

Redes neuronales artificiales en el pronóstico de la producción de leche bovina

Artificial neural networks in bovine milk production forecasting

Rudibel Perdigón-Llanes¹ , Neilys González-Benítez² 

¹Centro Meteorológico Provincial, Ministerio de la Agricultura, Pinar del Río, Cuba.

²Centro Meteorológico Provincial, Ministerio de Ciencia, Tecnología y Medio Ambiente, Pinar del Río, Cuba.

rperdigon9@gmail.com, neilysgonzalezbenitez@gmail.com

(Recibido: 19 julio 2021; aceptado: 23 noviembre 2021; Publicado en Internet: 30 junio 2022)

Resumen. Los pronósticos facilitan la toma de decisiones en granjas productoras de leche y contribuyen a mejorar la cadena productiva de este alimento. En la literatura se identificó que las redes neuronales artificiales poseen un ajuste aceptable al pronóstico de las producciones de leche. Sin embargo, en las fuentes bibliográficas consultadas no se evidenció un consenso sobre el tipo de red neuronal artificial con mejores rendimientos en esta actividad. Esta investigación tiene como objetivo identificar la red neuronal artificial con mayores índices de desempeño en el pronóstico de la producción de leche bovina. Se realizó una revisión de la literatura relacionada con los pronósticos de las producciones de leche mediante el uso de redes neuronales artificiales. Los resultados obtenidos en la literatura analizada evidenciaron que las redes no lineales autorregresivas con variables exógenas y las redes convolucionales poseen los mejores rendimientos en el pronóstico de la producción de leche bovina.

Palabras clave: Inteligencia artificial, Modelos de pronóstico, Ganadería, Toma de decisiones.

Abstract. Forecasting facilitates decision-making on dairy farms and contributes to improving the milk production chain. According to the literature, artificial neural networks have an acceptable adjustment to milk production forecasting. However, in the consulted bibliographic sources, there was no consensus on the type of artificial neural network with the best performance in this activity. This research is aimed at identifying the artificial neural network with the highest performance levels in bovine milk production forecasting. A literature review related to milk production forecasting using artificial neural networks was carried out. The results from the sources examined revealed that nonlinear autoregressive networks with exogenous variables and convolutional neural networks perform best in forecasting bovine milk production.

Keywords: Artificial intelligence, Forecasting models, Livestock, Decision making.

Tipo de artículo: Artículo de revisión.

1 Introducción

Los pronósticos permiten realizar estimaciones cuantitativas de eventos futuros mediante el análisis e interpretación de datos pasados (Perdigón Llanes & González Benítez, 2020; Winkowski, 2019). Esta actividad facilita la toma de decisiones en organizaciones y procesos productivos (Winkowski, 2019).

El uso de los pronósticos en granjas productoras de leche contribuye a mejorar la gestión del rebaño lechero, ahorrar energía en estas instalaciones y optimizar las inversiones de capital a largo plazo (Cockburn, 2020; Grzesiak et al., 2021; Liseune et al., 2021; Radwan et al., 2020). La aplicación de modelos de pronóstico en la industria láctea representa un tema de interés para la comunidad científica internacional (Perdigón Llanes & González Benítez, 2020). Sin embargo, su realización constituye una actividad compleja porque son diversos los factores que influyen en la producción de este alimento (Perdigón Llanes & González Benítez, 2020; Sugiono et al., 2017).

Según Ruelle et al. (2019) los modelos para pronosticar las producciones lecheras requieren de una significativa información de parametrización. Estos modelos se basan principalmente en algoritmos matemáticos, estocásticos de series de tiempo, regresivos y en técnicas computacionales de inteligencia artificial (Grzesiak et al., 2021; Perdigón Llanes & González Benítez, 2020).

La utilización de técnicas de AI en actividades agrícolas y ganaderas es un fenómeno creciente que facilita el procesamiento de datos y contribuye a incrementar la rentabilidad de las operaciones que se realizan en este sector (Banerjee et al., 2018; Dongre et al., 2017; Liu et al., 2021; Torres-Inga et al., 2019). Las técnicas de AI más utilizadas en este ámbito emplean algoritmos basados en redes neuronales artificiales (ANN, por sus siglas en inglés), árboles de decisión, y máquinas de soporte vectorial (Liakos et al., 2018; Slob et al., 2020). Los autores Murphy et al. (2014), Zhang et al. (2016), Dongre et al. (2017), y Perdigón Llanes y González Benítez (2021), identificaron que las redes neuronales artificiales son la técnica de inteligencia artificial con mejor ajuste al pronóstico de las producciones de leche.

Las ANN simulan el funcionamiento de las neuronas del cerebro humano y están compuestas por numerosos elementos de procesamiento altamente interrelacionados que funcionan al unísono para resolver problemas de forma precisa (Flores-Calero et al., 2021; Nayak et al., 2020; S. Sharma et al., 2020). Esta técnica requiere al menos de una capa de entrada y otra de salida, compuestas por nodos (neuronas) que se corresponden con las variables de entrada y salida respectivamente (S. Sharma et al., 2020). El flujo de datos entre las diferentes capas se realiza mediante conexiones ponderadas (N. Gandhi & Armstrong, 2016). Las redes neuronales artificiales manejan diferentes tipos de variables de entrada y poseen la capacidad de representar y aprender las relaciones lineales y no lineales existentes en los datos que modelan (Atil & Akilli, 2016; Dongre et al., 2017; Jha et al., 2019; Singh et al., 2020).

En la literatura se identificaron diversas investigaciones relacionadas con el desarrollo de modelos para pronosticar las producciones lecheras mediante el empleo de diferentes tipos de ANN (Perdigón Llanes & González Benítez, 2021; Slob et al., 2020). Los autores de las investigaciones consultadas determinaron que estas técnicas poseen rendimientos aceptables para la resolución de problemas específicos en ambientes con determinadas características (Slob et al., 2020). No obstante, en las fuentes bibliográficas analizadas no se evidenció un consenso sobre la ANN con mejor ajuste al pronóstico de las producciones lecheras.

El objetivo de la presente investigación consiste en identificar la ANN con mayores índices de desempeño en el pronóstico de las producciones de leche bovina. Para lograr este propósito, se efectuó una revisión de la literatura disponible en Internet relacionada con los pronósticos en organizaciones productoras de leche mediante el uso de redes neuronales artificiales.

Las revisiones de la literatura proporcionan una panorámica íntegra y sintetizada de la evidencia científica existente sobre determinado tema de investigación y permiten la resolución de preguntas científicas de manera transparente y reproducible (Lame, 2019; Linnenluecke et al., 2019). Los autores Slob et al. (2020), desarrollaron una revisión sistemática de la literatura donde identificaron las técnicas de AI utilizadas en el pronóstico de las producciones lecheras durante el período 2010-2020. Sin embargo, estos autores no determinaron en su investigación el tipo de ANN con mayores rendimientos en esta actividad.

2 Metodología

El proceso de revisión se desarrolló según la metodología descrita por Lame (2019) en su investigación. Inicialmente se formularon las preguntas de investigación (RQ, por sus siglas en inglés) y se trazó una estrategia de búsqueda para identificar la literatura de interés. Posteriormente se definieron los criterios de selección para distinguir las fuentes relevantes. Finalmente, se realizó el análisis de los datos extraídos de las fuentes consultadas y la presentación de los resultados. A continuación, se describen las fases del proceso de revisión desarrollado.

2.1 Preguntas de investigación

- RQ1. ¿Qué arquitecturas poseen las ANN utilizadas para predecir las producciones de leche bovina?
- RQ2. ¿Cuáles son las variables de entrada empleadas para realizar los pronósticos?
- RQ3. ¿Cómo se evalúan los rendimientos de los pronósticos?
- RQ4. ¿Qué tipo de ANN realiza el pronóstico de las producciones de leche con mayores índices de rendimiento?

2.2 Estrategia de búsqueda

Se realizó una búsqueda en las bases de datos académicas Google Scholar, IEEE Xplore, ScienceDirect, y Scielo. Para tal fin, se empleó la siguiente cadena de búsqueda: ("ANN" OR "artificial intelligence" OR "machine learning") AND ("milk production forecasting" OR "milk yield forecasting" OR "milk production prediction" OR "milk yield prediction"). La búsqueda se efectuó en el título, resumen, y palabras claves de la literatura indexada en las bases de datos mencionadas.

2.3 Criterios de selección

Según Slob et al. (2020), los criterios de selección aseguran que solo la literatura relevante sea identificada para su análisis y procesamiento. Estos autores clasificaron como fuentes relevantes las investigaciones con datos e información que contribuyen a resolver las preguntas de investigación. La [Tabla 1](#) describe los criterios empleados para seleccionar la literatura de interés.

Tabla 1. Criterios de selección utilizados.

Criterios de inclusión	Criterios de exclusión
Publicaciones referentes a la aplicación de las ANN para pronosticar las producciones de leche bovina.	Publicaciones referentes a la aplicación de otras técnicas de AI para pronosticar las producciones de leche bovina.
	Publicaciones duplicadas
Literatura publicada en idioma inglés o español.	Literatura publicada en otros idiomas.
Investigaciones publicadas durante el período comprendido entre enero 2010 y abril 2021.	Publicaciones con acceso restringido.
	Fuentes secundarias y terciarias de investigación.

Los autores Gupta et al. (2019), plantean que las ANN han sido ampliamente utilizadas para la realización de pronósticos en las últimas décadas. Con el objetivo de obtener resultados actualizados sobre las ANN utilizadas en los pronósticos de las producciones de leche bovina se incluyeron en el presente estudio fuentes primarias de investigación, publicadas en idiomas inglés o español durante el período comprendido entre enero de 2010 y abril de 2021, fecha en que fue realizado este trabajo. Se emplearon los métodos científicos analítico sintético, análisis documental, histórico lógico, y la triangulación teórica para facilitar el procesamiento de la información obtenida, estudiar su evolución en el tiempo, y disminuir el sesgo en la investigación.

3 Resultados y discusión

La búsqueda de documentos en las bases de datos académicas arrojó los siguientes resultados: Google Scholar con 140 publicaciones, IEEE Xplore con 6 publicaciones, ScienceDirect con 17 publicaciones, y Scielo con 83 publicaciones. La selección de las fuentes relevantes mediante los criterios de inclusión y exclusión utilizados permitió obtener un total de 37 investigaciones relacionadas con el objeto de estudio. La [Figura 1](#) muestra la distribución de las fuentes identificadas según su año y fuente de publicación.

En la literatura consultada los artículos en revistas académicas y las ponencias en conferencias científicas fueron los medios de publicación más utilizados. No se identificaron tesis de posgrado referentes al empleo de las ANN para pronosticar las producciones de leche bovina durante el período analizado. Se evidenció que las investigaciones relacionadas con la aplicación de las redes neuronales artificiales en los pronósticos de las producciones lecheras se incrementaron durante el último trienio del período analizado, representando un 37,83% del total de las publicaciones identificadas en la literatura estudiada. En correspondencia con los criterios de Slob et al. (2020), los resultados anteriores demostraron el creciente interés de la comunidad científica internacional respecto a esta temática.

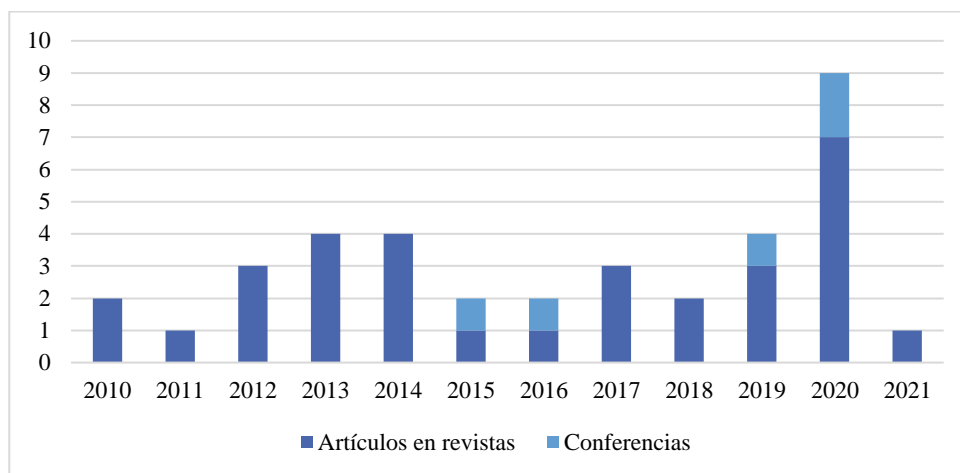


Figura 1. Distribución de las publicaciones identificadas.

RQ1. ¿Qué arquitecturas poseen las ANN utilizadas para predecir las producciones de leche bovina?

La arquitectura de una red neuronal define la organización de las neuronas que la componen y las direcciones de sus conexiones sinápticas (da Silva et al., 2017). La correcta selección de la arquitectura de una ANN es de suma importancia porque incide directamente en sus índices de aprendizaje (Kamilaris & Prenafeta Boldú, 2018; Radwan et al., 2020). Según da Silva et al. (2017), las principales arquitecturas de las ANN son: *feedforward* de una sola capa, *feedforward* multicapas, *feedback* o recurrentes y arquitectura de malla. La Figura 2 muestra las arquitecturas de las ANN que fueron utilizadas para pronosticar las producciones de leche bovina en las diferentes fuentes consultadas.

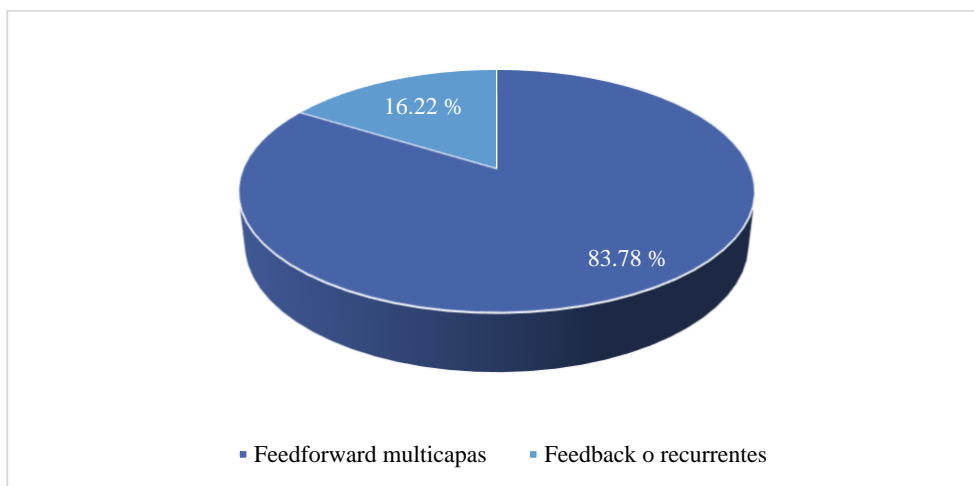


Figura 2. Arquitecturas de las ANN identificadas.

Se identificó que las ANN con arquitectura *feedforward* multicapas fueron las más utilizadas en las fuentes consultadas, fundamentalmente las redes de tipo perceptrón multicapa (MLP, por sus siglas en inglés) que fueron empleadas en un 75.67% de las investigaciones, las redes convolucionales (CNN, por sus siglas en inglés) en un 5.40%, y los sistemas híbridos de inferencia difusa con redes neuronales artificiales (ANFIS, por sus siglas en inglés) en un 2.71%. Las redes neuronales de arquitectura recurrente fueron utilizadas solo en el 16.22% de las publicaciones identificadas, principalmente las redes no lineales auto-regresivas con variables exógenas (NARX, por sus siglas en inglés) que se emplearon en un 13.51% de las investigaciones, y las redes neuronales con memoria a largo y corto plazo (LSTM, por sus siglas en inglés) en un 2.71%.

Según Sugiono et al. (2017) y Singh et al. (2020), el MLP es la ANN más utilizada. En concordancia con los autores citados, en la presente investigación se evidenció que las ANN de tipo MLP fueron

ampliamente empleadas para pronosticar las producciones de leche bovina. La [Tabla 2](#) describe la topología de algunas de estas ANN.

Tabla 2. Topologías de las ANN tipo MLP identificadas.

Citación	Capas ocultas	Cantidad de neuronas en cada capa
(R. S. Gandhi et al., 2010)	2	2 : 9
(Njubi et al., 2010)	3	7 : 4 : 1
(Njubi et al., 2011)	3	8 : 1 : 1
(Dongre et al., 2012)	2	3 : 5
(Gorgulu, 2012)	1	8
(R. S. Gandhi et al., 2012)	2	5 : 5
(Boniecki et al., 2013)	3	2 : 31 : 1
(Chaturvedi et al., 2013)	2	5 : 5
(Panigrahi et al., 2013)	1	3
(S. K. Sharma & Kumar, 2014)	2	4 : 2
(Bhosale & Singh, 2015)	2	5 : 5
(Sugiono et al., 2016)	2	20 : 20
(Bhosale & Singh, 2017)	2	5 : 5
(Dongre et al., 2017)	2	10 : 10
(Sugiono et al., 2017)	2	20 : 10
(Oyegbile et al., 2018)	3	6 : 2 : 1
(Machado Dallago et al., 2019)	3	100 : 100 : 100
(Singh et al., 2020)	1	6
(Nguyen et al., 2020)	1	4
(Akilli & Atil, 2020)	1 a 3	3 a 20
(Usman et al., 2020)	1	8
(Saefullah et al., 2020)	3	5 : 10 : 1

Se determinó que las ANN de tipo MLP utilizadas en la literatura consultada fueron diseñadas en su mayoría con 2 capas ocultas y un promedio de 8 neuronas en cada una respectivamente. El aprendizaje supervisado fue el más empleado, principalmente mediante métodos de retro propagación como la Regularización Bayesiana y el Gradiente Conjugado Escalonado, aplicados en el 48.64% y el 16.21% de las publicaciones, respectivamente. Se identificó que las funciones de activación más utilizadas fueron *tanh* (49% de las investigaciones) y *purelin* (46%).

RQ2. ¿Cuáles son las variables de entrada empleadas para realizar los pronósticos?

Según Perdigón Llanes y González Benítez (2020), determinar los elementos que inciden en las producciones lecheras es de vital importancia para realizar su pronóstico futuro. Peña-Rueda et al. (2018) y Perdigón Llanes y González Benítez (2020) identificaron que las producciones de leche bovina son influenciadas por disímiles factores relacionados fundamentalmente con las variaciones del clima, el manejo del ganado, su alimentación, sus características fisiológicas y genéticas.

Jha et al. (2019) aseguran que las ANN pueden realizar el pronóstico de fenómenos complejos si son provistas de un conjunto fiable de variables de entrada. En la presente investigación se identificaron las variables independientes utilizadas por los autores de las fuentes consultadas para pronosticar las producciones de leche bovina. Se identificaron un total de 41 variables que fueron agrupadas en siete categorías relacionadas con el período de lactancia del ganado lechero, sus características fisiológicas, rendimiento productivo durante períodos de prueba, datos del ambiente donde se desarrolla, alimentación del animal, ocurrencia de eventos externos y composición de la leche. Estas variables son descritas en la [Tabla 3](#) y constituyen los datos de entrada modelados por las ANN para realizar los pronósticos.

Tabla 3. Variables de entrada utilizadas en la literatura para realizar los pronósticos mediante las ANN.

Lactancia										
Citación	Producción de leche (Kg)	Frecuencia de lactancia	Duración de lactancia (días)	Número de lactancias	Pico de lactancia	Días en leche	Duración período de servicio	Período seco		
(R. S. Gandhi et al., 2010)	X		X				X	X		
(Njubi et al., 2010)	X		X							
(Dongre et al., 2012)	X									
(Gorgulu, 2012)				X						
(R. S. Gandhi et al., 2012)	X									
(Chaturvedi et al., 2013)	X						X			
(S. K. Sharma & Kumar, 2014)	X						X			
(Murphy et al., 2014)										
(Kumar & Hooda, 2014)	X		X				X	X		
(Bhosale & Singh, 2015)										
(F. Zhang et al., 2016)	X			X		X				
(Bhosale & Singh, 2017)	X		X		X					
(Dongre et al., 2017)										
(Gorgulu, 2018)				X						
(Oyegbile et al., 2018)	X									
(Pimpa et al., 2019)			X	X	X			X		
(F. Zhang et al., 2019)	X					X				
(Machado Dallago et al., 2019)		X				X				
(Nguyen et al., 2020)	X			X		X				
(Akilli & Atil, 2020)				X		X				
(F. Zhang et al., 2020)	X		X	X		X				
(W. Zhang et al., 2020)					X					
(Radwan et al., 2020)				X		X	X			
(Liseune et al., 2020)	X			X		X	X	X		
(Grzesiak et al., 2021)	X		X							
(Liseune et al., 2021)	X			X		X	X	X		
Características del animal										
Citación	Edad (años)	Edad en el parto (meses)	Fecha del parto	Intervalo entre partos	Paridad	Cant. crías por parto	Peso corporal (Kg)	Temp. corporal (°C)	Ritmo cardíaco	Valores genéticos
(R. S. Gandhi et al., 2010)		X								
(Njubi et al., 2010)	X	X	X		X					X
(Njubi et al., 2011)		X	X							
(Gorgulu, 2012)	X		X							
(Chaturvedi et al., 2013)		X		X						
(S. K. Sharma & Kumar, 2014)		X		X						
(Manoj et al., 2014)							X			
(Kumar & Hooda, 2014)		X		X						
(Sugiono et al., 2016)								X	X	
(F. Zhang et al., 2016)		X			X					
(Sugiono et al., 2017)								X	X	
(Gorgulu, 2018)	X									
(Oyegbile et al., 2018)				X			X			
(Pimpa et al., 2019)		X	X				X			
(F. Zhang et al., 2019)						X				
(Machado Dallago et al., 2019)			X		X		X			
(Akilli & Atil, 2020)		X								

(Singh et al., 2020)		X										
(Nguyen et al., 2020)					X							
(Usman et al., 2020)		X										
(W. Zhang et al., 2020)					X		X					
(Radwan et al., 2020)		X	X		X							
(Liseune et al., 2020)		X		X								
(Grzesiak et al., 2021)			X									
(Liseune et al., 2021)		X		X								
Rendimiento lechero durante períodos de prueba												
Citación	Rendimiento durante la prueba (Kg)		Producción total de por vida (Kg)		Rendimiento mínimo (Kg)		Rendimiento máximo (Kg)					
(Njubi et al., 2011)	X											
(R. S. Gandhi et al., 2012)			X									
(Gorgulu, 2012)	X											
(Chaturvedi et al., 2013)			X									
(S. K. Sharma & Kumar, 2014)			X									
(Yan et al., 2015)	X											
(Gorgulu, 2018)	X											
(Machado Dallago et al., 2019)	X											
(Akilli & Atil, 2020)	X											
(Usman et al., 2020)	X							X				
(Radwan et al., 2020)	X											
(Saefullah et al., 2020)S	X											
(Singh et al., 2020)								X				
(Grzesiak et al., 2021)	X											
(Liseune et al., 2021)					X			X				
Datos del ambiente												
Citación	Temp. Min. (°C)		Temp. Máx. (°C)		Humedad relativa		Velocidad del viento (m/s)		Precipitaciones (mm)		Horas de sol	
(Boniecki et al., 2013)	X	X										
(Sugiono et al., 2016)	X	X	X			X						
(F. Zhang et al., 2016)	X	X				X		X			X	
(Sugiono et al., 2017)	X	X	X			X						
(Pimpa et al., 2019)			X									
(Liseune et al., 2020)			X									
(F. Zhang et al., 2020)								X			X	
(Liseune et al., 2021)			X									
Alimentación												
Citación	Consumo de concentrado alimenticio (Kg)		Tipo de fibra alimenticia		Cant. De fibra consumida (Kg)		Consumo de almidón (Kg)		Consumo de Proteínas (Kg)			
(Pimpa et al., 2019)	X		X									
(Nguyen et al., 2020)						X		X			X	
(W. Zhang et al., 2020)	X											

Eventos externos				
Citación	Enfermedades del animal	Mastitis	Estrés	Abortos
(Pimpa et al., 2019)	X		X	
(Liseune et al., 2020)	X	X		X
(Liseune et al., 2021)	X	X		X
Composición de la leche				
Citación	Urea (mg dL ⁻¹)	Grasas y proteínas	Células somáticas (10 ³ cells mL ⁻¹)	beta-hidroxitirato (mmol L ⁻¹)
(Oyegbile et al., 2018)		X		
(Machado Dallago et al., 2019)	X	X	X	X

Sugiono et al. (2017) identificaron que la temperatura y la humedad relativa del ambiente inciden significativamente en los índices productivos del ganado lechero. Asimismo, F. Zhang et al. (2020), determinaron que el uso de datos climatológicos como variables de entrada en redes NARX incrementan su exactitud en el pronóstico de la producción de leche. Sin embargo, solo el 21.62 % de los autores consultados incluyeron datos climáticos como variables de entrada para predecir las producciones lecheras mediante ANN.

Se evidenció que los autores consultados emplearon en la capa de entrada de las ANN un promedio de 9 variables para modelar el pronóstico de las producciones de leche bovina. Se identificó que las variables más utilizadas se relacionaron con datos de la etapa de lactancia del ganado, sus características fisiológicas, y sus índices de producción de leche durante los períodos de prueba. En relación a estos hallazgos, los autores Slob et al. (2020) determinaron que las variables mencionadas fueron las más utilizadas en investigaciones publicadas durante el período 2010-2020 para la realización de pronósticos en la ganadería mediante técnicas de AI. Sin embargo, Slob et al. (2020) identificaron que solo fueron empleadas un promedio de 5 variables de entrada en las investigaciones, criterio que difiere de los resultados obtenidos en la presente investigación. Esta diferencia de criterios se debe a que Slob et al. (2020), incluyeron en su análisis publicaciones relacionadas no solo con los pronósticos de las producciones de leche, sino también con su calidad y la ocurrencia de enfermedades del ganado, dominios que requieren diferentes variables y enfoques de análisis para su modelación. Además, Slob et al. (2020) solo identificaron 10 investigaciones orientadas al pronóstico de las producciones lecheras.

RQ3. ¿Cómo se evalúan los rendimientos de los pronósticos?

Los autores Kumar y Hooda (2014), plantean que evaluar la exactitud de los modelos de pronóstico constituye un elemento fundamental para garantizar su aplicación práctica. La [Tabla 4](#) describe los principales métodos utilizados en las investigaciones identificadas para determinar la exactitud de los pronósticos. Se evidenció el empleo de múltiples métodos de evaluación en las diferentes publicaciones analizadas.

Tabla 4. Métodos de evaluación utilizados por los autores de la literatura consultada.

Método de evaluación	Nivel de utilización
Raíz del error cuadrático medio (RMSE, por sus siglas en inglés).	29.35%
Coefficiente de determinación (R ²).	27.17%
Media del error porcentual absoluto (MAPE, por sus siglas en inglés).	7.61%
Error cuadrático medio (MSE, por sus siglas en inglés).	6.52%

Método de evaluación	Nivel de utilización
Error absoluto medio (MAE, por sus siglas en inglés).	5.43%
Coefficiente de correlación de Pearson.	4.35%
Error de la suma cuadrática residual (SSE, por sus siglas en inglés).	3.26%

Se determinó que RMSE y R^2 fueron los métodos más empleados, representando el 29.35% y el 27.17% respectivamente, del total de métodos de evaluación utilizados en las fuentes consultadas. Además, se identificó que el enfoque de evaluación predominante en las investigaciones fue la retención, donde los datos de entrada fueron divididos en conjuntos de entrenamiento y validación, respectivamente. En relación a este hallazgo, se evidenció que en las publicaciones consultadas se empleó fundamentalmente el 80.64% del conjunto de datos para el entrenamiento y el 19.36% para la validación de las ANN.

Según Perdigón Llanes y González Benítez (2020) y Slob et al. (2020), los métodos RMSE y R^2 son ampliamente aplicados para evaluar la exactitud de los pronósticos de las producciones de leche. Los autores Slob et al. (2020), identificaron que durante el período 2010-2020 la validación mediante el enfoque de retención fue el más empleado para evaluar los pronósticos efectuados mediante técnicas de AI en la ganadería. Los resultados obtenidos en la presente investigación coinciden con los criterios de Perdigón Llanes y González Benítez (2020) y Slob et al. (2020).

RQ4. ¿Qué tipo de ANN realiza el pronóstico de las producciones de leche con mejores índices de rendimiento?

Según F. Zhang et al. (2016), Perdigón Llanes y González Benítez (2020), y F. Zhang et al. (2020), definir un modelo para pronosticar las producciones de leche bovina con un rendimiento adecuado en diferentes entornos es una actividad compleja, porque ninguno es preciso en todos los escenarios. En relación a estos criterios, se realizó un análisis de los diferentes tipos de ANN utilizadas en la literatura para pronosticar las producciones de leche bovina, con la finalidad de identificar la ANN con mejores resultados en esta actividad.

Los autores R. S. Gandhi et al. (2010), compararon el desempeño del MLP y el análisis de regresión múltiple (MRA, por sus siglas en inglés) para pronosticar las producciones de leche del ganado de la raza Sahiwal. R. S. Gandhi et al. (2010), evidenciaron que el MLP obtuvo valores de RMSE y R^2 superiores a MRA.

Njubi et al. (2010), analizaron la efectividad del MLP y la regresión lineal múltiple (MLR, por sus siglas en inglés), para pronosticar el rendimiento lechero mensual durante los 305 días del primer período de lactancia del ganado de la raza Holstein Friesian en Kenya. Estos autores determinaron que el pronóstico mediante el MLP alcanzó indicadores de RMSE y R^2 consistentemente superiores al pronóstico mediante la MLR.

En su investigación Dongre et al. (2012), evaluaron la eficiencia de una ANN de tipo MLP y un modelo basado en MLR para pronosticar la producción lechera del ganado de la raza Sahiwal durante los 305 días de su primer período de lactancia. Dongre et al. (2012), concluyeron que el pronóstico realizado por la ANN fue más eficiente, evidenciando una exactitud superior al 80%.

En su estudio Gorgulu (2012), analizó la capacidad de una ANN de tipo MLP para predecir la producción de leche durante 305 días del período de lactancia temprana del ganado suizo pardo. Este autor evaluó el rendimiento de la ANN respecto a la MLR y demostró que los valores medios pronosticados por la ANN se aproximaron a los valores medios reales sin mostrar diferencias estadísticamente significativas.

Boniecki et al. (2013), demostraron en su investigación que las ANN de tipo MLP constituyen herramientas efectivas para pronosticar las producciones lecheras a corto plazo del ganado de la raza Holstein Friesian en Polonia.

Panigrahi et al. (2013), evaluaron el rendimiento de tres tipos de ANN para el pronóstico de series de tiempo relacionadas con la producción mensual de leche y los índices de empleo en Wisconsin. Estos autores compararon el desempeño de tres MLP mediante diferentes métodos de aprendizaje: retro propagación, algoritmos genéticos, y algoritmos evolutivos diferenciales. Panigrahi et al. (2013), determinaron que la ANN combinada con el algoritmo evolutivo diferencial obtuvo mejores resultados en esta actividad.

Manoj et al. (2014), desarrollaron un estudio donde compararon la efectividad de una ANN de tipo MLP y un modelo basado en MLR en el pronóstico de las producciones lecheras durante los primeros 305 días del período de lactancia temprana del ganado de la raza Sahiwal. Los valores de RMSE y de R^2 alcanzados por la ANN fueron superiores al modelo basado en MLR (Manoj et al., 2014).

Los autores S. K. Sharma y Kumar (2014), identificaron que mediante una ANN de tipo MLP es posible realizar el pronóstico del rendimiento lechero total del ganado con indicadores mínimos de error y un coeficiente de correlación máximo próximo a 1, respecto a sus valores productivos reales.

Murphy et al. (2014), implementaron una NARX para pronosticar el rendimiento lechero diario del rebaño de la raza Holstein Friesian de una granja en Irlanda. Los autores Murphy et al. (2014), evaluaron el desempeño de la NARX respecto a una ANN de tipo MLP y un modelo basado en MLR. Según estos autores, el pronóstico realizado mediante la NARX para un período de 305; 50; 30, y 10 días alcanzó valores de RMSE= (8.59; 8.1; 6.77; 5.84), respectivamente, superior a la ANN de tipo MLP, que mostró valores de RMSE= (12.03; 12.15; 11.74; 10.7), y al modelo basado en MLR con valores de RMSE= (10.62; 10.68; 10.62; 10.54).

Bhosale y Singh (2015), compararon el rendimiento de dos modelos basados en MLR y en una ANN de tipo MLP, respectivamente, para pronosticar la producción lechera del ganado de raza Frieswal durante los primeros 305 días de su período de lactancia. Estos autores determinaron que el modelo basado en la ANN obtuvo un valor de R^2 de 85.07 %, superior al modelo basado en MLR.

F. Zhang et al. (2016), desarrollaron un Sistema para la Optimización del Pronóstico de la Producción de Leche (MPFOS, por sus siglas en inglés), con el fin de comparar la exactitud de múltiples modelos en el pronóstico de la producción de leche de un rebaño lechero irlandés. MPFOS se compuso de 9 modelos de pronóstico basados en funciones polinómicas (adaptativas, Ali-Schaeffer y Legendre), ecuaciones cuadráticas logarítmicas, curvas diferenciales cúbicas, función de ajuste de superficies, MLR, ANN-MLP y NARX, respectivamente (F. Zhang et al., 2016). El análisis comparativo realizado por estos autores permitió identificar que aunque la ANN-MLP obtuvo resultados aceptables, los pronósticos más precisos se obtuvieron mediante la función de ajuste de superficies y la NARX, respectivamente.

Sugiono et al. (2016) y Sugiono et al. (2017), evidenciaron que la aplicación de un algoritmo genético para fortalecer el aprendizaje de un MLP, permitió realizar eficientemente el pronóstico de las producciones lecheras del ganado de la raza Holstein Friesian con un valor de MSE inferior a 0.0035.

Dongre et al. (2017), demostraron que las producciones lecheras del ganado de la raza Deoni pueden ser pronosticadas eficientemente mediante una ANN de tipo MLP, con valores de R^2 superiores al 89% y de RMSE inferiores a 0.139.

Los autores Bhosale y Singh (2017), identificaron que el empleo de una ANN de tipo MLP permitió pronosticar las producciones lecheras del ganado de la raza cruzada Holstein Friesian con indicadores de rendimientos superiores a un modelo basado en MLR. Estos autores determinaron que el pronóstico mediante la ANN obtuvo valores de $R^2= 71.18\%$ y $RMSE=0.527$, superiores a la MLR que alcanzó resultados de 53.03% y 10.13, respectivamente.

Gorgulu (2018), evaluó el desempeño de una red ANFIS para predecir la producción de leche del ganado de la raza Jersey en Turquía. Según Gorgulu (2018), el pronóstico realizado con la red ANFIS demostró índices de rendimientos aceptables, con valores de $RMSE=0.576$ y $R^2=0.865\%$, durante el período de pruebas.

Oyegbile et al. (2018), compararon el rendimiento de la MLR, una ANN-MLP y un algoritmo de función genética para el pronóstico del rendimiento lechero durante 305 días del ganado de las razas Holstein, Jersey, Simmental, Suizo Pardo, Holstein x Bunaji y Jersey x Bunaji, en las condiciones ambientales de diferentes granjas en Nigeria. Según Oyegbile et al. (2018), la ANN-MLP mostró una precisión adecuada en los distintos entornos de análisis.

Machado Dallago et al. (2019), evaluaron tres modelos de pronóstico basados en MLR, árboles aleatorios (RF, por sus siglas en inglés) y en una ANN de tipo MLP respectivamente, para predecir el rendimiento lechero durante los días de prueba de vacas primíparas de la raza Holstein. Según Machado Dallago et al. (2019), los tres modelos demostraron una capacidad predictiva aceptable, sin embargo, la ANN obtuvo mejores índices de desempeño.

Akilli y Atil (2020), identificaron que una ANN-MLP con datos de entrada normalizados mediante la técnica de escala decimal y entrenada con el método de Regularización Bayesiana, permitió efectuar el pronóstico del rendimiento lechero del ganado de la raza Holstein Friesian con valores de R^2 superiores al 81% y de RMSE inferiores a 0.0069.

En su estudio, los autores Radwan et al. (2020) analizaron las capacidades de dos modelos basados en una ANN-MLP y en un método de análisis discriminante (DA, por sus siglas en inglés), respectivamente, para la clasificación y el pronóstico de los índices de rendimiento lechero del ganado de la raza Holstein Friesian. Los resultados obtenidos por Radwan et al. (2020), indicaron que la ANN-MLP obtuvo resultados superiores al modelo basado en DA.

Liseune et al. (2020), desarrollaron un modelo que combinó una red autocodificadora secuencial y una CNN para estimar las producciones diarias de leche durante 305 días del período de lactancia del ganado. Los autores Liseune et al. (2020), compararon la exactitud de su propuesta respecto a un MLP y determinaron que la combinación de la red autocodificadora secuencial y la CNN obtuvo valores de $RMSE=5.68$, $MAPE=0.17$ y $R^2=0.63$, superiores al MLP que mostró valores de $RMSE=6.77$, $MAPE=0.18$ y $R^2=0.48$.

Usman et al. (2020) y Singh et al. (2020), determinaron en sus investigaciones que las ANN de tipo MLP entrenadas mediante la Regularización Bayesiana permitieron pronosticar el rendimiento lechero durante los primeros 305 días del período de lactancia de los rebaños de ganado bovino cruzado Vrindavani y bufalino de la raza Murrah, respectivamente, con un valor de R^2 superior al 80%.

Liseune et al. (2021), propusieron un modelo para predecir íntegramente la curva de lactancia del ganado lechero mediante la combinación de una red autocodificadora secuencial, una CNN y un MLP. Liseune et al. (2021), evaluaron la efectividad de su propuesta respecto a tres modelos matemáticos. Según estos autores, el modelo propuesto obtuvo de forma general un error absoluto de 5.58 kg entre las predicciones de la producción diaria de leche y los valores reales, y un error de predicción del 11%, valor inferior al modelo matemático de referencia con mejores índices de rendimientos.

En las investigaciones consultadas se evidenció que las ANN *feedforward*, principalmente las ANN de tipo MLP, mostraron índices de rendimiento adecuados en el pronóstico de las producciones de leche, superior a técnicas como la MLR, MRA, y los RF. Sin embargo, se identificaron algunas publicaciones donde se demostró que el desempeño del MLP fue superado por las CNN y las NARX.

4 Conclusiones y trabajo futuro

Los resultados obtenidos en la presente investigación permitieron identificar que las ANN con arquitectura *feedforward* multicapas fueron ampliamente utilizadas para pronosticar las producciones de leche bovina durante el período 2010-2021. Se evidenció que el aprendizaje supervisado mediante métodos de retro propagación como la Regularización Bayesiana y el Gradiente Conjugado Escalonado fueron los más empleados en las fuentes consultadas.

Las principales variables de entrada utilizadas en la literatura se relacionaron con los datos de la etapa de lactancia del ganado, sus características fisiológicas y sus índices de producción de leche durante los períodos de prueba. Asimismo, se identificó que en las publicaciones analizadas se emplearon un promedio de 9 variables en la capa de entrada de las ANN para realizar los pronósticos de las producciones de leche bovina. Las funciones de activación más aplicadas en las ANN identificadas fueron *tanh* y *purelin*, respectivamente.

Se evidenció que la retención fue el enfoque de evaluación predominante y que los métodos más utilizados para comprobar la exactitud en los pronósticos fueron RMSE y R2. Aunque las ANN de tipo MLP mostraron índices de desempeño adecuados, las CNN y las NARX obtuvieron rendimientos superiores en el pronóstico de las producciones de leche bovina. Sin embargo, el estudio y aplicación de estos tipos de ANN en el sector de la industria láctea aún es incipiente, situación que denota una línea para el desarrollo de futuras investigaciones.

Identificar las características y el tipo de ANN con mejores rendimientos en el pronóstico de las producciones de leche bovina posibilitará potenciar el desarrollo de modelos de inteligencia artificial para apoyar la toma de decisiones en instalaciones productoras de leche. Según S. Sharma et al. (2020), son escasas las investigaciones sobre la influencia que poseen las funciones de activación en el desempeño de las ANN. Próximos trabajos pueden centrar su análisis en el desempeño de ANN recurrentes en el pronóstico de las producciones de leche, así como evaluar la influencia de diferentes arquitecturas, métodos de aprendizaje y de funciones lineales y no lineales de activación en los rendimientos de estas ANN. También, se propone incluir como parte de las variables de entrada en ANN recurrentes datos climáticos de la localidad donde se desarrolla el ganado, en aras de verificar su incidencia en la exactitud de los pronósticos. Se sugiere, además, emplear enfoques de validación cruzada para comprobar los rendimientos de estas redes neuronales con un mismo conjunto de datos.

Declaración de conflicto de intereses

Los autores declaran no tener conflicto de intereses con respecto a la investigación, autoría o publicación de este artículo.

Financiación

Los autores no recibieron apoyo financiero para la investigación, autoría y/o publicación de este artículo.

ORCID iD

Rudibel Perdigón-Llanes  <https://orcid.org/0000-0001-7288-6224>

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

Referencias

- Akilli, A., & Atil, H. (2020). Evaluation of Normalization Techniques on Neural Networks for the Prediction of 305-Day Milk Yield. *Turkish Journal of Agricultural Engineering Research*, 354–367. <https://doi.org/10.46592/turkager.2020.v01i02.011>
- Atil, H., & Akilli, A. (2016). Comparison of artificial neural network and K-means for clustering dairy cattle. *International Journal of Sustainable Agricultural Management and Informatics*, 2, 40. <https://doi.org/10.1504/IJSAMI.2016.077266>
- Banerjee, G., Sarkar, U., Das, S., Das, S., & Ghosh, I. (2018). Artificial Intelligence in Agriculture: A Literature Survey. *International Journal of Scientific Research in Computer Science Applications and Management Studies*, 7(3), 1–6.
- Bhosale, M. D., & Singh, T. P. (2015). Comparative study of feed-forward neuro-computing with multiple linear regression model for milk yield prediction in dairy cattle. *Current Science*, 108(12), 2257–2261.
- Bhosale, M. D., & Singh, T. P. (2017). Development of Lifetime Milk Yield Equation Using Artificial Neural Network in Holstein Friesian Cross Breddairy Cattle and Comparison with Multiple Linear Regression Model. *Current Science*, 113(05), 951. <https://doi.org/10.18520/cs/v113/i05/951-955>
- Boniecki, P., Lipiński, M., Koszela, K., & Przybył, J. (2013). Neural prediction of cows' milk yield according to environment temperature. *African Journal of Biotechnology*, 12(29).
- Chaturvedi, S., Gupta, A., Yadav, R., & Sharma, A. K. (2013). Life time milk amount prediction in dairy cows using artificial neural networks. *International Journal of Recent Research and Review*, 5, 1–6.
- Cockburn, M. (2020). Review: Application and Prospective Discussion of Machine Learning for the Management of Dairy Farms. *Animals*, 10(9). <https://doi.org/10.3390/ani10091690>
- da Silva, I. N., Hernane Spatti, D., Andrade Flauzino, R., Liboni, L. H. B., & dos Reis Alves, S. F. (2017). Artificial Neural Network Architectures and Training Processes. In I. N. da Silva, D. Hernane Spatti, R. Andrade Flauzino, L. H. B. Liboni, & S. F. dos Reis Alves (Eds.), *Artificial Neural Networks* (pp. 21–28). Springer International Publishing. https://doi.org/10.1007/978-3-319-43162-8_2
- Dongre, V., Gandhi, R. S., Singh, A., & Ruhil, A. P. (2012). 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*, 147(1), 192–197. <https://doi.org/10.1016/j.livsci.2012.04.002>
- Dongre, V., Kokate, L. S., Salunke, V., Durge, S., & Patil, V. (2017). Artificial Intelligence for Prediction of Standard Lactation Milk yield in Deoni Cattle. *International Journal of Livestock Research*, 1. <https://doi.org/10.5455/ijlr.20170806105856>
- Flores-Calero, M., Leppe, B., Pilla, M., Gualsaqui, M., Zabala-Blanco, D., & Albuja, A. (2021). Multiclasificación de arritmias cardíacas usando una red neuronal y la tarjeta MyRio-1900. *Inteligencia Artificial Revista Iberoamericana de Inteligencia Artificial*, 24, 129–146. <https://doi.org/10.4114/intartif.vol24iss67pp129-146>
- Gandhi, N., & Armstrong, L. J. (2016). A review of the application of data mining techniques for decision making in agriculture. *2016 2nd International Conference on Contemporary Computing and Informatics (IC3I)*, 1–6. <https://doi.org/10.1109/IC3I.2016.7917925>
- Gandhi, R. S., Monalisa, V. B., Ruhil, A. P., Singh, A., & Sachdeva, G. K. (2012). Prediction of first lactation 305-day milk yield based on weekly test day records using artificial neural networks in Sahiwal Cattle. *Indian Journal of Dairy Science*, 65(3), 229–233.

- Gandhi, R. S., Raja, T., Ruhil, A. P., & Kumar, A. (2010). Artificial Neural Network versus Multiple Regression Analysis for Prediction of Lifetime Milk Production in Sahiwal Cattle. *Journal of Applied Animal Research*, 38, 233–237. <https://doi.org/10.1080/09712119.2010.10539517>
- Gorgulu, O. (2012). Prediction of 305-day milk yield in Brown Swiss cattle using artificial neural networks. *South African Journal of Animal Science*, 42(3). <https://doi.org/10.4314/sajas.v42i3.10>
- Gorgulu, O. (2018). Prediction of 305 days milk yield from early records in dairy cattle using on Fuzzy Inference System. *The Journal of Animal & Plant Sciences*, 28(4), 996–1001.
- Grzesiak, W., Zaborski, D., Szatkowska, I., & Królaczyk, K. (2021). Lactation milk yield prediction in primiparous cows on a farm using the seasonal auto-regressive integrated moving average model, nonlinear autoregressive exogenous artificial neural networks and Wood's model. *Animal Bioscience*, 34(4), 770–782. <https://doi.org/10.5713/ajas.19.0939>
- Gupta, A., Salau, A. O., Chaturvedi, P., & Akinola, S. A. (2019). Artificial Neural Networks: Its Techniques and Applications to Forecasting. *2019 International Conference on Automation, Computational and Technology Management (ICACTM)*, 320–324. <https://doi.org/10.1109/ICACTM.2019.8776701>
- Jha, K., Doshi, A., Patel, P., & Shah, M. (2019). A comprehensive review on automation in agriculture using artificial intelligence. *Artificial Intelligence in Agriculture*, 2, 1–12. <https://doi.org/10.1016/j.aiaa.2019.05.004>
- Kamilaris, A., & Prenafeta Boldú, F. (2018). A review of the use of convolutional neural networks in agriculture. *The Journal of Agricultural Science*, 156, 1–11. <https://doi.org/10.1017/S0021859618000436>
- Kumar, H., & Hooda, B. (2014). Prediction of milk production using artificial neural network. *Current Advances in Agricultural Sciences*, 6(2), 173. <https://doi.org/10.5958/2394-4471.2014.00013.6>
- Lame, G. (2019). Systematic Literature Reviews: An Introduction. *Proceedings of the Design Society: International Conference on Engineering Design*, 1(1), 1633–1642. <https://doi.org/10.1017/dsi.2019.169>
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine Learning in Agriculture: A Review. *Sensors*, 18(8). <https://doi.org/10.3390/s18082674>
- Linnenluecke, M. K., Marrone, M., & Singh, A. K. (2019). Conducting systematic literature reviews and bibliometric analyses. *Australian Journal of Management*, 45(2), 175–194. <https://doi.org/10.1177/0312896219877678>
- Liseune, A., Salamone, M., van den Poel, D., Ranst, B., & Hostens, M. (2020). Leveraging latent representations for milk yield prediction and interpolation using deep learning. *Computers and Electronics in Agriculture*, 175, 105600. <https://doi.org/10.1016/j.compag.2020.105600>
- Liseune, A., Salamone, M., van den Poel, D., van Ranst, B., & Hostens, M. (2021). Predicting the milk yield curve of dairy cows in the subsequent lactation period using deep learning. *Computers and Electronics in Agriculture*, 180, 105904. <https://doi.org/10.1016/j.compag.2020.105904>
- Liu, Y., Ma, X., Shu, L., Hancke, G. P., & Abu-Mahfouz, A. M. (2021). From Industry 4.0 to Agriculture 4.0: Current Status, Enabling Technologies, and Research Challenges. *IEEE Transactions on Industrial Informatics*, 17(6), 4322–4334. <https://doi.org/10.1109/TII.2020.3003910>
- Machado Dallago, G., Figueiredo, D. M. de, Andrade, P. C. de R., Santos, R. A. dos, Lacroix, R., Santschi, D. E., & Lefebvre, D. M. (2019). Predicting first test day milk yield of dairy heifers. *Computers and Electronics in Agriculture*, 166, 105032. <https://doi.org/10.1016/j.compag.2019.105032>
- Manoj, M., Gandhi, R. S., Raja, T., Ruhil, A. P., Singh, A., & Gupta, A. K. (2014). Comparison of artificial neural network and multiple linear regression for prediction of first lactation milk yield using early body weights in Sahiwal cattle. *Indian Journal of Animal Sciences*, 84, 427–430.
- Murphy, M. D., O'Mahony, M. J., Shalloo, L., French, P., & Upton, J. (2014). Comparison of modelling techniques for milk-production forecasting. *Journal of Dairy Science*, 97(6), 3352–3363. <https://doi.org/10.3168/jds.2013-7451>
- Nayak, J., Vakula, K., Dinesh, P., Naik, B., & Pelusi, D. (2020). Intelligent food processing: Journey from artificial neural network to deep learning. *Computer Science Review*, 38, 100297. <https://doi.org/10.1016/j.cosrev.2020.100297>
- Nguyen, Q. T., Fouchereau, R., Frénod, E., Gerard, C., & Sincholle, V. (2020). Comparison of forecast models of production of dairy cows combining animal and diet parameters. *Computers and Electronics in Agriculture*, 170, 105258. <https://doi.org/10.1016/j.compag.2020.105258>
- Njubi, D., Wakhungu, J., & Badamana, M. S. (2011). Prediction of second parity milk yield of Kenyan Holstein-Friesian dairy cows on first parity information using neural network system and multiple linear regression methods. *Livestock Research for Rural Development*, 23.
- Njubi, D., Wakhungu, J. W., & Badamana, M. S. (2010). Use of test-day records to predict first lactation 305-day milk yield using artificial neural network in Kenyan Holstein-Friesian dairy cows. *Tropical Animal Health and Production*, 42(4), 639–644. <https://doi.org/10.1007/s11250-009-9468-7>
- Oyegbile, B., Akinsola, O., Obioma, O., Atanda, A., Paul, B., Oladipo, M., & Abba, Z. (2018). Neural Network and Regression Based Model for Cows' Milk Yield Prediction in Different Climatic Gradients. *Annual Research & Review in Biology*, 28, 1–9. <https://doi.org/10.9734/ARRB/2018/41947>
- Panigrahi, S., Karali, Y., & Behera, Dr. H. (2013). Time Series Forecasting using Evolutionary Neural Network. *International Journal of Computer Applications*, 75, 13–17. <https://doi.org/10.5120/13146-0553>
- Peña-Rueda, Y., Benítez, D., Ray, J. v., & Fernández-Romay, Y. (2018). Determinant factors of livestock production in a rural community in the southwest of Holguín, Cuba. *Literature-Film Quarterly*, 52.

- Perdigón Llanes, R., & González Benítez, N. (2020). Una revisión bibliográfica sobre modelos para predecir las producciones de leche. *Revista Ingeniería Agrícola*, 10(4).
- Perdigón Llanes, R., & González Benítez, N. (2021). *Comparación y selección de técnicas de inteligencia artificial para pronosticar las producciones de leche bovina*. 15.
- Pimpa, A., Eiamkanitchat, N., Phatsara, C., & Moonmanee, T. (2019). Decision Support System for Dairy Cattle Management Using Computational Intelligence Technique. *Proceedings of the 2019 7th International Conference on Computer and Communications Management*, 181–185. <https://doi.org/10.1145/3348445.3348449>
- Radwan, H., el Qaliouby, H., & Elfadl, E. A. (2020). Classification and prediction of milk yield level for Holstein Friesian cattle using parametric and non-parametric statistical classification models. *Journal of Advanced Veterinary and Animal Research*, 7(3), 429–435. <https://doi.org/10.5455/javar.2020.g438>
- Ruelle, E., Delaby, L., & Shalloo, L. (2019). Linkage between predictive transmitting ability of a genetic index, potential milk production, and a dynamic model. *Journal of Dairy Science*, 102. <https://doi.org/10.3168/jds.2018-15197>
- Saefullah, A., Hendri, M., Lindawati, S., Badaruddin, M., & Hutahaean, J. (2020). Analysis of Deep Learning Cyclical order for Prediction of Fresh Milk Production in Sumatera. *Journal of Physics: Conference Series*, 1566, 12087. <https://doi.org/10.1088/1742-6596/1566/1/012087>
- Sharma, S. K., & Kumar, E. (2014). Anticipating milk yield using artificial neural network. *Int. Journal of Applied Sciences and Engineering Research*, 3, 690–695. <https://doi.org/10.6088/ijaser.030300013>
- Sharma, S., Sharma, S., & Athaiya, A. (2020). Activation functions in neural networks. *International Journal of Engineering Applied Sciences and Technology*, 04(12), 310–316. <https://doi.org/10.33564/IJEAST.2020.v04i12.054>
- Singh, N. P., Usman, S., Maurya, V., Dutt, T., Bhatt, N., & Kumar, A. (2020). Comparative analysis of artificial neural network algorithms for prediction of FL305DMY in Murrah buffalo. *International Journal of Livestock Research*, 1. <https://doi.org/10.5455/ijlr.20200704062936>
- Slob, N., Catal, C., & Kassahun, A. (2020). Application of Machine Learning to Improve Dairy Farm Management: A Systematic Literature Review. *Preventive Veterinary Medicine*, 187, 105237. <https://doi.org/10.1016/j.prevetmed.2020.105237>
- Sugiono, S., Soenoko, R., & Andriani, D. (2016). *Analysis the relationship of physiological, environmental, and cow milk productivity using AI*. <https://doi.org/10.1109/ICODSE.2016.7936165>
- Sugiono, S., Soenoko, R., & Riawati, L. (2017). Investigating the Impact of Physiological Aspect on Cow Milk Production Using Artificial Intelligence. *International Review of Mechanical Engineering (I.R.E.M.E.)*, 11, 7.
- Torres-Inga, C. S., López-Crespo, G., Guevara-Viera, R., Narváez-Terán, J., Serpa-García, V. G., Guzmán-Espinoza, C. K., Guevara-Viera, G., & de Juana, Á. J. (2019). Eficiencia técnica en granjas lecheras de la Sierra Andina mediante modelación con redes neuronales. *Revista de Producción Animal*, 31(1), 11–17.
- Usman, M., Singh, N. P., Dutt, T., Tiwari, R., & Kumar, A. (2020). Comparative study of artificial neural network algorithms performance for prediction of FL305DMY in crossbred cattle. *Journal of Entomology and Zoology Studies*, 8, 516–520.
- Winkowski, C. (2019). Classification of forecasting methods in production engineering. *Engineering Management in Production and Services*, 11(4), 23–33.
- Yan, W. J., Chen, X., Akcan, O., Lim, J., & Yang, D. (2015). Big data analytics for empowering milk yield prediction in dairy supply chains. *2015 IEEE International Conference on Big Data (Big Data)*, 2132–2137. <https://doi.org/10.1109/BigData.2015.7363997>
- Zhang, F., Murphy, M. D., Shalloo, L., Ruelle, E., & Upton, J. (2016). An automatic model configuration and optimization system for milk production forecasting. *Computers and Electronics in Agriculture*, 128, 100–111. <https://doi.org/10.1016/j.compag.2016.08.016>
- Zhang, F., Upton, J., Shalloo, L., & Murphy, M. D. (2019). Effect of parity weighting on milk production forecast models. *Computers and Electronics in Agriculture*, 157, 589–603. <https://doi.org/10.1016/j.compag.2018.12.051>
- Zhang, F., Upton, J., Shalloo, L., Shine, P., & Murphy, M. D. (2020). Effect of introducing weather parameters on the accuracy of milk production forecast models. *Information Processing in Agriculture*, 7(1), 120–138. <https://doi.org/10.1016/j.inpa.2019.04.004>
- Zhang, W., Yang, K., Yu, N., Cheng, T., & Liu, J. (2020). Daily milk yield prediction of dairy cows based on the GA-LSTM algorithm. *2020 15th IEEE International Conference on Signal Processing (ICSP)*, 1, 664–668. <https://doi.org/10.1109/ICSP48669.2020.9320926>