



Revista Cubana de Ciencias Informáticas

ISSN: 1994-1536

ISSN: 2227-1899

Editorial Ediciones Futuro

Perdigón Llanes, Rudibel; González Benítez, Neilys
Comparación y selección de técnicas de inteligencia
artificial para pronosticar las producciones de leche bovina
Revista Cubana de Ciencias Informáticas, vol. 15, núm. 2, 2021, pp. 24-43
Editorial Ediciones Futuro

Disponible en: <https://www.redalyc.org/articulo.oa?id=378367420002>

- ▶ Cómo citar el artículo
- ▶ Número completo
- ▶ Más información del artículo
- ▶ Página de la revista en redalyc.org



Sistema de Información Científica Redalyc

Red de Revistas Científicas de América Latina y el Caribe, España y Portugal
Proyecto académico sin fines de lucro, desarrollado bajo la iniciativa de acceso
abierto

Tipo de artículo: Artículo original

Temática: Inteligencia Artificial

Recibido: 22/01/2021 | Aceptado: 15/03/2021

Comparación y selección de técnicas de inteligencia artificial para pronosticar las producciones de leche bovina

Comparison and selection of artificial intelligence techniques for forecasting bovine milk productions

Rudibel Perdigón Llanes ^{1*} <https://orcid.org/0000-0001-7288-6224>

Neilys González Benítez ² <http://orcid.org/0000-0001-8691-445X>

¹ Empresa Comercializadora “Frutas Selectas”, Km 1 ½ Carretera a San Juan y Martínez, Pinar del Río, Cuba, CP 20100. E-mail: rperdigon90@gmail.com

² Centro Meteorológico Provincial CITMA, Colón # 106 entre Antonio Maceo y Virtudes, Pinar del Río, Cuba, CP 20100. E-mail: neilysgonzalezbenitez@gmail.com

* Autor para correspondencia. (rperdigon90@gmail.com)

RESUMEN

Los pronósticos constituyen una herramienta efectiva para la toma de decisiones, principalmente en el sector de la industria láctea porque contribuyen a mejorar la gestión del rebaño lechero, ahorrar energía en las granjas y optimizar las inversiones de capital a largo plazo. La aplicación de técnicas de inteligencia artificial para pronosticar las producciones de leche es un tema de interés para la comunidad científica. Sin embargo, definir una técnica o modelo para pronosticar estas producciones con un rendimiento eficiente en diferentes ambientes es una actividad desafiante y compleja, porque ninguno es preciso en todos los escenarios. En esta investigación se compararon las técnicas de inteligencia artificial utilizadas en la literatura para pronosticar las producciones de leche bovina y se seleccionó mediante la aplicación del Proceso de Análisis Jerárquico la técnica con mejor ajuste a estos pronósticos. Se utilizaron como métodos científicos el analítico sintético, la encuesta y el método experimental. Los resultados obtenidos permitieron identificar a las técnicas de inteligencia artificial basadas en Redes Neuronales Artificiales como las de mejor ajuste al pronóstico de las producciones de leche bovina, superior a los Árboles de Decisión y a las Máquinas de Soporte Vectorial. Se determinó que los criterios de selección más relevantes en el ámbito de las producciones lecheras son la capacidad de estas técnicas para manejar datos que presentan incertidumbre y su habilidad para obtener resultados precisos de manera óptima. El análisis realizado apoya la toma de decisiones en organizaciones productoras de leche.

Palabras clave: análisis multi-criterio; proceso de análisis jerárquico; pronósticos; toma de decisiones.

ABSTRACT

Forecasting is an effective decision-making tool, especially in the dairy industry, because it helps to improve dairy herd management, save farm energy and optimize long-term capital investments. The application of artificial intelligence techniques to forecasting milk productions is a topic of interest for the scientific community. However, defining a technique or model to forecast these

productions with an absolute performance at a global level is a challenging and complex activity, because none is accurate in all scenarios. In this research, artificial intelligence techniques used in the literature to forecast bovine milk productions were compared and the technique with the best adjustment to these forecasts was selected through the application of the Analytic Hierarchy Process. The synthetic analysis, the survey and experimental method were used as scientific methods. The results obtained allowed identifying artificial intelligence techniques based on Artificial Neural Networks as the best fit for forecasting bovine milk production, superior to Decision Trees and Support Vector Machines. It was determined that the most relevant selection criteria in the dairy production sector are the capacity of these techniques to handle data that present uncertainty and their ability to obtain precise results in an optimal way. The analysis carried out supports decision making in milk producing organizations.

Keywords: multi-criteria analysis; analytic hierarchy process; forecasting; decision making.

Introducción

La toma de decisiones es un proceso de análisis en el que se selecciona una alternativa óptima entre varias para lograr un objetivo específico (Wen, Liao & Zavadskas, 2020). Esta actividad posee una amplia aplicación en las organizaciones porque frecuentemente los directivos requieren tomar decisiones en relación a diferentes asuntos (Mahmoudi et al., 2020; Wen, Liao & Zavadskas, 2020). La toma de decisiones en organizaciones productoras de leche es un factor esencial para aumentar sus índices productivos y económicos (Gunnar, 2015). Sin embargo, este proceso en ocasiones se realiza en circunstancias de escasez de información, situación que requiere elevar su eficiencia y exactitud (Gunnar, 2015).

Los pronósticos constituyen una herramienta útil para la toma de decisiones en la industria láctea (Yan et al., 2015; Zhang et al., 2020). La predicción acertada de las producciones de leche bovina

facilita a los productores de este alimento mejorar su planificación financiera y evitar pérdidas económicas (Jensen, van der Voort & Hogeveen, 2018; da Rosa et al., 2020; Nguyen et al., 2020). Además, posibilita mejorar la gestión del rebaño lechero, ahorrar energía en las granjas y optimizar las inversiones de capital a largo plazo (Yan et al., 2015; Zhang et al., 2020).

En la actualidad, se emplean diferentes modelos para pronosticar las producciones de leche bovina (Perdigón y González, 2020). Estos modelos se apoyan en la aplicación de algoritmos matemáticos, estocásticos de series de tiempo, regresivos y computacionales basados en técnicas de inteligencia artificial (AI, por sus siglas en inglés) para realizar los pronósticos (Torres-Inga et al., 2019; Perdigón y González, 2020). El uso de técnicas de inteligencia artificial en las actividades agrícolas y ganaderas es un fenómeno creciente que contribuye a mejorar el procesamiento de datos y la rentabilidad de las operaciones que se realizan en este sector (Kaygisiz & Sezgin, 2017; González et al., 2018; Torres-Inga et al., 2019). Entre las técnicas de inteligencia artificial más utilizadas en la literatura consultada para pronosticar las producciones de leche bovina se identificaron:

1. Técnicas basadas en Redes Neuronales Artificiales (ANN, por sus siglas en inglés) (Sugiono, Soenoko & Riawati, 2017; Gorgulu, 2018; Machado et al., 2019; Torres-Inga et al., 2019; Liseunea et al., 2020; Zhang et al., 2016; 2019; 2020; Zhang W. et al., 2020)
2. Técnicas basadas en Máquinas de Soporte Vectorial (SVM, por sus siglas en inglés) (Yan et al., 2015; Nguyen et al. 2020; Saha & Bhattacharyya, 2020)
3. Técnicas basadas en Algoritmos Genéticos (GA, por sus siglas en inglés) (Yan et al., 2015; Notte et al., 2016; Zhang W. et al., 2020)
4. Técnicas basadas en Árboles de Decisión (DT, por sus siglas en inglés) (Eyduran et al., 2013; Nguyen et al. 2020; Piwczyński et al., 2020; Kliś et al., 2021)

Estas técnicas muestran un comportamiento apropiado para la realización de pronósticos en diferentes ámbitos porque carecen de limitaciones para el manejo de grandes cantidades de datos y variables de entrada y poseen la capacidad de identificar, aprender y aproximar las características de los datos simulando las relaciones intrínsecas y no lineales existentes en estos (Dongre et al.,

2012; Oscullo & Haro, 2016; Kaygisiz & Sezgin, 2017). Además, posibilitan obtener resultados precisos con ahorro de tiempo y recursos de cómputo (Nguyen et al., 2020).

Las técnicas de AI permiten realizar pronósticos eficientes en el sector agrícola basando su análisis en la resolución de problemas específicos en entornos con características y variables determinadas (Slob, Catal & Kassahun, 2021). Sin embargo, la producción de leche bovina es influenciada por diversos factores que dificultan su pronóstico (Yan et al., 2015; Perdigón y González, 2020). Las variaciones del clima, el manejo del ganado, su alimentación, sus rasgos genéticos y fisiológicos y la incidencia de enfermedades son algunos de los elementos que influyen en la producción de leche bovina y complejizan su pronóstico (Perdigón y González, 2020). Definir un modelo o técnica para pronosticar estas producciones con un rendimiento eficiente en diferentes ambientes es una actividad desafiante y compleja, porque ninguno es preciso en todos los escenarios (Zhang et al., 2016; Perdigón et al., 2020; Zhang et al., 2020).

Determinar la técnica de AI con mejor ajuste al pronóstico de las producciones de leche es un tema de interés para la comunidad científica internacional (Dongre et al., 2012; Murphy et al., 2014; Nguyen et al. 2020). Sin embargo, no existe un consenso en la literatura consultada sobre la técnica de AI con mejores rendimientos en este proceso. Además, los autores identificados emplearon como criterio fundamental para evaluar la efectividad de estas técnicas su exactitud para la realización de los pronósticos, elemento que está sujeto a factores del ambiente donde se realiza la predicción (variables predictoras) y que puede ser insuficiente según las características del entorno de decisión (tiempo, datos y recursos disponibles, interpretabilidad y aplicación). La variedad de algoritmos aplicables por cada una de las técnicas de pronóstico basadas en AI identificadas en la literatura complejiza el empleo de análisis estadísticos como metodología para determinar la técnica con mejor ajuste al pronóstico de estas producciones.

La toma de decisiones multicriterio (MCDM, por sus siglas en inglés) ha demostrado resultados satisfactorios en disímiles campos de aplicación, específicamente en situaciones donde se debe decidir entre varias alternativas considerando diversos criterios o puntos de vista para su selección (Márquez-Benavides & Baltierra-Trejo, 2017; González, Estrada y Febles, 2018). El Proceso de Análisis Jerárquico (AHP, por sus siglas en inglés) es uno de los métodos MCDM más utilizado en

la literatura por su relevancia y aplicación práctica (Saaty & Ergu, 2015; Ossadnik, Schinke & Kaspar, 2016; Bocanegra-Villegas et al., 2020), fundamentalmente en investigaciones agropecuarias para la selección de modelos de producción de granjas lecheras (Rozman et al., 2016). Su principal fortaleza radica en el manejo de criterios cuantitativos (información y datos obtenidos) y cualitativos (puntos de vista del decisor y características del entorno de decisión) en el proceso de toma de decisiones (Saaty & Ergu, 2015; Ossadnik, Schinke & Kaspar, 2016; Montalván-Estrada, et al., 2017).

La presente investigación tiene como objetivo comparar las técnicas de inteligencia artificial utilizadas en la literatura para pronosticar las producciones de leche bovina y seleccionar mediante la aplicación del AHP la que mejor se ajusta a este proceso según diferentes criterios de selección. Se seleccionó el método AHP porque presenta un soporte matemático válido para el análisis de problemas de selección; mide criterios cuantitativos y cualitativos mediante una escala común; permite verificar errores en el desarrollo de las evaluaciones a partir de índices de inconsistencias y posibilita complementar los resultados obtenidos con otros métodos matemáticos de optimización (Ocampo, Tamayo y Castaño, 2019). Este estudio se estructura en 3 secciones fundamentales: en la sección materiales y métodos o metodología computacional se exponen los métodos científicos y la metodología utilizada para el desarrollo de la investigación; los principales hallazgos obtenidos durante la aplicación del AHP y su comparación con otras investigaciones relacionadas con la utilización de técnicas de AI en los pronósticos de leche bovina son descritos en la sección resultados y discusión; finalmente, se presentan las conclusiones.

Materiales y métodos o Metodología Computacional

En esta investigación se emplearon como métodos científicos el analítico sintético, la encuesta y el método experimental. El método analítico sintético permitió el análisis y síntesis de la literatura relacionada con los pronósticos y la toma de decisiones en la industria láctea. La encuesta se

empleó para obtener las valoraciones y juicios de los expertos para la aplicación del AHP. El método experimental se utilizó para desarrollar un estudio de caso donde se implementó el AHP con el objetivo de seleccionar la técnica de inteligencia artificial con mejor ajuste al pronóstico de las producciones de leche bovina. Como metodología para implementar el AHP se adoptó el procedimiento propuesto por (Mendoza et al., 2019) en su investigación. La figura 1 describe este procedimiento.

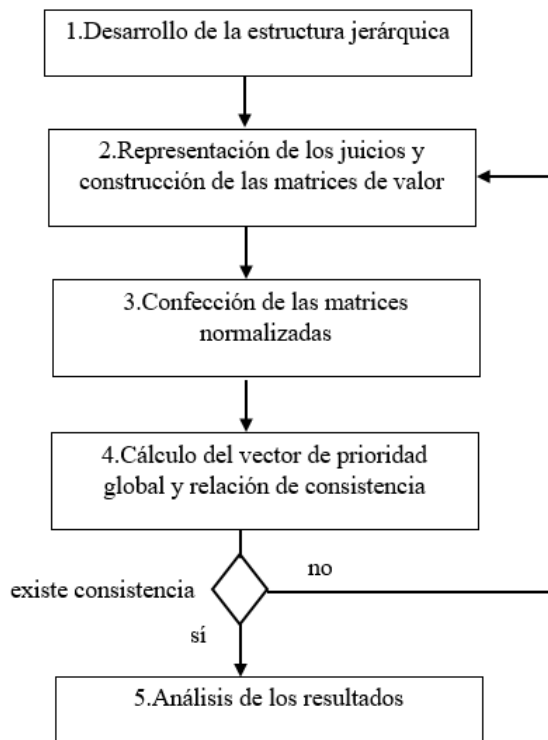


Fig. 1- Metodología adoptada para aplicar el AHP(Mendoza et al., 2019).

Para realizar las comparaciones entre las alternativas según los criterios de selección fueron consultados 15 expertos nacionales con un alto nivel profesional y experiencia en temáticas relacionadas con la inteligencia artificial (100% de los expertos) y la ganadería (80% de los expertos). La selección de los expertos se realizó mediante el análisis curricular, donde se tomaron en consideración aspectos como su título universitario, categoría científica, publicaciones

académicas, dominio sobre el tema en cuestión y experiencia investigativa. La totalidad de los expertos ostentan la categoría científica de Doctor en Ciencias y el 66.67% de estos poseen más de 10 años de experiencia como investigador. Los expertos consultados pertenecen a las instituciones: Empresa Pecuaria Genética “Camilo Cienfuegos” (2 expertos), Universidad de Pinar del Río (2 expertos), Centro Meteorológico Provincial de Pinar del Río (1 experto), Universidad Agraria de La Habana (4 expertos), Instituto de Investigaciones de Ingeniería Agrícola (4 expertos) y Universidad de Camagüey (2 expertos).

La correcta selección de los expertos contribuyó a reducir el error y la incertidumbre durante el proceso de comparación de las alternativas. Para priorizar las alternativas, en correspondencia con los criterios de comparación seleccionados y con el objetivo de elevar la certidumbre en este proceso, se empleó la escala de (Saaty, 1990) descrita en la tabla 1. Esta escala permite establecer la importancia o preferencia de las alternativas en la matriz de comparaciones con cierto grado de certeza y homogeneidad (Mendoza et al., 2019).

Tabla 1 - Escala utilizada para medir los juicios de los expertos (Saaty, 1990).

Escala numérica	Escala verbal	Descripción
1	Igual importancia	Los dos elementos contribuyen igualmente a la propiedad o criterio
3	El elemento es moderadamente más importante respecto al otro	El juicio y la experiencia previa favorecen a un elemento frente al otro
5	El elemento es fuertemente más importante respecto al otro	El juicio y la experiencia previa favorecen fuertemente a un elemento frente al otro
7	La importancia del elemento es muy fuerte respecto al otro	Un elemento domina fuertemente
9	La importancia del elemento es extrema respecto al otro	Un elemento domina al otro con el mayor orden de magnitud posible
2,4,6,8	Valores intermedios entre dos juicios adyacentes	

Resultados y discusión

Desarrollo de la estructura jerárquica

La figura 2 describe la estructura jerárquica del análisis realizado en esta investigación. En la cúspide de la jerarquía se ubica el objetivo de análisis, los criterios de comparación en el nivel intermedio y las alternativas en el nivel inferior.

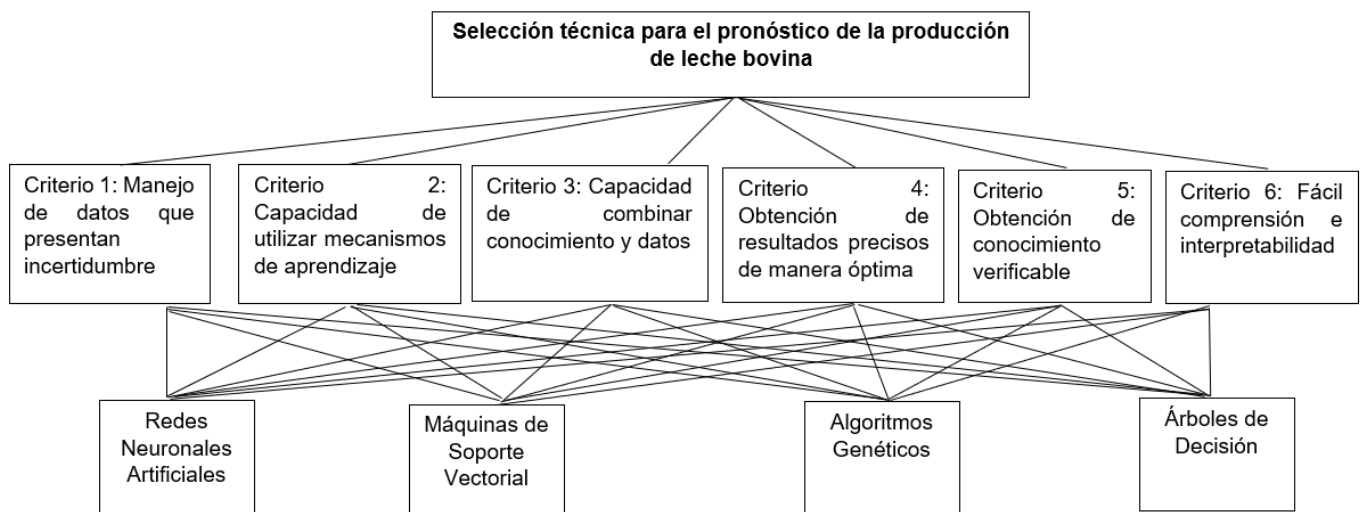


Fig. 2 - Estructura jerárquica del análisis.

Fuente: elaboración propia.

Los criterios fueron seleccionados según la revisión de la literatura relacionada con los pronósticos en el sector ganadero: manejo de datos que presentan incertidumbre (Yan et al., 2015; Liseunea et al., 2020), empleo de mecanismos de aprendizaje (González et al., 2018), combinación de conocimiento y datos (González et al., 2018), obtención de resultados precisos de manera óptima (Murphy et al., 2014; Nguyen et al., 2020; Perdigón y González, 2020), obtención de conocimiento verificable (González et al., 2018), facilidad para su comprensión e interpretabilidad (Slob, Catal & Kassahun, 2021).

Las alternativas a evaluar en el presente estudio están conformadas por las técnicas de inteligencia artificial identificadas en las fuentes bibliográficas consultadas. No se incluyeron como alternativas

algoritmos basados en regresiones porque según (Slob, Catal & Kassahun, 2021) estos han sido utilizados solo como métodos de comparación en investigaciones sobre la gestión de las producciones lecheras durante los últimos años, evidenciando rendimientos inferiores al resto de las técnicas de AI. Las alternativas seleccionadas aglutinaron diferentes algoritmos que fueron clasificados según los criterios de (Liakos et al., 2018) y (Slob, Catal & Kassahun, 2021):

1. Técnicas basadas en ANN: *adaptive neuro fuzzy inference system*, ANNs simétricas, *nonlinear auto-regressive model with exogenous input*, perceptrón multicapa, *back propagation neural network*, redes neuronales convolucionales y *long short-term memory networks* (LSTM, por sus siglas en inglés).
2. Técnicas basadas en SVM: *support vector regression*.
3. Técnicas basadas en GA: algoritmos genéticos clásicos simples.
4. Técnicas basadas en DT: bosques aleatorios, árboles estadísticos de decisión, árboles de regresión y clasificación.

Representación de los juicios y construcción de las matrices de valor

La aplicación de un cuestionario al grupo de expertos permitió obtener sus juicios de valor sobre los criterios de selección y las alternativas. Se confeccionaron 7 matrices de comparación por pares $n \times n$, donde los expertos evaluaron los criterios de selección asumidos y las alternativas según estos criterios. La tabla 2 muestra las matrices de valor obtenidas según las valoraciones de los expertos.

Tabla 2 - Matrices de valoraciones consensuadas.

a. Matriz de comparación de criterios						
	Criterio 1	Criterio 2	Criterio 3	Criterio 4	Criterio 5	Criterio 6
Criterio 1	1	2	3	2	4	2
Criterio 2	1/2	1	5	1/3	1/3	1/3
Criterio 3	1/4	1/5	1	1/7	1/3	1/5
Criterio 4	1/2	3	7	1	5	2
Criterio 5	1/3	3	3	1/5	1	1/2
Criterio 6	1/2	3	5	1/2	2	1

b. Matriz de comparación del criterio 1					c. Matriz de comparación del criterio 2				
	ANN	SVM	GA	DT		ANN	SVM	GA	DT
ANN	1	3	8	3	ANN	1	6	9	8
SVM	1/3	1	5	1/3	SVM	1/6	1	4	5
GA	1/8	1/5	1	1/6	GA	1/9	1/4	1	2
DT	1/3	3	6	1	DT	1/8	1/5	1/2	1

d. Matriz de comparación del criterio 3					e. Matriz de comparación del criterio 4				
	ANN	SVM	GA	DT		ANN	SVM	GA	DT
ANN	1	2	5	2	ANN	1	1/2	4	5
SVM	1/2	1	8	1/2	SVM	2	1	3	4
GA	1/5	1/8	1	1/7	GA	1/4	1/3	1	1/2
DT	1/2	2	7	1	DT	1/5	1/4	2	1

f. Matriz de comparación del criterio 5					g. Matriz de comparación del criterio 6				
	ANN	SVM	GA	DT		ANN	SVM	GA	DT
ANN	1	3	8	2	ANN	1	1/2	1/6	1/7
SVM	1/3	1	6	1/3	SVM	2	1	1/6	1/7
GA	1/8	1/6	1	1/4	GA	6	6	1	1/3
DT	1/2	3	4	1	DT	7	7	3	1

En cada matriz el elemento de la fila $i=1, 2, \dots, n$ se calificó respecto al elemento de la columna $j=1, 2, \dots, n$ según las magnitudes de la escala descrita en la tabla 1. Este proceso se realizó de forma tal que, si el elemento a_{ij} de la matriz de comparación A es k, entonces $a_{ji}= 1/k$, luego todos

los elementos diagonales $a_{ii}=1$ porque se evalúan a sí mismos (Saaty, 1990). Para sintetizar los juicios consensuados de los expertos se utilizó la media geométrica porque brinda una exactitud adecuada en este proceso (Mendoza et al., 2019).

Confección de las matrices normalizadas

Para normalizar las matrices de comparación se dividió cada uno de sus elementos entre la suma de los valores de su columna correspondiente. El cálculo de los vectores de prioridad de las matrices normalizadas se realizó promediando cada una de sus filas. La tabla 3 muestra las matrices normalizadas y sus respectivos vectores de prioridad.

Tabla 3 - Matrices normalizadas y sus vectores de prioridad.

a. Matriz normalizada y vector de prioridad de la comparación de criterios							
	Criterio 1	Criterio 2	Criterio 3	Criterio 4	Criterio 5	Criterio 6	Vector de prioridad
Criterio 1	0.32	0.16	0.13	0.48	0.32	0.33	0.29
Criterio 2	0.16	0.08	0.208	0.08	0.03	0.06	0.10
Criterio 3	0.08	0.02	0.04	0.03	0.03	0.03	0.04
Criterio 4	0.16	0.25	0.29	0.24	0.39	0.33	0.28
Criterio 5	0.11	0.25	0.13	0.05	0.08	0.08	0.11
Criterio 6	0.16	0.25	0.21	0.12	0.16	0.17	0.18
Total	1	1	1	1	1	1	1

b. Matriz normalizada y vector de prioridad del criterio 1					
	ANN	SVM	GA	DT	Vector de prioridad
ANN	0.558	0.417	0.400	0.667	0.51
SVM	0.186	0.139	0.250	0.074	0.16
GA	0.070	0.028	0.050	0.037	0.05
DT	0.186	0.417	0.300	0.222	0.28
Total	1	1	1	1	1

c. Matriz normalizada y vector de prioridad del criterio 2					
	ANN	SVM	GA	DT	Vector de prioridad
ANN	0.713	0.805	0.621	0.500	0.66
SVM	0.119	0.134	0.276	0.313	0.21
GA	0.079	0.034	0.069	0.125	0.08
DT	0.089	0.027	0.034	0.063	0.05
Total	1	1	1	1	1

d. Matriz normalizada y vector de prioridad del criterio 3					
	ANN	SVM	GA	DT	Vector de prioridad
ANN	0.558	0.417	0.400	0.667	0.51
SVM	0.186	0.139	0.250	0.074	0.16
GA	0.070	0.028	0.050	0.037	0.05
DT	0.186	0.417	0.300	0.222	0.28
Total	1	1	1	1	1

e. Matriz normalizada y vector de prioridad del criterio 4					
	ANN	SVM	GA	DT	Vector de prioridad
ANN	0.713	0.805	0.621	0.500	0.66
SVM	0.119	0.134	0.276	0.313	0.21
GA	0.079	0.034	0.069	0.125	0.08
DT	0.089	0.027	0.034	0.063	0.05
Total	1	1	1	1	1

	ANN	SVM	GA	DT	Vector de prioridad
ANN	0.455	0.390	0.238	0.549	0.41
SVM	0.227	0.195	0.381	0.137	0.24
GA	0.091	0.024	0.048	0.039	0.05
DT	0.227	0.390	0.333	0.275	0.31
Total	1	1	1	1	1

	ANN	SVM	GA	DT	Vector de prioridad
ANN	0.290	0.240	0.400	0.476	0.35
SVM	0.580	0.480	0.300	0.381	0.44
GA	0.072	0.160	0.100	0.048	0.10
DT	0.058	0.120	0.200	0.095	0.12
Total	1	1	1	1	1

	ANN	SVM	GA	DT	Vector de prioridad
ANN	0.511	0.419	0.421	0.558	0.48
SVM	0.170	0.140	0.316	0.093	0.18
GA	0.064	0.023	0.053	0.070	0.05
DT	0.255	0.419	0.211	0.279	0.29
Total	1	1	1	1	1

	ANN	SVM	GA	DT	Vector de prioridad
ANN	0.063	0.034	0.038	0.088	0.06
SVM	0.125	0.069	0.038	0.088	0.08
GA	0.375	0.414	0.231	0.206	0.31
DT	0.438	0.483	0.692	0.618	0.56
Total	1	1	1	1	1

Los vectores de prioridad representan la preferencia de las alternativas respecto al criterio considerado. Los resultados obtenidos en la tabla 3a evidencian que la capacidad de manejar datos que presentan incertidumbre y la obtención de resultados precisos de manera óptima constituyen los criterios más relevantes para seleccionar las técnicas de inteligencia artificial con mejor ajuste al pronóstico de las producciones de leche bovina. En relación a estos criterios, se identificó que las ANN son más eficientes para manejar datos que presentan incertidumbre (tabla 3b) y que las SVM permiten alcanzar resultados precisos con mayor ahorro de tiempo y recursos de cómputo, seguidas por las ANN (tabla 3e). Asimismo, se evidenció que los DT son la técnica de AI que ofrecen mejor comprensión e interpretabilidad de su funcionamiento durante la realización del pronóstico (tabla 3g).

Cálculo del vector de prioridad global y relación de consistencia

Se conformó una matriz de prioridad con los vectores de prioridad de las alternativas respecto a los criterios recogidos en las tablas 3b, 3c, 3d, 3e, 3f y 3g respectivamente, con el propósito de calcular el vector de prioridad global de las alternativas. La tabla 4 muestra la matriz de prioridad confeccionada y el vector de prioridad global de las alternativas.

Tabla 4 - Matriz de prioridad.

	Criterio 1	Criterio 2	Criterio 3	Criterio 4	Criterio 5	Criterio 6	Vector de prioridad
ANN	0.51	0.66	0.41	0.35	0.48	0.06	0.39
SVM	0.16	0.21	0.24	0.44	0.18	0.08	0.23
GA	0.05	0.08	0.05	0.10	0.05	0.31	0.11
DT	0.28	0.05	0.31	0.12	0.29	0.56	0.26

El vector de prioridad global de las alternativas indica su nivel de preferencia y constituye la solución del juicio de expertos (Mendoza et al., 2019). Para determinar su valor se multiplicó el vector de prioridad de los criterios obtenido en la tabla 3a, por la matriz de prioridad elaborada en la tabla 4. El vector de prioridad global evidenció que las técnicas basadas en Redes Neuronales Artificiales y Árboles de Decisión constituyen las técnicas de inteligencia artificial con mejor ajuste al pronóstico de las producciones de leche con un índice de preferencia de 0.39 y 0.26 respectivamente.

Para validar los resultados de esta investigación se calculó la relación de consistencia (RC) por cada matriz de comparación elaborada. La RC indica la racionalidad de los juicios empleados en las matrices de comparación y se calcula dividiendo el índice de consistencia (IC) entre el índice de consistencia aleatorio (IA) (Mendoza et al., 2019). Las fórmulas 1 y 2 muestran respectivamente cómo determinar las magnitudes de estos índices.

$$IC = \frac{\lambda_{max} - n}{n - 1} \tag{1}$$

$$IA = \frac{1.98(n - 2)}{n} \tag{2}$$

Donde

n: cantidad de elementos a evaluar en la matriz de comparación.

λ_{max} : valor promedio de los elementos del vector obtenido resultado del cociente entre la multiplicación de la matriz de comparación por su respectivo vector de prioridad y este último.

Según (Saaty, 1990), si $RC < 0.10$ el nivel de inconsistencia de los juicios es aceptable, de lo contrario los expertos deben revisar sus valoraciones. La tabla 5 muestra el valor de RC de las matrices de comparación.

Tabla 5 - Relación de consistencia de las matrices de comparación.

Matriz de comparación	RC
Comparación de criterios	0.091
Manejo de datos que presentan incertidumbre	0.067
Capacidad de utilizar mecanismos de aprendizaje	0.079
Capacidad de combinar conocimiento y datos	0.078
Obtención de resultados precisos de manera óptima	0.079
Obtención de conocimiento verificable	0.075
Fácil comprensión e interpretabilidad	0.060

Los resultados de la tabla 5 evidencian que el nivel de inconsistencia existente en las comparaciones por pares realizadas es aceptable, esto demuestra que no existió contradicción en los juicios brindados por los expertos.

Análisis de resultados

Los índices de RC descritos en la tabla 5 permiten inferir que la ejecución del proceso de juicio de expertos fue realizada de manera correcta. Los resultados obtenidos evidenciaron que las técnicas de inteligencia artificial basadas en Redes Neuronales Artificiales brindan mejor ajuste al pronóstico de las producciones de leche bovina con un nivel de preferencia de 39%, superior a las técnicas

basadas en Árboles de Decisión y Máquinas de Soporte Vectorial, ambas con 26% y 23% respectivamente.

En su análisis (Murphy et al., 2014) determinaron que las ANN de tipo NARX permiten incrementar la exactitud en los pronósticos de las producciones de leche, superior a los modelos basados en técnicas de regresión lineal múltiple y ANN estáticas. Los autores (Liakos et al., 2018) identificaron que las técnicas de inteligencia artificial más utilizadas en investigaciones relacionadas con la producción ganadera durante el período 2004-2018 fueron las SVM y las ANN, respectivamente. En su investigación (Nguyen et al., 2020), compararon el rendimiento de 3 modelos de pronóstico para predecir la producción lechera de la raza Holstein–Friesian mediante la aplicación de técnicas basadas en ANN, SVM y Random Forest, respectivamente. Los autores citados determinaron que el modelo basado en SVM obtuvo la mejor relación exactitud-costo computacional. Según (Zhang W. et al., 2020), el uso de GA en redes LSTM posibilitó obtener predicciones más exactas de la producción de leche bovina en comparación con modelos basados únicamente en ANN-LSTM. El estudio de revisión realizado por (Slob, Catal & Kassahun, 2021) sobre la gestión de las granjas lecheras durante el período 2010-2020 evidenció que las ANN y los DT fueron las técnicas de inteligencia artificial con mejores rendimientos en este sector. En correspondencia con los resultados obtenidos por (Slob, Catal & Kassahun, 2021), en la presente investigación se evidenció que las técnicas de inteligencia artificial basadas en ANN y DT respectivamente, ofrecen los mejores rendimientos para pronosticar las producciones de leche bovina.

Conclusiones

La aplicación del AHP permitió identificar a las técnicas basadas en Redes Neuronales Artificiales como las de mejor ajuste al pronóstico de las producciones de leche bovina, superior a las técnicas basadas en Árboles de Decisión y Máquinas de Soporte Vectorial. Además, se evidenció que la capacidad de manejar datos que presentan incertidumbre y la obtención de resultados precisos de

manera óptima constituyen los criterios de selección más relevantes para evaluar las técnicas de inteligencia artificial aplicadas al pronóstico de las producciones de leche.

Esta investigación facilita la toma de decisiones en organizaciones productoras de leche y contribuye al desarrollo de modelos de pronóstico en el sector de la industria láctea. Futuros trabajos pueden orientarse a evaluar los rendimientos de diferentes tipos de Redes Neuronales Artificiales en el pronóstico de las producciones de leche y determinar la correlación existente entre sus características y su eficiencia como herramientas predictivas.

Referencias

- Da Rosa, R.; Goldschmidt, G.; Kunst, R.; Deon, C.; Da Costa, C. A. Towards combining data prediction and internet of things to manage milk production on dairy cows. *Computers and Electronics in Agriculture*, 2020, 169. doi: <https://doi.org/10.1016/j.compag.2019.105156>
- Dongre, V.B.; Gandhi, R.S.; Singh, A.; Ruhil A. P. Comparative efficiency of artificial neural networks and multiple linear regression analysis for prediction of first lactation 305-day milk yield in Sahiwal cattle. *Livestock Science*, 2012, 147(1-3): p. 192-197. doi: <https://doi.org/10.1016/j.livsci.2012.04.002>
- Eyduran, E.; Yilmaz, I.; Tariq, M.; Kaygisiz, A. Estimation of 305-d milk yield using regression tree method in Brown Swiss Cattle. *JAPS Journal of Animal and Plant Sciences*, 2013, 23(3): p. 731–735.
- González, N.; Estrada, V.; Febles, A. Estudio y selección de las técnicas de Inteligencia Artificial para el diagnóstico de enfermedades. *Revista de Ciencias Médicas de Pinar del Río*, 2018, 22(3): p. 534-544.
- González, N.; Leiva, M. Y.; Faggioni, K. M.; Álvarez, P. J. Estudio comparado de las técnicas de Inteligencia Artificial para el diagnóstico de enfermedades en la ganadería. *Revista de Sistemas, Cibernética e Informática*, 2018, 15(2): p. 17-20.

- Gorgulu, O. Prediction of 305 days milk yield from early records in dairy cattle using on Fuzzy Inference System. *The Journal of Animal & Plant Sciences*, 2018, 28(4): p. 996-1001.
- Gunnar, B. Different methods to forecast milk delivery to dairy: a comparison for forecasting. *International Journal of Agricultural Management*, 2015, 4(3): p. 132-140. doi: <https://doi.org/10.5836/ijam/2015-03-132>
- Jensen, D. B.; Van Der Voort, M.; Hogeveen, H. Dynamic forecasting of individual cow milk yield in automatic milking systems. *J. Dairy Sci.*, 2018, 101(11): p. 1–12. doi: <https://doi.org/10.3168/jds.2017-14134>
- Kaygisiz, F.; Sezgin, F. H. Forecasting goat milk production in Turkey using Artificial Neural Networks and Box-Jenkins models. *Animal Review*, 2017, 4(3): p. 45-52. doi: 10.18488/journal.ar.2017.43.45.52
- Kliś, P.; Piwczyński, D.; Sawa, A.; Sitkowska, B. Prediction of Lactational Milk Yield of Cows Based on Data Recorded by AMS during the Periparturient Period. *Animals*, 2021, 11(2):383. doi: <https://doi.org/10.3390/ani11020383>
- Liakos, K. G.; Busato, P.; Moshou, D.; Pearson, S.; Bochtis, D. Machine Learning in Agriculture: A Review. *Sensors*, 2018, 18: 2674. doi: <https://dx.doi.org/10.3390/s18082674>
- Liseunea, A.; Salamone, M.; Van Den Poel, D.; Van Ranst, B.; Hostens, M. Leveraging latent representations for milk yield prediction and interpolation using deep learning. *Computers and Electronics in Agriculture*, 2020, 175: 105600. doi: <https://doi.org/10.1016/j.compag.2020.105600>
- Machado, G.; Figueiredoa, D. M.; Resende, P. C.; Dos Santosa, R. A.; Lacroixc, R.; Santschic, D.; Lefebvre, D. M. Predicting first test day milk yield of dairy heifers. *Computers and Electronics in Agriculture*, 2019, 166: p. 1-8. doi: <https://doi.org/10.1016/j.compag.2019.105032>
- Mahmoudi, A.; Mi, X.; Liao, H.; Feylizadeh, M. F.; Turskis, Z. Grey Best-Worst Method for Multiple Experts Multiple Criteria Decision Making Under Uncertainty. *Informatica*, 2020, 31(2): p. 331-357. doi: <https://doi.org/10.15388/20-INFOR409>
- Mendoza, A.; Solano, C.; Palencia, D.; Garcia, D. Aplicación del proceso de jerarquía analítica (AHP) para la toma de decisión con juicios de expertos. *Ingeniare. Revista chilena de ingeniería*, 2019, 27(3): p. 348-360. doi: <http://dx.doi.org/10.4067/S0718-33052019000300348>

Montalván-Estrada, A.; Aguilera-Corrales, Y.; Veitia-Rodríguez, E.; Brígido-Flores, O. Análisis multicriterio para la gestión integrada de aguas residuales industriales. *Ingeniería Industrial*, 2017, 38(2): p. 56-67.

Murphy, M. D.; O'mahony, M. J.; Shalloo, L.; French, P.; Upton, J. Comparison of modeling techniques for milk-production forecasting. *J. Dairy Sci.*, 2014, 97(6): p. 3352–3363. doi: <http://dx.doi.org/10.3168/jds.2013-7451>

Notte, G.; Pedemonte, M.; Cancela, H.; Chilibroste, P. Resource allocation in pastoral dairy production systems: Evaluating exact and genetic algorithms approaches. *Agricultural Systems*, 2016, 148: p. 114-123. doi: <http://dx.doi.org/10.1016/j.agsy.2016.07.009>

Nguyen, Q. T.; Fouchereau, R.; Frénod, E.; Gerard, C.; Sincholle, V. Comparison of forecast models of production of dairy cows combining animal and diet parameters. *Computers and Electronics in Agriculture*, 2020, 170. doi: <https://doi.org/10.1016/j.compag.2020.105258>

Ocampo, C. D.; Tamayo, J.; Castaño, H. M. Gestión del Riesgo en la Implementación de Sistemas Fotovoltaicos en Proyectos de Extracción de Oro en Colombia a partir del Proceso de Análisis Jerárquico (AHP). *Información Tecnológica*, 2019, 30(3): p. 127-136. doi: <http://dx.doi.org/10.4067/S0718-07642019000300127>

Oscullo, J.; Haro L. Pronóstico de la Demanda Diaria del Sistema Nacional Interconectado Utilizando Redes Neuronales. *Revista Politécnica*, 2016, 38 (1): p. 77-82.

Ossadnik, W.; Schinke, S.; KASPAR, R. H. Group Aggregation Techniques for Analytic Hierarchy Process and Analytic Network Process: A Comparative Analysis. *Group Decision and Negotiation*, 2016, 25: p. 421-457. doi: <https://doi.org/10.1007/s10726-015-9448-4>

Rozman, Č., Grgić, Z., Maksimović, A., Čejvanović, F., Puška, A. I Šakić Bobić, B. Multiple-criteria approach of evaluation of milk farm models in Bosnia and Herzegovina. *Mljekarstvo*, 2016, 66 (3): p. 206-214. doi: <https://doi.org/10.15567/mljekarstvo.2016.0305>

Piwczyński, D.; Sitkowska, B.; Kolenda, M.; Brzozowski, M.; Aerts, J.; Schork, P. M. Forecasting the milk yield of cows on farms equipped with automatic milking system with the use of decision trees. *Animal Science Journal*, 2020, 91(1), e13414. doi: <https://doi.org/10.1111/asj.13414>

- Perdigón, R.; González, N. Una revisión bibliográfica sobre modelos para predecir las producciones de leche. *Revista Ingeniería Agrícola*, 2020, 10(4): p. 69-77.
- Perdigón, R.; Viltres, H.; Orellana, A. Models for predicting perishable products demands in food trading companies. *Revista Cubana de Ciencias Informáticas*, 2020, 14(1): p. 110-135.
- Saaty, T. L. How to make a decision: The analytic hierarchy process. *European Journal of Operational Research*, 1990, 48(1): p. 9-26. doi: [https://doi.org/10.1016/0377-2217\(90\)90057-I](https://doi.org/10.1016/0377-2217(90)90057-I)
- Saaty, T. L.; Ergu, D. When is a Decision-Making Method Trustworthy? Criteria for Evaluating Multi-Criteria Decision-Making Methods. *International Journal of Information Technology & Decision Making*, 2015, 14(6): p. 1171-1187. doi: <https://doi.org/10.1142/S021962201550025X>
- Saha, A.; Bhattacharyya, S. Artificial insemination for milk production in India: A statistical insight. *Indian Journal of Animal Sciences*, 2020, 90(8): p. 1186–1190.
- Slob, N.; Catal, C.; Kassahun, A. Application of Machine Learning to Improve Dairy Farm Management: A Systematic Literature Review. *Preventive Veterinary Medicine*, 2021, 187: 105237. doi: <https://doi.org/10.1016/j.prevetmed.2020.105237>
- Sugiono, S.; Soenoko, R.; Riawati, L. Investigating the Impact of Physiological Aspect on Cow Milk Production Using Artificial Intelligence. *International Review of Mechanical Engineering*, 2017, 11(1): p. 30-36. doi: <https://doi.org/10.15866/ireme.v11i1.9873>
- Torres-Inga, C. S.; López-Crespo, G.; Guevara-Viera, R.; Narváez-Terán, J.; Serpa- García, V. G.; Guzmán-Espinoza, C. K.; Guevara-Viera, G.; Aguirre de Juana, A. J. Eficiencia técnica en granjas lecheras de la Sierra Andina mediante modelación con redes neuronales. *Revista Producción Animal*, 2019, 31(1): p. 10-15.
- Wen, Z.; Liao, H.; Zavadskas, E. K. Macont: Mixed Aggregation by Comprehensive Normalization Technique for Multi-Criteria Analysis. *Informatica*, 2020, p. 1-24. doi: <https://doi.org/10.15388/20-INFOR417>
- Yan, W. J.; Chen, X.; Akcan, O.; Lim, J.; Yang, D. Big Data Analytics for Empowering Milk Yield Prediction in Dairy Supply Chains. En: *International Conference on Big Data (Big Data)*, Santa Clara, CA, USA: IEEE, 2015, p. 2132-2137. doi: <https://doi.org/10.1109/BigData.2015.7363997>

Zhang, F.; Murphy, M. D.; Shalloo, L.; Ruelle, E.; Upton, J. An automatic model configuration and optimization system for milk production forecasting. *Computers and Electronics in Agriculture*, 2016, 128: p. 100–111. doi: <https://doi.org/10.1016/j.compag.2016.08.016>

Zhang, F.; Upton, J.; Shalloo, L.; Murphy, M. D. Effect of parity weighting on milk production forecast models. *Computers and Electronics in Agriculture*, 2019, 157: p. 589–603. doi: <https://doi.org/10.1016/j.compag.2018.12.051>

Zhang, F.; Upton, J.; Shalloo, L.; Shine, P.; Murphy, M. D. Effect of introducing weather parameters on the accuracy of milk production forecast models. *Information Processing in Agriculture*, 2020, 7(1): p. 120-138. doi: <https://doi.org/10.1016/j.inpa.2019.04.004>

Zhang, W.; Yang, K.; Yu, N.; Cheng, T.; Liu, J. Daily milk yield prediction of dairy cows based on the GA-LSTM algorithm. En: *International Conference on Signal Processing (ICSP)*, Beijing, China: IEEE, 2020, p. 664-668. doi: <https://doi.org/10.1109/ICSP48669.2020.9320926>

Conflicto de interés

Los autores declaran que no existe conflicto de intereses.

Contribución de los autores

1. Conceptualización: Rudibel Perdigón Llanes.
2. Curación de datos: Rudibel Perdigón Llanes.
3. Análisis formal: Rudibel Perdigón Llanes.
4. Adquisición de fondos: No procede.
5. Investigación: Rudibel Perdigón Llanes y Neilys González Benítez.
6. Metodología: Neilys González Benítez.
7. Administración del proyecto: Rudibel Perdigón Llanes.
8. Recursos: Rudibel Perdigón Llanes.
9. Software: No procede.
10. Supervisión: Neilys González Benítez.

11. Validación: Rudibel Perdigón Llanes y Neilys González Benítez
12. Visualización: Rudibel Perdigón Llanes.
13. Redacción – borrador original: Rudibel Perdigón Llanes.
14. Redacción – revisión y edición: Neilys González Benítez.

Financiación

Esta investigación no recibió ninguna subvención específica de organismos de financiación de los sectores público, comercial o sin fines de lucro.