionado hasta convertirse en una herramienta clave para incrementar la producción de leche y carne en el ganado bovino, respondiendo a la creciente demanda mundial de alimentos (Hoyos et al., 2023). En la actualidad, se plantea la necesidad de introducir nuevas tecnologías que optimicen este proceso y lo hagan más eficiente.

El desarrollo reproductivo de la hembra bovina pasa por etapas importantes como añoja, novilla y vaca, donde se manifiestan cambios esenciales para alcanzar la madurez sexual. El primer estro suele aparecer en la etapa de añoja, aunque puede variar entre los 9 y 15 meses de edad (Montes de Oca, 2016). El ciclo estral, que dura en promedio 21 días, se divide en dos fases: lútea y folicular, cada una con dos etapas específicas. La ovulación ocurre durante el estro, considerado el inicio del ciclo, y tiene una duración aproximada de 12 a 18 horas, lo que dificulta su detección por su brevedad (Carvajal et al., 2020).

Durante el estro, las vacas presentan comportamientos característicos como receptividad a la monta, inquietud, disminución en la producción de leche, lamido de genitales, bajo consumo de alimentos y cambios físicos como edematización de la vulva o secreción de mucus (Strappini et al., 2015; Ávila, 2024; Hernández y Ortega, [2009]). Sin embargo, factores como la falta de experiencia del recelador, el ambiente o el estrés pueden dificultar su identificación. Una detección correcta del estro trae beneficios importantes: mayor tasa de natalidad, aumento en la producción de leche y reducción de costos en la inseminación artificial (Strappini et al., 2015).

Métodos y errores en la detección del estro

Los métodos para detectar el estro en bovinos se clasifican en visuales, no visuales, electrónicos y químicos (Ortiz y Avila, 2020). Entre los visuales destacan la observación directa, etiquetas detectoras de monta, ampollas adheridas a la grupa, crayón marcador y toros receladores. Los no visuales incluyen cambios fisiológicos como la temperatura y la actividad hormonal, mientras que los electrónicos emplean podómetros, microchips y cámaras de vigilancia, muchas veces complementados con softwares que registran y notifican las actividades. Los métodos químicos abarcan la androgenización y los implantes hormonales. La observación sigue siendo el método más viable por su bajo costo y efectividad, siempre que el recelador esté capacitado y realice inspecciones frecuentes (Hernández y Ortega, 2009).

A pesar de la implementación de estos avances tecnológicos, aún se presentan fallas en la detección del estro. Entre los principales factores que generan errores se encuentran el anestro, provocado por mala

nutrición, estrés, enfermedades reproductivas, genética o quistes ováricos; la falta de experiencia del recelador; el estro mudo, en el que algunas hembras no muestran síntomas visibles; y la ausencia de seguimiento del ciclo estral y del proceso posterior a la inseminación tomando los criterios aportados por Hernández y Ortega (2009) y Jiménez (2010). Para reducir estos problemas se han incorporado tecnologías avanzadas capaces de identificar comportamientos animales, e incluso se explora la aplicación de la IA en la reproducción bovina (Strappini et al., 2015), aunque su implementación aún enfrenta desafíos.

Desafíos, aplicaciones e impacto de la Inteligencia Artificial en la reproducción bovina

La reproducción bovina continúa siendo un campo en desarrollo para la incorporación de nuevas tecnologías por lo que la IA enfrenta desafíos en este sector incluyendo la resistencia al cambio por parte de los ganaderos (Álvarez (2024), los altos costos de implementación (Patel y Prajapati, 2018), la necesidad de capacitación del personal y los requerimientos de grandes volúmenes de datos junto con equipos de almacenamiento y procesamiento avanzados. A pesar de estas limitaciones, la IA ofrece beneficios significativos al aplicarse en procesos como la mejora genética, la predicción y prevención de enfermedades, el monitoreo y análisis de patrones para la detección del estro, la integración con dispositivos electrónicos para el seguimiento en tiempo real y la optimización de la inseminación artificial (Chávez et al., 2024), contribuyendo a una mayor precisión, eficiencia en la reproducción ganadera y la toma de decisiones.

La IA aplicada a la reproducción bovina ofrece múltiples beneficios al sector ganadero. Permite identificar con mayor precisión el momento adecuado para la inseminación, optimizar la selección de embriones de alta calidad y realizar un monitoreo constante de la salud del ganado para detectar problemas tempranos (González et al., 2018; Perdígón y González, 2021). Además, la automatización de procesos reduce errores humanos y mejora la eficiencia operativa, mientras que los análisis predictivos y la selección genética asistida incrementan la productividad y sostenibilidad del rebaño. En conjunto, estas aplicaciones fortalecen la toma de decisiones estratégicas, elevan el bienestar animal y contribuyen a un manejo más rentable y eficiente de la producción bovina (Horrach et al., 2020).

Actualmente, la reproducción bovina se concentra en la producción de leche por lo que resulta imprescindible fomentar técnicas de IA en esta área con el propósito de aumentar los niveles de producción (Perdígón y González, 2021). Su incorporación en la transformación digital y la reproducción bovina busca responder a las necesidades de progreso y desarrollo, planteando estrategias que permitan aprovechar las ventajas de estas tecnologías para mejorar la producción y la eficiencia en la ganadería (Bekara y Bareille, 2019).

Dentro de las técnicas de IA aplicables a la reproducción ganadera destacan el aprendizaje automático, que permite procesar y analizar datos mediante diferentes tipos de algoritmos (Hinestroza, 2018); las redes bayesianas, útiles para la toma de decisiones bajo incertidumbre (Rodríguez y Dolado, 2007); las máquinas de soporte vectorial, que optimizan la clasificación de datos (Resendiz, 2006); y los árboles de decisión, empleados en tareas de clasificación y regresión (Martí *et al.*, 2022). Según Souza y de Oliveira (2022), estas técnicas se pueden aplicar a la detección precisa del estro, el monitoreo de la salud animal, la selección genética de embriones, la optimización de la inseminación artificial, el análisis de grandes volúmenes de datos genéticos y la mejora de la eficiencia reproductiva.

Los árboles de decisión representan una solución sencilla y a su vez ofrecen resultados sólidos. Entre sus ventajas se encuentran la facilidad de interpretación de los resultados, la rápida traducción en principios aplicables a la producción, la capacidad de clasificar datos tanto categóricos como numéricos y la ausencia de suposiciones previas sobre la forma de los datos o el comportamiento del modelo (Taha y Mohsin, 2021). Además, no requieren de muchos recursos, convirtiéndose en una opción rápida y eficiente para conjuntos de datos de tamaño moderado (Bouza y Santiago, 2012).

Árboles de decisión para regresión

Los árboles de decisión para regresión son herramientas no paramétricas que permiten predecir información mediante la división de los datos en segmentos más pequeños basados en características específicas. Se componen de nodos de decisión y nodos hojas que representan categorías o valores, lo que facilita la clasificación y regresión (Ghiasi *et al.*, 2020; Taha y Mohsin, 2021). Estas herramientas destacan por su precisión en el análisis de datos y optimización de procesos (Barrientos *et al.*, 2009; Martí *et al.*, 2022). También, pueden combinarse con otros modelos para mejorar su exactitud (Kotsiantis, 2013) y se construyen agrupando datos homogéneos que permiten modelar relaciones entre variables dependientes e independientes (Kocarik y Deveci, 2020). Sin embargo, presentan desventajas como la tendencia al sobreajuste cuando el árbol es demasiado profundo y el aumento de la complejidad de cálculo a medida que crece el tamaño de la muestra de entrenamiento (Taha y Mohsin, 2021).

Además de los árboles de decisión, existen otros modelos de regresión como la regresión de soporte vectorial, las redes neuronales artificiales y la regresión logística. Cada uno tiene diferentes requerimientos de recursos y niveles de precisión (Perdigón y González, 2021; Shafiee *et al.*, 2021; Olascoaga-Del Angel *et al.*, 2022). En cuanto a algoritmos específicos de árboles de decisión, destacan CART, Random Forest y XGBoost. CART es valorado por

su simplicidad y capacidad de manejar datos moderados con alta precisión, mientras que Random Forest y XGBoost resultan menos eficientes en conjuntos de datos de tamaño moderado, aunque ofrecen mayor robustez en escenarios más complejos (Ejea, 2017). Tomando en cuenta el análisis realizado, se selecciona el método CART ya que, por sus características, se ajusta adecuadamente al escenario descrito anteriormente.

Método CART

El método de aprendizaje automático CART pertenece al grupo de aprendizaje supervisado y se utiliza tanto para clasificación como para regresión de datos. Se caracteriza por su flexibilidad, ya que puede aprender a partir de conjuntos de entrenamiento y reutilizar parámetros en distintas secciones del modelo, lo que le permite identificar interdependencias complejas entre variables (Ghiasi *et al.*, 2020). Su construcción se basa en criterios de división que buscan minimizar el error de predicción y generar nodos homogéneos, facilitando así el análisis de los datos.

Entre sus principales ventajas se destacan la facilidad de interpretación de los resultados, la capacidad de manejar variables categóricas sin necesidad de codificación y la posibilidad de identificar relaciones no lineales y modelar patrones complejos (Pérez, 2024). Además, CART no requiere grandes volúmenes de datos para su entrenamiento, lo que lo convierte en una herramienta eficiente y de bajo costo en términos de recursos tecnológicos. Para desarrollar un modelo basado en CART se deben realizar tres procesos fundamentales: entrenamiento, evaluación y ajuste del modelo.

El proceso de entrenamiento de un modelo de árboles de decisión comienza con la recopilación y preparación de datos bien estructurados, que luego se dividen en dos subconjuntos: entrenamiento y prueba (García, 2023). El conjunto de entrenamiento, que debe contener la mayor parte de los registros, se utiliza para que el modelo aprenda a identificar relaciones entre variables, aplicar criterios de división y detectar patrones que permitan generar predicciones precisas. Por su parte, el conjunto de prueba, aunque más pequeño, debe ser representativo del total de datos, ya que su función es evaluar la capacidad del modelo para generalizar y comprobar la fiabilidad de sus resultados. La división puede hacerse de manera aleatoria o intencionada, pero siempre debe garantizar un equilibrio entre las diferentes clases del modelo (Trujillano *et al.*, 2008). Una práctica común es asignar aproximadamente el 80 % de los datos al entrenamiento y el 20 % al conjunto de prueba, lo que asegura que el modelo disponga de suficientes registros para aprender sin perder la capacidad de validación. Este proceso es esencial para evitar sesgos, reducir errores y garantizar que el modelo pueda aplicarse con éxito en nuevos escenarios, convirtiéndose en una herramienta confiable para la predicción y el análisis de datos.

Durante el proceso de evaluación de un modelo es esencial monitorear los errores en su desempeño y capacidad de aprendizaje. Un error de entrenamiento elevado indica dificultades para aprender, lo que puede deberse a datos insuficientes o ruidosos y refleja un alto sesgo. En contraste, un error bajo sugiere que el modelo ha captado correctamente las relaciones entre los datos, aunque es necesario analizar el conjunto de prueba para detectar posibles casos de sobreajuste (Benitez et al., 2018). Este fenómeno ocurre cuando el modelo no solo aprende los patrones, sino también el ruido de los datos de entrenamiento, generando alta varianza y un rendimiento deficiente en datos nuevos. Para evitarlo, se emplean técnicas como la validación cruzada y la regularización, que ayudan a construir modelos más robustos y capaces de generalizar adecuadamente (Hernández, 2022).

La evaluación del rendimiento de un modelo de regresión requiere un análisis exhaustivo tanto en el conjunto de entrenamiento como en el de prueba, comparando métricas de desempeño para medir su capacidad de generalización (Pérez, 2024). Métodos como la validación cruzada permiten dividir los datos en múltiples pliegues y obtener resultados más precisos y fiables. Además, se pueden establecer criterios de aceptación basados en umbrales de error para determinar la precisión del modelo y diferenciar predicciones correctas de incorrectas (Vivaracho-Pascual et al., 2016). Esta etapa de evaluación facilita el ajuste de hiperparámetros, lo que contribuye a mejorar la calidad de las predicciones y optimizar el rendimiento del modelo.

Los árboles de decisión pueden verse afectados por problemas como el sobreajuste, especialmente cuando existen clases desequilibradas en los datos (Ghiasi et al., 2020). Para evitarlo se puede ajustar el modelo empleando estrategias como el ajuste de hiperparámetros, el proceso de podado y la validación cruzada. Los hiperparámetros más comunes incluyen la profundidad del árbol, el criterio de clasificación y el número mínimo de muestras en un nodo, los cuales pueden modificarse durante el desarrollo del modelo para mejorar su desempeño y capacidad de generalización (Hernández, 2022).

Pérez (2024) considera el proceso de podado como una técnica clave para reducir la complejidad del árbol y evitar que el modelo capture ruido innecesario. Entre sus variantes se encuentran la poda por complejidad de costo, que busca equilibrar simplicidad y precisión (Ejea, 2017); la poda por altura, que limita la profundidad máxima del árbol (McTavish et al., 2022); la poda por número mínimo de muestras en hojas, que asegura predicciones más confiables (Zhong et al., 2008); y la poda por número mínimo de muestras para dividir un nodo, que evita divisiones basadas en datos insuficientes (Tong et al., 2022). Todas estas técnicas contribuyen a crear modelos más robustos, interpretables y eficientes.

Por su parte, la validación cruzada es un método esencial para evaluar el rendimiento de los árboles de decisión. Consiste en dividir los datos en múltiples subconjuntos o pliegues, entrenando y probando el modelo en cada uno de ellos. Esto permite obtener una estimación más precisa y confiable de su capacidad de generalización, asegurando que el modelo final sea robusto y mantenga

un buen desempeño en diferentes escenarios de aplicación (Ochoa, 2019).

CONCLUSIONES

El análisis de las técnicas CART, Random Forest y XGBoost permitió identificar que CART constituye la alternativa más adecuada para la predicción del esto considerando las condiciones de la Granja Universitaria "El Guayabal". Este algoritmo ofrece interpretabilidad, facilidad de implementación y bajos requerimientos computacionales. Por otro lado, Random Forest se presenta como una opción alternativa con mejor desempeño, aunque con mayor complejidad. Sin embargo, XGBoost, pese a su alta precisión, demanda recursos y conocimientos técnicos que exceden las posibilidades actuales de la institución.

REFERENCIAS BIBLIOGRÁFICAS

- ÁLVAREZ, S.: "Luces, sombras y riesgos de la inteligencia artificial", *PAPELES de relaciones ecosociales y cambio global*, 164: 5-12, 2024.
- ÁVILA, I.M.: *Incidencia de factores intrínsecos y extrínsecos en la efectividad reproductiva mediante la inseminación artificial en las parroquias de salcedo en el período 2023.*, Universidad Técnica de Cotopaxi]. Ecuador., Tesis de Grado, Cotopaxi, Ecuador, 2024.
- BARRIENTOS, R. E.; CRUZ, N.; ACOSTA, H. G.; IVONNE, R.; GOGASCOECHEA, M.; PAVÓN, P.; BELÁZQUEZ, S. L.: "Árboles de decisión como herramienta en el diagnóstico médico". *Revista Médica de la Universidad Veracruzana*, 9(2), 2009. Disponible en: https://www.soporte.uv.mx/rm/numanteriores/revmedica_vol9_num2/articulos/arboles.pdf
- BEKARA, M.E.A.; BAREILLE, N.: "Quantification by simulation of the effect of herd management practices and cow fertility on the reproductive and economic performance of Holstein dairy herds", *Journal of dairy science*, 102(10): 9435-9457, 2019, ISSN: 0022-0302.. DOI: <https://doi.org/10.3168/jds.2018-15484>
- BENITEZ, R.; CENCERRADO, A.; ESCUDERO, G.; KANAAN, S.: *Inteligencia Artificial Avanzada* (Vol. 1). Universitat Oberta de Catalunya, 2018. Disponible en: https://openaccess.uoc.edu/bitstream/10609/140427/8/Inteligencia%20artificial%20avanzada_M%C3%B3dulo%201_Inteligencia%20artificial%20avanzada.pdf
- BOUZA, C. N.; SANTIAGO, A.: "La minería de datos: Árboles de Decisión y su aplicación en estudios médicos". *Modelación Matemática de Fenómenos del Medio Ambiente y la Salud*, 2, 64-78, 2012. Disponible en: https://rideca.cs.buap.mx/web/files/articulo_itBUo0uWLAaJENf.pdf.
- CABALLERO, Y.; BELLO, R.; ROSETE, A.: "La inteligencia artificial dentro de la transformación digital para el desarrollo", *Anales de la Academia de Ciencias de Cuba*, 14(1), 2024, ISSN: 2304-0106., Disponible en: <http://www.revistaccuba.cu/index.php/revacc/article/view/1530>.

- CARVAJAL, A. M.; MARTÍNEZ, M. E.; TAPIA, M.: "Ciclo estral en la hembra bovina y su importancia reproductiva". *INIA*, 246, 2020.
- CHÁVEZ, N.; GONZÁLEZ, R.; MARRERO, Y.; GONZÁLEZ, L. M.: "La Inteligencia Artificial en la Reproducción Bovina", *Ciencias Universitarias*, 22. 2024. Disponible en: <https://revistas.unah.edu.cu/index.php/cu>
- EJEA, D. G.: *Árboles de Regresión. Algunos algoritmos y extensiones a métodos de consenso*. [Tesis de Grado, Universidad de Zaragoza]. 2017. Disponible en: <https://zaguan.unizar.es/record/63779/files/TAZ-TFG-2017-4733.pdf>
- FOOTE, R. H.: "The history of artificial insemination: Selected notes and notables". *Journal of Animal Science*, 80 (2), 1-10, 2002. Disponible en: https://www.asas.org/docs/default-source/midwest/mw2020/publications/footehist.pdf?sfvrsn=59da6c07_0
- GARCÍA, C.: *Aplicación para predecir afluencia de gente en las calles de Madrid*. [Tesis de Grado, Escuela Técnica Superior de Ingeniería y Sistema de Telecomunicación]. 2023. Disponible en: https://oa.upm.es/77956/1/PFG_GARCIA_CALVO_CRISTINA.pdf
- GHIASI, M. M.; ZENDEHBOUDI, S.; MOHSENIPOUR, A. A.: "Decision tree-based diagnosis of coronary artery disease: CART model". *Computer Methods and Programs in Biomedicine*, 192. 2020. Disponible en: <https://www.sciencedirect.com/science/article/abs/pii/S0169260719308971>
- GONZÁLEZ, N.; LEYVA, M. Y.; FAGGONI, K. M.; ÁLVAREZ, P. J.: "Estudio comparado de las técnicas de Inteligencia Artificial para el diagnóstico de enfermedades en la ganadería". *Sistemas, Cibernética e Informática*, 15(2), 2018.
- HAFEZ, E. S. E.; HAFEZ, B.: *Reproduction in Farm Animals* (7th ed.). 2000. Disponible en: https://cuvas.edu.pk/cuvas_libraries/ebooks/Reproduction%20In%20Farm%20Animals%20HAFEEZ.pdf
- HERNÁNDEZ, J.; ORTEGA, A.: *Manual de Inseminación Artificial en Bovinos*, Ed. Universidad Nacional Autónoma de México, México D.F., 2009.
- HERNÁNDEZ, L.: *Análisis predictivo de funcionamiento de Sistema Híbrido Off Grid mediante Machine Learning*. [Tesis de Grado, Escuela Técnica Superior de Ingeniería y Sistema de Telecomunicación]. Madrid, España, 2022. Disponible en: https://oa.upm.es/72650/1/TFG_LAURA_HERNANDEZ_CUBO.pdf
- HINESTROZA RAMÍREZ, D.: "El Machine Learning a través de los tiempos, y los aportes a la humanidad", 2018.
- HORRACH, M. N.; BERTOT, J. A.; VÁZQUEZ, R.; GARAY, M.: "Eficiencia reproductiva de sistemas vacunos en inseminación artificial. Tendencias actuales y perspectivas". *Revista de Producción Animal*, 32 (3), 2020. Disponible en: <https://revistas.reduc.edu.cu/index.php/rpa/article/view/e3592>
- HOYOS, J. F.; VELÁSQUEZ, B. L.; RICO, D.; GARCÍA, N.: "Impacto transformador de la inteligencia artificial y aprendizaje autónomo en la producción agropecuaria: un enfoque en la sostenibilidad y eficiencia". *Revista Formación Estratégica*, 7 (1), 2023. Disponible en <https://formacionestrategica.com/index.php/foes/article/view/111/80>. ISSN: 2805-9832.
- JIMÉNEZ, D.: *Técnicas de Inseminación Artificial aplicadas en bovinos*. [Tesis de Grado, Universidad Autónoma Agraria "Antonio Narro"]. México, 2010.
- KOCARIK, B.; DEVECI, İ.: "Regresyon Analizleri mi Karar Ağaçları mı?" *Manisa Celal Bayar Üniversitesi Sosyal Bilimler Dergisi*, 18 (4), 251-260, 2020. ISSN: 1304-4796.
- KOTSIANTIS, S. B.: "Decision trees: a recent overview". *Artificial Intelligence Review*, 39(4), 261-283, 2013. Disponible en: <https://link.springer.com/article/10.1007/s10462-011-9272-4#citeas>.
- MARTÍ, A.; MILBERBERG, A.; MARESA, D.; PRIETO, A. S.; LLANES-SANTIAGO, O.: "Propuesta de metodología para el diagnóstico de fallos basado en árboles de decisión y lógica difusa". *Revista de Ingeniería Electrónica, Automática y Comunicaciones*, 43(2), 2022.
- MCTAVISH, H.; ZHONG, C.; ACHERMANN, R.; KARIMALIS, I.; CHEN, J.; RUDIN, C.; SELTZER, M.: *Fast Sparse Decision Tree Optimization via Reference Ensembles* The Thirty-Sixth AAAI Conference on Artificial Intelligence (AAAI-22), 2022. Disponible en: <https://cdn.aaai.org/ojs/21194/21194-13-25207-1-2-20220628.pdf>.
- MONTES DE OCA, E. A.: *Desarrollo histórico y tendencial de la ganadería vacuna en la Isla de la Juventud: periodo 1573-actualidad*. [Tesis de Maestría, Universidad de La Habana]. 2016. Disponible en: [https://accesoabierto.uh.cu/files/original/2134433/Elvira_Aleida_Montes_de_Oca_Garcia_\[2017\].pdf](https://accesoabierto.uh.cu/files/original/2134433/Elvira_Aleida_Montes_de_Oca_Garcia_[2017].pdf)
- OCHOA, L. L.: *Evaluación de Algoritmos de Clasificación utilizando Validación Cruzada* The 17th LACCEI International Multi-Conference for Engineering, Education, and Technology: "Industry, Innovation, and Infrastructure for Sustainable Cities and Communities", Montego Bay, Jamaica, 2019.
- OLASCOAGA-DEL ANGEL, K. S.; KONIGSBERG-FAINSTEIN, M.; PÉREZ-VILLANUEVA, J.; LÓPEZ, N. E.: "Uso de la inteligencia artificial en la investigación para el reposicionamiento de fármacos". *TIP Revista Especializada en Ciencias Químico-Biológicas*, 25, 1-17. 2022. DOI: <https://doi.org/10.22201/fesz.23958723e.2022.450>
- ORTIZ, S. D.; AVILA, K. Y.: *Fundamentos y métodos actuales de detección de celo en bovinos*. [Tesis de Grado, Universidad Cooperativa de Colombia]. Colombia, 2020.

- PARRADO-ALVAREZ, O.L.; CARRIÓN-CABRERA, L.; CUESTA-LÓPEZ, R.: "El pensamiento y obra de Fidel Castro Ruz sobre la formación de profesionales para la agricultura: Array", *Maestro y Sociedad*, 172-183, 2019, ISSN: 1815-4867.
- PATEL, H. H.; PRAJAPATI, P.: "Study and Analysis of Decision Tree Based Classification Algorithms". *International Journal of Computer Sciences and Engineering*, 6(10), 2018.
- PERDIGÓN, R.; GONZÁLEZ, N.: "Comparación y selección de técnicas de inteligencia artificial para pronosticar las producciones de leche bovina". *Revista Cubana de Ciencias Informáticas*, 15(2), 24-43, 2021.
- PÉREZ, A.: *Detección de Patrones de Fallas de Automóviles Basada en Técnicas de Aprendizaje automático y Bases de Conocimiento*. [Tesis de Maestría, Benemérita Universidad Autónoma de Puebla]. México, 2024. Disponible en: <https://repositorioinstitucional.buap.mx/server/api/core/bitstreams/8c9719a0-939c-4e74-8c45-2b089e0b88d5/content>
- RESENDIZ, J. A.: *Las maquinas de vectores de soporte para identificación en línea*. [Máster en Control Automático, Centro de Investigaciones del Instituto Politécnico Nacional de México], México, 2006.
- RODRÍGUEZ, D.; DOLADO, J.: *Redes Bayesianas en la Ingeniería del Software*. 1-21, 2007.
- SHAFIEE, S.; LIED, L. M.; BURUD, I.; DIESETH, J. A.; MUATH, A.: "Sequential forward selection an dsupport vector regression in comparison to LASSO regression for spring wheat yield prediction based on UAV imagery". *Computers and Electronics in Agriculture*, 183, 2021. DOI: <https://doi.org/10.1016/j.compag.2021.106036>. ISSN: 0168-1699.
- SOUZA, V.; DE OLIVEIRA, G.: "Application of Artificial Intelligence in Cattle Farming: A Scope Review". *Revista electrónica de Veterinaria (REDVET)*, 23 (2), 2022. Disponible en <https://veterinaria.org/index.php/REDVET/article/download/160/37/> . ISSN: 1695-7504.
- STRAPPINI, A.C.; NORAMBUENA, L.; MATAMALA, F.: *Importancia de la detección de celo utilizando métodos amigables con el bienestar animal*, Inst. XXXVIII Reunión Científica Anual de la Asociación Peruana de Producción Animal, Perú, 2015.
- TAHA, B.; Y MOHSIN, A.: "Classification Based on Decision Tree Algorithm for Machine Learning". *Journal of Applied and Technology Trends*, 02(01), 20-28, 2021. Disponible en: <https://www.jastt.org/index.php/jasttpath/article/view/65>
- THIBIER, M.: "The zootechnical applications of biotechnology in animal reproduction: current methods and perspectives". *Reproduction Nutrition Development*, 45, 235-242, 2005. DOI: <https://doi.org/10.1051/rnd:2005016>
- TONG, L.; LIU, Z.; JIANG, Z.; ZHOU, F.; CHEN, L.; LYU, J.; ZHANG, X.; WANG, Y.; LI, L.; ZHOU, H.: "Cost-sensitive boosting pruning trees for depression detection on Twitter". *IEEE Transactions on Affective Computing*, 2022.
- TRUJILLANO, J.; SARRIA-SANTAMERA, A.; ESQUERDA, A.; BADIA, M.; PALMA, M.; MARCH, J.: "Aproximación a la metodología basada en árboles de decisión (CART). Mortalidad hospitalaria del infarto agudo de miocardio". *Gac Sanit*, 22(1), 65-72, 2008.
- VIVARACHO-PASCUAL, C.; SIMON-HURTADO, A.; MANSO-MARTINEZ, E.; PASCUAL-GASPAR, J. M.: "Client Threshold Prediction in Biometric Signature Recognition by Means of Multiple Linear Regression and Its Use for Score Normalization". *The Journal of the Pattern Recognition Society*, 55, 1-13, 2016. DOI: <https://doi.org/10.1016/j.patcog.2016.02.007>
- ZHONG, M.; GEORGIPOULOS, M.: "Anagnostopoulos, G. C.: A k-norm pruning algorithm for decision tree classifiers based on error rate estimation" *Machine learning*, 71, 55-88, 2008.