



UNIVERSIDAD AUTÓNOMA CHAPINGO

**CENTRO DE INVESTIGACIONES ECONÓMICAS, SOCIALES Y
TECNOLÓGICAS DE LA AGROINDUSTRIA Y LA AGRICULTURA MUNDIAL**

MAESTRÍA EN CIENCIAS EN ESTRATEGIA AGROEMPRESARIAL

**REDES NEURONALES ARTIFICIALES PARA LA PREDICCIÓN DE PRECIOS
DE LA LECHE EN MÉXICO**

TESIS

Que como requisito parcial para obtener el grado de:

MAESTRO EN CIENCIAS EN ESTRATEGIA AGROEMPRESARIAL



Presenta:

ITZELLY SÁNCHEZ RAFAEL

Bajo la supervisión de:

DR. FERNANDO CERVANTES ESCOTO

DRA. RAQUEL SALAZAR MORENO



Chapingo, Estado de México, a 15 de noviembre 2023

REDES NEURONALES ARTIFICIALES PARA LA PREDICCIÓN DE PRECIOS DE LA LECHE EN MÉXICO

Tesis realizada por **Itzelly Sánchez Rafael**, bajo la dirección del Comité Asesor indicado, aprobada por el mismo y aceptada como requisito parcial para obtener el grado de:

MAESTRO EN CIENCIAS EN ESTRATEGIA AGROEMPRESARIAL

DIRECTOR:



DR. FERNANDO CERVANTES ESCOTO

CO-DIRECTOR:



DRA. RAQUEL SALAZAR MORENO

ASESOR:



DR. J REYES ALTAMIRANO CÁRDENAS

ASESOR:



DR. JOSÉ ALFREDO CESÍN VARGAS

CONTENIDO

ABREVIATURAS USADAS	VI
DEDICATORIA	VII
AGRADECIMIENTOS.....	VIII
DATOS BIOGRÁFICOS.....	IX
RESUMEN GENERAL	X
ABSTRACT.....	XI
1. INTRODUCCIÓN.....	1
1.1. Planteamiento del problema.....	2
1.2. Objetivos de la investigación.....	3
1.2.1. Objetivo general	4
1.2.2. Objetivos específicos.....	4
1.3. Preguntas de investigación	4
1.4. Hipótesis	4
2. MARCO TEÓRICO	5
2.1. Mercado de la leche.....	5
2.2. Predicción de precios.....	6
2.3. Redes neuronales artificiales	7
3. MARCO REFERENCIAL	10
3.1. Contexto Internacional de la leche	10
3.2. Contexto Nacional de la leche.....	14

3.3.	Usos de las redes neuronales artificiales	15
4.	MATERIALES Y MÉTODOS.....	18
4.1.	Objeto de estudio	18
4.1.1.	Obtención de datos.....	19
4.1.2.	Análisis exploratorio de los datos	19
4.1.3.	Matriz de correlación	20
4.2.	Modelo de redes neuronales artificiales	20
4.2.1.	Arquitectura de la Red Neuronal Artificial	20
4.2.2.	Algoritmo de aprendizaje	21
4.2.3.	Entrenamiento, validación y prueba de la red neuronal.....	22
4.2.4.	Medidas de desempeño de la red	22
4.2.5.	Análisis de Sensibilidad	23
5.	RESULTADOS Y DISCUSIÓN	24
5.1.	Contexto nacional de la producción de leche en México	24
5.1.1.	Regionalización	24
5.1.2.	Producción.....	26
5.1.3.	Importaciones	27
5.2.	Análisis exploratorio	28
5.2.1.	Correlación de variables	29
5.2.2	Entrenamiento, validación y prueba.....	30
6.	CONCLUSIONES	33
	LITERATURA CITADA	34

ANEXOS	38
--------------	----

Anexo 1. Código elaborado para la programación de la Red Neuronal Artificial	38
--	----

Lista de cuadros

Cuadro 1. Países de latinoamérica y el caribe (lac) con mayor volumen de exportación en el periodo 2017-2019. Valor expresado en toneladas.	12
Cuadro 2. Principales países importadores de leche de vaca entera, en el período de 2017 a 2019.....	13
Cuadro 3. Variables relacionadas al precio medio rural de la leche en México	18
Cuadro 4. Regionalización de la producción de leche bovino.....	25
Cuadro 5. Estadística descriptiva.....	28

Lista de figuras

Figura 1. Arquitectura de una red neuronal. Perceptrón multicapa con 14 variables de entrada y 8 nodos en la capa oculta.....	8
Figura 2. Arquitectura de una red neuronal monocapa (izquierdo) y arquitectura de una red neuronal recurrente (derecho).	9
Figura 3. Principales países productores de leche entera de vaca en el período 2010 -2019.....	10
Figura 4. Los 20 países con mayor producción de leche entera de vaca en el mundo en 2019.....	11

Figura 5. Arquitectura de la red neuronal artificial implementada para predecir el precio de la leche.....	21
Figura 6. Producción de leche fluida de bovino en México de 1980 a 2021	26
Figura 7. Producción de leche fluida de bovino en la región templada en México de 1980 a 2021	26
Figura 8. Importaciones mexicanas de leche descremada y suero en polvo de 1980 a 2021	27
Figura 9. Matriz de correlación del precio de la leche con las variables relacionadas	29
Figura 10. Error cuadrado medio y eficiencia de la red, con el rango de nodos en la capa oculta entre 3 y 17	31
Figura 11. Simulación entre el precio real de la leche y el precio estimado por la red neuronal en la etapa de evaluación (2018-2021)	311
Figura 12. Análisis de sensibilidad para la RNA con 8 variables de entrada.....	32

ABREVIATURAS USADAS

ARIMA	Autoregressive Integrated Moving Average
CANILEC	Cámara Nacional de Industriales de la Leche
FAO	Food and Agriculture Organization
FEPALE	Federación Panamericana de Lechería
GARCH	Generalized Autoregressive Conditional Heteroskedasticity
INEGI	Instituto Nacional de Estadística y Geografía
INPC	Índice Nacional de Precios al Consumidor
LAC	Latinoamérica y el Caribe
MSE	Mean Squared Error
OCDE	Organización para la Cooperación y el Desarrollo Económico
PIB	Producto Interno Bruto
SAGARPA	Secretaría de Agricultura y Desarrollo Rural
SE	Secretaría de Economía
SIACON	Servicio de Información Agroalimentaria de Consulta
USDA	United States Department of Agriculture

DEDICATORIA

*Si camino sola, quizá llegue más rápido,
pero si camino acompañada,
tengo la certeza de que llegaré.*

A Dios, por la bendición de la vida y la dicha de una hermosa familia.

A mis padres, Celiflora Rafael Pérez y Juan Sánchez Gaytán; a mis hermanos: Nadia, Alan y Zaira Isabel; a mis adorados sobrinos J. Ernesto y Frida del Carmen; por ser mi ancla cuando me encuentro a la deriva. Los amo.

A mi hijo Julen, este es nuestro logro, es el resultado de nuestro esfuerzo y perseverancia; nos tocó extrañarnos unos días, pero hoy, estamos a un paso de iniciar un nuevo capítulo en nuestras vidas; No hay nada que no pueda lograr, si te tengo a mi lado. Te ama infinitamente, mamá.

A la memoria de mis padres de crianza, Juvencio Rafael Valdés † y Eva Pérez Ruiz †; porque sus enseñanzas han sido mi guía, sé que, ahora más que nunca, acompañan mis pasos. Eternamente los amo.

A mi abuelita, Eleodora Gaytán Rodríguez; a mis tíos, tías y primos de las familias Rafael Pérez y Sánchez Gaytán; a mis cuñadas, Nidia e Iris, gracias por tanto amor para conmigo y mi bebé.

A mis amigos; Alejandra, Rocío, Abril, Alonso, por compartir conmigo esta aventura; a Vianey, mi hermana de vida; a Tania, a Saraí por su cariño y comprensión; a Joyce, a J. Carlos, por su compañía en los momentos difíciles; Adrián, Day y Gab por su apoyo incondicional. Los quiero tanto.

A mis compañeros; Ángeles, Miguel, Medardo, Juan, Gus, Suleidy, Brenda. Por los momentos compartidos en las aulas. Todo el éxito para ustedes.

AGRADECIMIENTOS

A la **Universidad Autónoma Chapingo**, mi alma mater; al **Centro de Investigaciones Económicas, Sociales y Tecnológicas de la Agroindustria y la Agricultura Mundial**, por abrirme las puertas para continuar preparándome profesionalmente y contribuir significativamente al desarrollo del agro mexicano.

Al **Consejo Nacional de Humanidades Ciencias y Tecnología**, por el financiamiento otorgado para llevar a cabo este proyecto de investigación.

Al **Dr. Fernando Cervantes Escoto** por su acompañamiento, dedicación y apoyo para la realización de este trabajo.

A la **Dra. Raquel Salazar Moreno** por compartir sus conocimientos, apoyo y fortalecer los proyectos colaboración entre centros de investigación.


Al **Dr. J Reyes Altamirano Cárdenas**, por su atención, consejos y tiempo dedicado a la realización de este trabajo de investigación.

Al **Dr. José A. Cesín Vargas**, por compartir su conocimiento y experiencia a este proyecto, y fortalecer la colaboración entre Universidades.

Al **Dr. Jorge Aguilar Ávila**, por el apoyo y consejos que contribuyen a mi desarrollo personal y profesional.

A **todos los profesores**, mi reconocimiento a la labor que desempeñan con tanto compromiso, compartiendo su experiencia con profesionalismo. Así mismo, al **personal administrativo**; gracias por su apoyo y acompañamiento durante mi estancia en el centro.

DATOS BIOGRÁFICOS



Itzelly Sánchez Rafael nació el 21 de octubre de 1991 en San Sebastián Atoyaquillo, Tlaxiaco, Oaxaca. Es Ingeniero Agroindustrial por la Universidad Autónoma Chapingo, generación 2009 – 2014, titulada por tesis en marzo de 2018. Durante sus estudios de licenciatura realizó su estancia profesional en la Universidad de Cartagena, España, participando en un proyecto de investigación de mejoramiento genético de melón piel de Sapo (*Cucumis melo*).

De noviembre de 2016 a febrero 2017, fungió como Prestador de Servicios Profesionales en la Asociación Nacional de Egresados de Chapingo en Oaxaca, mediante el proyecto “Transferencia a productores de innovaciones tecnológicas agropecuarias y acuícolas existentes en instituciones de enseñanza e investigación, con alto potencial productivo”. Mas tarde, se desempeñó como responsable del área de Gestión de créditos y cobranza en la comercializadora de tractores MAQUINALIKA S.A. de C.V.

En los años 2021 al 2023 fue estudiante de la Maestría en Ciencias en Estrategia Agroempresarial en el Centro de Investigaciones Económicas, Sociales y Tecnológicas de la Agroindustria y la Agricultura Mundial (CIESTAAM) de la Universidad Autónoma Chapingo. En abril de 2023 participó como ponente en la XLVIII Reunión Científica de la Asociación Mexicana para la Producción Animal Y Seguridad Alimentaria A.C. y la XVII Reunión de la Asociación Latinoamericana de Producción Animal.

RESUMEN GENERAL

REDES NEURONALES ARTIFICIALES PARA LA PREDICCIÓN DE PRECIOS DE LA LECHE EN MÉXICO¹

Por su alto valor nutricional, la leche es un alimento esencial para el desarrollo humano; por ello es un producto que toma relevancia cuando se habla de soberanía alimentaria en las naciones. En México, el sector lácteo representa la tercera actividad más importante en la industria de los alimentos, siendo uno de los grandes impulsores de la economía nacional; sin embargo, no es autosuficiente en la demanda de este producto, por ello, es preciso que se implementen políticas encaminadas al fortalecimiento y transparencia en la determinación de precio de la leche, que permitan elevar la competitividad del producto en el mercado internacional. Las redes neuronales artificiales son una tecnología emergente y quizá el mejor ejemplo de los alcances de la inteligencia artificial. Su aplicación es diversa en las diferentes áreas de la ciencia, incluida la economía. En esta investigación se implementó un modelo de redes neuronales artificiales, para predecir los precios de la leche en México, utilizando datos de 1980 a 2021. El propósito fue analizar el impacto en la predicción, de variables relacionadas al precio nacional de leche de vaca. El modelo demostró tener un alto poder predictivo. Se pudo comprobar la utilidad de las redes neuronales artificiales para la predicción de precios, ya que se obtuvieron resultados muy cercanos a los verídicos. Se resalta también la capacidad que tiene para ponderar el impacto de productos y factores relacionados al precio del producto estudiado, como son los precios de los granos y otros derivados lácteos.

Palabras clave: inteligencia artificial, redes neuronales artificiales, predicción, precios, leche.

¹Tesis de Maestría en Ciencias en Estrategia Agroempresarial, Universidad Autónoma Chapingo
Autor: Itzelly Sánchez Rafael
Director de tesis: Dr. Fernando Cervantes Escoto

ABSTRACT

ARTIFICIAL NEURAL NETWORKS FOR THE FORECASTING OF MILK PRICES IN MÉXICO¹

Milk is an essential food for human development, due to its high nutritional value. For this reason, it is a product that becomes relevant when talking about food sovereignty in nations. In Mexico, dairy sector represents the third most important activity in the food industry, being one of the great drivers of the national economy. However, it is not self-sufficient in the demand for this product, therefore, it is necessary to implement policies aimed at strengthening and transparency in the determination of milk prices, which allow to increase the competitiveness of the product in the international market. Artificial neural networks are an emerging technology and perhaps the best example of the scope of artificial intelligence. Its application is diverse in different areas of science, including economics. In this research, an artificial neural network model was implemented to predict milk prices in Mexico, using data from 1980 to 2021. The purpose was to analyze the impact of variables related to the national price of cow's milk. The model proved to have high predictive power in milk price. It was possible to verify the usefulness of artificial neural networks for the prediction of real prices, where results very close to reality were obtained. The ability to weigh the impact of products and factors related to the price of the product studied, such as grains and other dairy derivatives, is also highlighted.

Keywords: Artificial intelligence, artificial neural networks, prediction, prices, milk.

¹Tesis de Maestría en Ciencias en Estrategia Agroempresarial, Universidad Autónoma Chapingo

Autor: Itzelly Sánchez Rafael

Director de tesis: Dr. Fernando Cervantes Escoto

1. INTRODUCCIÓN

Dentro del sector ganadero, la producción de leche es una actividad fundamental en la seguridad alimentaria de las regiones donde se lleva a cabo. En la actualidad, gran parte del consumo de lácteos se concentra en los países industrializados, esto, debido al poder adquisitivo y elevado consumo per cápita que tienen. Sin embargo, el rápido crecimiento poblacional en los países en vías de desarrollo ha contribuido a que su participación, en la producción de leche, se haya incrementado en las últimas décadas (de Groot, 2018; SE, 2012).

En el mundo, un gran número de países, consideran la producción y abasto de leche como una prioridad nacional, razón por la cual, establecen políticas de alto proteccionismo para este sector. De acuerdo con información del Dairy World Markets and Trade (USDA, 2021), países desarrollados como algunos miembros de la Unión Europea o Estados Unidos, producen un gran volumen de leche, por lo que sus excedentes terminan vendiéndolos en el mercado internacional con grandes subsidios, distorsionando fuertemente los precios del producto en el mercado mundial.

En este sentido, México recurre a la importación de una parte de dichos excedentes (principalmente de Estados Unidos), para satisfacer la demanda interna, debido a que la producción nacional es insuficiente; este efecto económico provoca que el precio al productor disminuya y pierda su capacidad de negociación en el mercado (Brambila-Paz et al., 2013; SE, 2012).

Aguilar & López (2006) mencionan que, los factores que influyen en el desempeño de la producción de leche en México son; las políticas de gobierno, la sanidad, los sistemas administrativos, de organización y la adopción de tecnologías en los sistemas pecuarios.

Por su parte, en Estados Unidos, la base del crecimiento del sector lechero en este país fue fijar políticas que determinan barreras a la importación y subsidios a la exportación, poniendo énfasis en sostener el precio de la leche y apoyar a las granjas lecheras así como precios adecuados para el productor, lo que les permite capitalizarse (García et al., 1997; Wolf & Widmar, 2015).

Por lo anterior, es preciso que en México se implementen políticas encaminadas al fortalecimiento y transparencia en la determinación del precio de la leche al productor.

De acuerdo con Vicentin & García (2017), contar con estimaciones sobre la evolución futura de los precios en el sector lechero, ayudaría en la toma de decisiones, tanto productivas como de inversiones, pues se estarían realizando con base en escenarios probables; por lo tanto, disponer de herramientas confiables de predicción para dichos precios, sería de suma utilidad para todos los agentes que participan en la cadena de valor.

1.1. Planteamiento del problema

En el mercado de los lácteos, este año y los venideros serán de incertidumbre y volatilidad. La afectación en el consumo de la leche y sus subproductos por el menor poder adquisitivo de la población, así como, los mayores costos de las empresas, los efectos del nuevo etiquetado frontal, los precios más elevados de granos y forrajes y el comportamiento del sector externo son algunos factores determinantes para la producción nacional.

Los lácteos, siendo bienes con una demanda elástica con respecto al precio y al ingreso, sin duda, se verán afectados puesto que, dada la situación, un segmento importante de la población adquirirá, como criterio principal de compra, los productos de menor precio, más allá de la calidad del alimento.

Tener predicciones confiables, permite tomar decisiones con menor grado de incertidumbre, y esto es muy importante para los agentes que interactúan en el sector, dado que permitirá una planificación más fundamentada de sus actividades.

En este sentido, es de relevancia en el área económica, tener pronósticos certeros del comportamiento del precio de un producto y en este caso, del sector lácteo en particular (Vicentin & García, 2017).

En los últimos años, la gestión del conocimiento y el procesamiento masivo de información ha cobrado relevancia en el sector empresarial, debido principalmente, a la forma en la que las organizaciones gestionan dicho conocimiento y procesan la información utilizando nuevas herramientas tecnológicas; ejemplo de ello, es el uso de técnicas de Inteligencia Artificial, que han dejado clara la necesidad de contar con soportes de ayuda robustos, para tomar decisiones en la actividad empresarial (Sosa, 2007).

En este sentido, aplicar técnicas de Inteligencia Artificial para pronosticar el comportamiento del precio de la leche, puede ser un tema de interés para la comunidad científica. Definir cuál método es mejor, es todavía incierto, lo que se puede afirmar es que existe evidencia a favor de las redes neuronales artificiales en el área financiera, en comparación con los modelos estadísticos tradicionales, así mismo, que éstas pueden emplearse como herramientas complementarias para tener cierto grado de comparación y definir las condiciones óptimas para el caso de estudio, la leche en México.

1.2. Objetivos de la investigación

En el siguiente apartado se muestra el objetivo general, y a continuación los específicos de la investigación.

1.2.1. Objetivo general

Implementar un modelo de redes neuronales artificiales para predecir los precios de la leche en México.

1.2.2. Objetivos específicos

Identificar los factores relacionados a los precios de la leche en México.

Pronosticar precios de la leche utilizando un modelo de redes neuronales artificiales.

Plantear estrategias en materia de política pública orientadas a la toma de decisiones por los actores involucrados.

1.3. Preguntas de investigación

Las preguntas que se responden en esta investigación son las siguientes:

¿Cuál es la situación actual de la actividad lechera en México?

¿Son las redes neuronales artificiales una alternativa para el pronóstico de precios de la leche?

¿Cuáles son las estrategias que podrían aplicarse en las diferentes etapas de la cadena de valor de la leche conociendo el pronóstico de precios?

1.4. Hipótesis

Los factores socio- económicos, políticos, medioambientales y el comercio internacional, influyen la determinación de los precios de la leche en México.

Las redes neuronales artificiales, son un método fiable para la predicción de precios.

Considerando la predicción de precios de la leche, es posible diseñar políticas públicas para el fortalecimiento del sector lácteo en México.

2. MARCO TEÓRICO

2.1. Mercado de la leche

La leche es un producto alimentario que forma parte de la canasta básica familiar, su rico valor nutricional la hace un alimento de primera necesidad para el desarrollo humano y especialmente para la población infantil, por ello, es importante en el desarrollo de programas sociales que tienen por objetivo la seguridad alimentaria a nivel mundial.

Específicamente, como menciona en su informe (FEPALE, 2021), en América Latina la producción y consumo de lácteos, tienen un rol muy importante en la economía y la alimentación de la población, debido al fuerte arraigo en la cultura local, además de que constituye un componente accesible y económico en la dieta de las poblaciones.

La mayor parte de la producción de leche se destina para la elaboración de productos como quesos, yogures y mantequilla. De acuerdo con OCDE & FAO, (2020), se espera que durante esta década aumente 1.2 % anual el consumo mundial de los productos lácteos frescos, promovido principalmente por un crecimiento del ingreso per cápita de los consumidores.

Cabe considerar que el papel de México, como oferente en el mercado mundial de la leche es incipiente, no es autosuficiente en su producción y actualmente es el mayor importador de leche en polvo, siendo su principal proveedor Estados Unidos (Dávalos, 2020).

En México, las empresas cooperativas Lala y Alpura, son las más relevantes en el mercado nacional, ya que mantienen un precio comparativo elevado por la materia prima; además, estas empresas han fomentado la modernización de los establos que les proveen materia prima, mejoras orientadas, principalmente, a estrictos controles de calidad. Sin embargo, el grueso de productores que, en su mayoría son pequeños, tratan de acceder a mejores niveles tecnológicos sin mucho éxito (García, 2001).

De acuerdo con el Banco Mundial, (2021); particularmente, los precios de los productos alimentarios básicos han aumentado sustancialmente a raíz de la disminución de la oferta en América del Sur y la fuerte demanda de China. Sin embargo, se prevé que los precios se estabilicen puesto que la mayor parte de los mercados mundiales de alimentos básicos siguen estando adecuadamente abastecidos en comparación con los niveles históricos.

2.2. Predicción de precios

Predecir es fundamental en cualquier nivel del proceso productivo puesto que las predicciones se pueden incorporar para la toma de decisiones inteligentes. Estas proyecciones se elaboran para periodos concretos que pueden ser días específicos, semanas o meses (Moreno, 2008).

En este sentido, estimar precios permiten tanto a productores, comercializadores e industriales poder planificar y gestionar estrategias para protegerse o aprovechar las variaciones de los precios de un producto.

Existen diversos métodos que se han utilizado para la predicción de variables en el sector agropecuario. Los más comunes son los estadísticos, los clásicos aplicados al análisis de series de tiempo, son: la regresión polinomial de segundo grado, promedio móvil, suavización exponencial simple y suavización exponencial doble, el modelo GARCH y modelo ARIMA (López, 2020).

Una serie tiempo es una secuencia de observaciones, medidas en determinados momentos del tiempo, ordenadas cronológicamente y, espaciadas entre sí de manera uniforme. Su análisis se basa en la suposición de que los valores que toma la variable de observación es la consecuencia de tres componentes: su tendencia, la estacionalidad y su aleatoriedad. La actuación conjunta de estos da como resultado los valores medidos. El principal objetivo de una serie de tiempo X_t , donde $t= 1,2,3...n$ es su análisis para hacer pronósticos (Villavicencio, 2010).

Otra de las herramientas utilizadas con éxito en la predicción de precios, son las redes neuronales artificiales (RNA). De acuerdo con Zerecero, (2017) una de las principales ventajas de este método, es detectar no-linealidades en series temporales, lo que ha permitido que su uso sea de gran utilidad en la predicción de variables económicas y financieras.

2.3. Redes neuronales artificiales

De acuerdo con Acevedo, Serna, & Serna, (2017:174), Teuvo Kohonen refiere que: “las redes neuronales artificiales son redes interconectadas masivamente en paralelo con elementos simples, usualmente son adaptativas y tienen una organización jerárquica, las cuales tratan de interactuar con los objetos del mundo real, del mismo modo que lo puede hacer el sistema nervioso biológico”.

Por su parte, Hurtado, Estupiñan, & Carreño, (2018) definen una red neuronal artificial como un gran número de neuronas interconectadas que permiten el procesamiento de grandes volúmenes de datos a alta velocidad, trabajan en paralelo hacia una solución específica.

Se entiende como neurona o también llamado elemento procesador PE (process element) a la unidad de una Red Neuronal Artificial; este procesador posee la capacidad limitada de calcular, en general, una suma ponderada de

sus entradas y luego le aplica una función de activación para obtener una señal que será transmitida a la próxima neurona (Salas, 2005).

La figura 1 muestra la arquitectura de una Red Neuronal Artificial; esta se compone de capas o niveles agrupadas y poseen un alto grado de conectividad entre ellas.




Figura 1. Arquitectura de una red neuronal. Perceptrón multicapa con 14 variables de entrada y 8 nodos en la capa oculta.

Fuente: Salazar-Moreno; López C., Rojano A, & Fitz Rodríguez, (n.d.).

Esta estructura de interconexión es conocida como red multicapa; del lado izquierdo, se observan las variables de entradas (14) quienes reciben los valores de patrones y están representados como vectores que sirven de entrada a la red.

Posteriormente se observa una capa oculta, cuyas unidades responden a rasgos particulares que aparecen en los patrones de entrada y, finalmente, la capa de salida, que es una respuesta de la red a las variables de entrada. Este tipo de red puede estar total o parcialmente conectada (Isasi & Galván, 2004).

En la figura 2, se observa la arquitectura de dos tipos diferentes de red, la primera, es ejemplo de una red monocapa, cuya arquitectura es más sencilla ya que solo tiene una capa de neuronas que proyectan las entradas a otras neuronas de salida; la segunda, muestra la arquitectura de una red recurrente, la cual, se diferencia de las anteriores, en la existencia de lazos de realimentación en la red. Éstos pueden ser entre neuronas de diferentes capas, o de la misma capa o incluso, entre una misma neurona.




Figura 2. Arquitectura de una red neuronal monocapa (izquierdo) y recurrente (derecho).

Fuente: ERNA, 2022.

En cuanto al funcionamiento de las RNA, a diferencia de los algoritmos que se utilizan en las técnicas tradicionales de programación, donde las instrucciones son previamente programadas, en las RNA estas deben ser “entrenadas”.

El entrenamiento, es el proceso mediante el cual se adaptan los pesos de las variables de entrada para que, la Red Neuronal Artificial, responda de cierto modo; de esta manera “*aprende*” a calcular la salida correcta, para cada arreglo que se ha introducido de entrada. Así pues, en el *aprendizaje*, una red neuronal adapta o cambia los pesos de las conexiones en respuesta a los ejemplos de entrada, y opcionalmente también en respuesta a las salidas deseadas (Basogain, 1998; Matich, 2001).

3. MARCO REFERENCIAL

3.1. Contexto Internacional de la leche

De acuerdo con la FAO (2009), en el mundo, 150 millones de hogares se dedican a la producción de leche. En la mayoría de los países en desarrollo, la leche es producida por pequeños agricultores y la producción lechera contribuye a la seguridad alimentaria y la nutrición de los hogares.

En los últimos años Estados Unidos e India se han mantenido como los principales productores de leche bovina en el mundo, con volúmenes de producción por arriba de los 90 millones de toneladas (Mt por año) (Figura 3). De acuerdo con Dairy Export, 2016; la adopción de prácticas agrícolas modernas y eficientes, son factores que han determinado el alto nivel de producción del país americano, aunque es una actividad que se practica en todo el país, el mayor volumen de producción se concentra en cinco estados: California, Wisconsin, Idaho, Nueva York y Pensilvania




Figura 3. Principales países productores de leche entera de vaca en el período 2010 -2019

Fuente: Elaboración propia con datos de FAOSTAT, (2019)

En la India, la leche es el producto agrícola número uno, su sistema de producción es rural y el nivel de procesamiento es a pequeña escala; sin embargo, su sistema de comercialización cooperativa le ha permitido desarrollarse frente a los “gigantes productores globales” como Estado Unidos (GRAIN, 2019).

De acuerdo con estimaciones de OECD & FAO, (2020), en los próximos 10 años India y Pakistán contribuirán con más de la mitad del crecimiento de la producción mundial de leche y ordeñarán más de 30% de la producción mundial en 2029.

En la Figura 4, se muestra el listado de los veinte países con mayor volumen de producción de leche de vaca en el mundo, al 2019.




Figura 4. Los 20 países con mayor producción de leche entera de vaca en el mundo en 2019

Fuente: Elaboración propia con datos de FAOSTAT, 2019

Destaca, el posicionamiento de Estados Unidos como principal productor con 99 millones de toneladas, seguido de India con 90 millones; ambos países representaron el 25% de la producción total.

México posicionado en el lugar 17° con 12.3 millones de toneladas, el 1.3% de la producción total en el mundo. También se destaca la participación de la Unión Europea.

De acuerdo con el artículo Perspectivas Agrícolas 2020-2029 presentado por OECD & FAO, (2020); se prevé que la producción mundial de leche crezca más que cualquier otro producto agrícola básico, llegando a una producción total de 997 millones de toneladas al 2029, lo que representa un incremento anual del 1.6%.

Si bien, la tendencia de producción de leche regional es creciente, en relación con la producción del país norteamericano, no se ha mantenido constante al presentar algunas disparidades entre años. FEPALE (2019), menciona que este comportamiento relativo de la producción regional se debe al importante crecimiento de la producción global, no solo de Estados Unidos, sino también de países como India, China y Pakistán.

La región de América Latina siempre ha estado abierta al comercio mundial de productos lácteos. En varios países de la región la cadena láctea ha mostrado su capacidad para aportar positivamente al balance de divisas a través de las exportaciones, en el Cuadro 1 se puede observar el comportamiento, en cuanto a volumen de exportación de leche de vaca, de países de América central como Costa Rica, Nicaragua y de países del sur de América.

Cuadro 1. Países de Latinoamérica y el Caribe (LAC) con mayor volumen de exportación de leche de vaca en el periodo 2017-2019. Valor expresado en toneladas.

País	2017	2018	2019
Costa Rica	35,304	38,404	39,978
Honduras	9,939	14,633	12,613

Uruguay	11,747	12,027	8,951
Nicaragua	25,652	7,645	5,003
México	1,860	2,355	4,001
Brasil	66	271	1,320
Chile	1,122	453	1,284
Perú	710	1,110	829

Fuente: Elaboración propia con datos de FAOSTAT (2021)

En el Cuadro 2 se visualizan los países con mayor valor de importación de leche. En este rubro, Alemania es el principal importador de leche de bovino, con más de 2 millones de toneladas al cierre del 2019; lo anterior debido, principalmente a que, alrededor del 47% de la producción láctea alemana se destina a la elaboración de quesos y en menor proporción otros productos como la mantequilla, nata y yogures; que posteriormente exporta a países miembros de la Unión Europea, principalmente (GALEGO,2021). México también figura en este contexto, con 117 mil toneladas de leche de vaca importadas, la cual proviene principalmente de Estados Unidos.

Cuadro 2. Principales países importadores de leche de vaca entera, en el período de 2017 a 2019

País	2017	2018	2019
Alemania	2,777,928	2,353,680	2,647,279
Italia	1,174,689	1,113,711	1,173,759
Bélgica	1,039,152	943,425	645,869
Irlanda	697,173	757,811	639,985
Países Bajos	691,019	714,759	721,724
China	607,048	615,089	771,444
México	30,947	37,174	117,670

Fuente: Elaboración propia con datos de FAOSTAT

La Secretaría de Economía en México (SE, 2012) y Dávalos (2020); reportan que, en la última década, el crecimiento en el consumo mundial de lácteos es correspondiente al aumento de la población mundial y que éste se encuentra concentrado en los países industrializados como consecuencia de su mayor poder adquisitivo y consumo per cápita.

3.2. Contexto Nacional de la leche

La tercera actividad más importante en la industria de los alimentos es el sector lácteo, siendo uno de los grandes impulsores de la economía en México. Este sector presenta una alta oportunidad de desarrollo tanto nacional como internacional, puesto que la demanda de alimentos sigue a la alza debido al crecimiento de la población (CANILEC, 2021; Hernández & Gil, 2019).

En 2020 la producción nacional de leche creció en 2.3%, ubicándose en 12,554 millones de litros, más del doble de la producción previa a la entrada del TLCAN, hoy TMEC. Datos del Instituto Nacional de Estadística y Geografía (INEGI) señala que la elaboración de productos lácteos representó el 10 % del Producto Interno Bruto (PIB) de la industria alimentaria de México (CANILEC, 2021).

En México se identifican cuatro sistemas para la producción de leche: el especializado, semi-especializado, familiar y de doble propósito. Y la producción es muy heterogénea desde el punto de vista tecnológico, agroecológico y socioeconómico, incluyendo la gran variedad de climas regionales y características de tradiciones y costumbres de las poblaciones (Robledo, 2019).

En 2021, FORBES publicó una nota que hace énfasis en el déficit nacional que existe para cubrir la demanda de este alimento en el país. De acuerdo con el SIAP (2023), el consumo anual per cápita de leche de bovino es de 131.4 litros.

Los animales lecheros se crían en una infinidad de sistemas de producción y se pueden clasificar en cuatro tipos. Sistemas especializados sin tierra, cuyo objetivo principal es la producción de leche. Sistemas integrados de cosecha y

producción lechera, orientados al mercado y a la subsistencia, que se enfocan en la producción conjunta de la leche, la carne y la cosecha. Sistemas de pastoreo que dependen de la movilidad para la producción de leche, y en menor medida, de otros productos y servicios ganaderos.

De acuerdo con FIRA (2019), en México, la elaboración de subproductos lácteos es uno de los sectores más importantes de la industria alimentaria. La elaboración de queso, crema y yogurt representaron 38.8 por ciento del valor total de la elaboración de productos lácteos.

3.3. Usos de las redes neuronales artificiales

Las redes neuronales son una tecnología informática emergente que puede utilizarse en un gran número y variedad de aplicaciones. Se han aplicado modelos de redes neuronales en diferentes disciplinas; ciencias de la salud, finanzas, ciencias nucleares, aeronáutica, biología, en la propia informática (Rivas & Mazón, 2018).

En el área financiera el uso de las redes neuronales ha sido variado, teniendo diferentes aplicaciones: la administración de los portafolios de inversión, la evaluación de acciones, las estrategias de cobertura y arbitraje, el análisis de la volatilidad y correlación y la predicción de los precios de acciones, bonos, tasas de interés y de cambio, entre otros (del Carpio, 2005).

Shachmurove (2002) afirma que, los métodos tradicionales para pronosticar incluyen métodos de regresión múltiple, análisis de series temporales, promedios móviles y métodos de suavizado. Sin embargo, todos éstos, tienen el mismo inconveniente, en la medida en que requieren suposiciones sobre la forma de distribución de la población.

De acuerdo con Villada, Muñoz, & García, (2012), en un estudio de pronóstico de precios las redes neuronales mostraron un buen comportamiento, con bajos errores en su desempeño tanto en aprendizaje como en predicción, en un

estudio de pronóstico de precios en dos de las principales acciones del mercado de valores colombiano.

Cabrera & Ortiz (2012) utilizaron el sistema de identificación basado en redes neuronales diferenciales para el pronóstico del rendimiento del Índice de Precios y Cotizaciones en la Bolsa Mexicana de Valores, destacaron el buen desempeño de este sistema y lo consideran viable, útil y robusto para la descripción de variables financieras.

Los resultados experimentales muestran que, las redes neuronales artificiales, tienen mejores valores predictivos que las técnicas tradicionales de modelado estadístico debido a su capacidad para tratar los datos no lineales y estocásticos, incluso mejor que las técnicas tradicionales de modelado estadístico como Box-Jenkins (Basheer, Abduhakeem, & Fuad, 2016), técnicas basadas en Árboles de Decisión y Máquinas de Soporte Vectorial (Perdigón & González, 2021); modelo ARIMA (Somvanshi et al., 2006) y modelo GARCH, (Ortiz, 2017).

Estos autores mencionan que, se obtuvo la misma precisión en el valor de predicción pero que, el esfuerzo realizado para obtener los resultados con la familia de modelos GARCH, fue significativamente mayor que con las RNA, por lo que propone utilizar las RNA como un método alternativo fiable en el análisis de series de tiempo.

Se han realizado diversas investigaciones para predicción de precios de diferentes productos como el petróleo (Ortiz, 2017), el oro (Villada et al., 2012); en productos agrícolas como el maíz (Zerecero, 2017) y el café (M. I. García, 2003).

En cuanto a predicción de precios del producto leche, Shahriary & Mir (2016) aplicaron un modelo de redes neuronales artificiales en el pronóstico del precio de esta en Irán, un año más tarde Vicentín y García (2017) lo aplicaron con el mismo fin en el sector lácteo argentino. Si bien, no existen muchos

antecedentes de aplicación de las RNA en la predicción de precios de leche, si existe evidencia como una alternativa viable para realizar este análisis y con una efectividad incluso mayor a las series de tiempo que tradicionalmente se utilizan como son modelos ARIMA Y GARCH.

4. MATERIALES Y MÉTODOS

4.1. Objeto de estudio

En esta investigación, se analizó y pronosticó el precio medio rural de leche de bovino en México. Se realizó una revisión documental para identificar los factores relacionados al precio de la leche; se consideró para cada factor relacionado, información del período de 1980 al 2021.

Se identificaron ocho variables relacionadas al precio de la leche (Cuadro 3): Producción nacional de leche fluida de bovino, precio nacional de maíz amarillo, precio nacional de pasta de soya, siendo estos base de alimentación del ganado bovino; así mismo se identificó las importaciones de subproductos. La base de datos se integró con información anual de cada una de las variables de 1980 a 2021, obteniendo un total de 378 datos.

Cuadro 3. Variables relacionadas al precio medio rural de la leche en México

Abreviación	Variable	Unidades
PL	Precio leche	Pesos/L (deflactado)
PrL	Producción leche	litros
PM	Precio maíz	Pesos/tonelada (deflactado)
PS	Precio soya	Pesos/tonelada (deflactado)
ILD	Importación leche descremada en polvo y suero en polvo	Toneladas
ILP	Importaciones de leche entera en polvo	Toneladas
IY	Importaciones de yogurt con aditivos	Toneladas
IM	Importaciones de mantequilla de leche de vaca	Toneladas
IQ	Importaciones de quesos (todos tipos)	Toneladas

Fuente: Elaboración propia

4.1.1. Obtención de datos

La información de los precios y producción nacional de la leche, se obtuvo en bases de datos del Sistema de Información Agroalimentaria y Consulta (SIACON); la información sobre importaciones de leche descremada, suero, leche entera en polvo, importaciones de yogurth, mantequilla de leche de vaca y queso (todos) de la base de datos de la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO Statics) , mientras que, los datos de los precios del maíz y pasta de soya se obtuvieron en el Sistema de Nacional de Información e Integración de Mercados

Para obtener los datos reales, se deflactaron los precios nacionales nominales del precio de la leche, maíz y pasta de soya. Para deflactar los precios se tomó un Índice Nacional de Precios al Consumidor (INPC) con base en la segunda quincena de diciembre del año 2021 (diciembre 2021=117.308).

4.1.2. Análisis exploratorio de los datos

Después de una depuración de información, se integró la base de datos en una hoja de Excel. Para el análisis y programación de la Red Neuronal Artificial se utilizó la plataforma MatLab. El primer paso fue realizar un análisis para detectar datos faltantes y outliers en la base de datos. Mediante la función *fillmissing* se llenaron las entradas faltantes en la variable IY (importaciones de yogurt), ya que no se encontró registro de la información de los años de 1980 a 1987; esta función rellena las entradas faltantes de una matriz o tabla con un valor constante, para lo cual, se eligió la media como valor constante. Posteriormente, se utilizó la función *filloutliers* para detectar valores significativamente diferentes en cada una de las variables, los outliers identificados se reemplazaron mediante la función *clip*, misma que asigna el valor de la media de la variable más 3 desviaciones estándar; finalmente, se

generó la base de datos con las funciones aplicadas y se realizó un análisis de correlación.

4.1.3. Matriz de correlación

Para conocer el grado de asociación entre las variables se realizó un análisis de correlación; Su rango de valores va de -1 a 1, siendo 0 una nula correlación, 1 una correlación positiva perfecta y -1 una correlación negativa perfecta.

4.2. Modelo de redes neuronales artificiales

Una de las arquitecturas de redes neuronales artificiales más utilizadas por su eficiencia para pronosticar. Para determinar el número de nodos en la capa oculta se aplicó el teorema de Kolmogorov, el cual define el rango de nodos en que la red debe ser entrenada; además se registra el valor de error cuadrado medio (MSE) y eficiencia (E):

$$|h_1 = 2n + 1 \quad (1)$$

$$|h_2 = \sqrt{mn} \quad (2)$$

$$|h_3 = n \quad (3)$$

Donde h es el número máximo de nodos en la capa oculta, n el número de variables de entrada y m el número de variables de salida.

4.2.1. Arquitectura de la Red Neuronal Artificial

Como se muestra en la figura 5 la red está compuesta por ocho nodos en la capa de entrada, que corresponden a cada una de las variables relacionadas al

precio de la leche; cuatro nodos en la capa oculta y la capa de salida que corresponde a la variable a predecir.




Figura 5. Arquitectura de la red neuronal artificial implementada para predecir el precio de la leche

4.2.2. Algoritmo de aprendizaje

El algoritmo backpropagation o retropropagación es el más utilizado para entrenar redes neuronales multicapa; su funcionamiento consiste en aplicar un patrón de activación en la capa de entrada, propagándose hacia la intermedia, hasta generar una salida. El valor es comparado con el que se desea obtener y calcula un valor de error; estos errores se transmiten hacia atrás, partiendo de la capa de salida, hacia la intermedia, por lo que reciben un porcentaje de error aproximado a la participación de la capa intermedia en la salida original (González, 2023).

Basándose en el valor del error recibido, se reajustan los pesos de conexión de cada neurona, de manera que la siguiente vez que se presente el mismo patrón, la salida esté más cercana a la deseada.

4.2.3. Entrenamiento, validación y prueba de la red neuronal

Se entrenó la red de acuerdo con el rango en el número de nodos (de 1 a 8), posteriormente se compararon los resultados de eficiencia y error cuadrado medio y con base en ello, se eligió la red con el número de nodos en la capa oculta que presentó mayor eficiencia y menor error cuadrado medio.

Cabe señalar que en este proceso, se considera únicamente el 90 % de información del total que conforma la base de datos. Una vez que se eligió la red, ésta se sometió a un proceso de validación, la cual consiste en alimentar la red con el 10 % de los datos restantes y definir la predicción de precios para un determinado rango de tiempo. Finalmente, el algoritmo comparó la simulación de la red con los precios reales y de esta manera se realizaron las medidas de ajuste necesarias, hasta que los valores predichos fueran lo más cercanos a los reales. Una vez realizado el ajuste, se comprobó nuevamente la eficiencia y error cuadrado medio de la red, para decidir si es suficiente para realizar la predicción a años posteriores.

4.2.4. Medidas de desempeño de la red

Se consideraron dos criterios para evaluar el desempeño de la red: el error cuadrado medio (MSE) y la eficiencia (E).

Error cuadrado medio (MSE)

Cuando la tarea de aprendizaje consiste en la estimación de una función, normalmente se utiliza el error cuadrado medio para evaluar la ejecución del modelo y está dada por la siguiente ecuación (Palmer et. al, 2021):

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

Donde: n es el número de datos, y_i es el valor observado, $\hat{y}_i$ el valor predicho.

Eficiencia (E)

La eficiencia fue propuesta por Nash y Sutcliffe (1970) y se define como: uno menos la suma de las diferencias cuadráticas absolutas entre los valores predichos y los valores observados normalizados, por la varianza de los valores observados durante el período investigado (Krause,2005). Se calcula como:

$$E = 1 - \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

Donde: n es el número de datos, y_i es el valor observado, $\hat{y}_i$ el valor predicho y $\bar{y}$ representa el promedio de los valores observados.

4.2.5. Análisis de Sensibilidad

Con el objetivo de determinar la importancia relativa de cada variable de entrada en la red, se realizó un análisis de sensibilidad utilizando el algoritmo de Garson.

Garson (1991), propone un método que particiona los pesos de conexión de la red neuronal y se describe por la siguiente ecuación:

$$RI_j = \left[\frac{\sum_{j=1}^n \left[\frac{|W_{ij} \cdot W_{j0}|}{\sum_{k=1}^m |W_{ij} \cdot W_{j0}|} \right]}{\sum_{k=1}^m \left[\sum_{j=1}^n \left[\frac{|W_{ij} \cdot W_{j0}|}{\sum_{k=1}^m |W_{ij} \cdot W_{j0}|} \right]} \right]} \right] \cdot 100 \quad (6)$$

Donde RI_j representa el porcentaje de influencia de cada valor de entrada i sobre el valor de salida k ; $\sum_{k=1}^I |W_{jk}|$ es la suma de pesos que conectan la capa de entrada i y la neurona j ; n corresponde al total de vectores de entrada; I corresponde al total de neuronas de la capa oculta, V_{jk} representa los pesos de la conexión entre la neurona j y el vector de entrada k .

Este método, facilita la interpretación de los efectos directos de las variables de entrada sobre la respuesta, mediante la eliminación de pesos de conexión que no contribuyen significativamente al rendimiento de la red neuronal (Olden y Jackson, 2002).

El algoritmo de Garson utiliza los valores absolutos de los pesos de conexión tanto de la capa de entrada a la capa oculta, como los pesos de la capa oculta a la de entrada, mismos que se obtienen en el proceso de entrenamiento de la red; sin embargo, este no indicará la dirección de la relación entre variables de entrada y salida.

5. RESULTADOS Y DISCUSIÓN

5.1. Contexto nacional de la producción de leche en México

5.1.1. Regionalización

En México, la producción de leche de bovino es muy heterogénea desde el punto de vista tecnológico, agroecológico y socioeconómico, incluyendo la gran

variedad de climas regionales y características de tradiciones y costumbres de las poblaciones.

Por otra parte, las unidades de producción en México se pueden agrupar en tres niveles, de acuerdo con su tecnificación: el estabulado, que se localiza en cuencas y zonas especializadas del norte y centro (como la Laguna); el semi estabulado o familiar, que prevalece en las zonas templadas del centro occidental y norte (como los Altos de Jalisco); y el de ordeña estacional y libre pastoreo, preponderante en las regiones húmedas, semi cálidas y secas del trópico mexicano (Del Valle & Álvarez, 1997).

Respecto a las condiciones climáticas y la disponibilidad de agua la SAGARPA, tiene establecida una tipología que considera la distribución de explotaciones lecheras en los estados.

Cuadro 4. Regionalización de la producción de leche bovino

Región	Estados
Región Tropical	Campeche, Colima, Chiapas, Guerrero, Nayarit, Oaxaca, Quintana Roo, Tabasco, Veracruz y Yucatán.
Región Templada	Aguascalientes, Guanajuato, Hidalgo, Jalisco, México, Michoacán, Morelos, Puebla, Querétaro, Tlaxcala y CDMX.
Región Árida y Semiárida	Baja California, Baja California Sur, Coahuila, Chihuahua, Durango, Nuevo León, San Luis Potosí, Sinaloa, Sonora, Tamaulipas y Zacatecas

Fuente: Programa de producción de leche y de sustitución de las importaciones. SAGARPA-Dirección General de Ganadería, marzo de 1997

5.1.2. Producción

La producción promedio anual de leche de bovino en México durante el período 1980-2021 tuvo una tasa anual de crecimiento promedio de 1.159 % (figura 6). Esta producción ha sido insuficiente para abastecer un consumo anual de 13312 millones de litros, registrándose déficits anuales de aproximadamente 20 % cubiertos con importaciones.




Figura 6. Producción de leche fluida de bovino en México de 1980 a 2021

Fuente: Elaboración propia

En la figura 7, se observa la producción de leche de bovino en México, con base en la regionalización por clima, correspondiente la región templada para los años de 1980 al 2021. En dicha región se concentra casi la mitad de la producción nacional.




Figura 7. Producción de leche fluida de bovino en la región templada en México de 1980 a 2021

Fuente: Elaboración propia con datos de SIAP.

Magaña et al., (2006), refiere que la ventaja de la región del trópico de México es la disponibilidad de agua y suelo, factores que permiten cultivar forrajes como insumos alimenticios a bajo costo; sin embargo, a pesar de dicho potencial, no se han podido mejorar los rendimientos que obtienen en el sistema especializado que predomina en la región templada.

5.1.3. Importaciones

Tal como refiere Robledo (2019), la principal problemática en México es la importación de leche descremada en Polvo, donde Estados Unidos tienen la ventaja comercial. En 2018, de las 360 mil toneladas de leche descremada en polvo importada, el 97% provino de este país y con importaciones marginales de otros países como Canadá y Francia




Figura 8. Importaciones mexicanas de leche descremada y suero en polvo de 1980 a 2021

Fuente: Elaboración propia con datos de FAO, 2021

Las importaciones de leche descremada en polvo se han mantenido fluctuantes, sin embargo, durante 2006 y 2007 las importaciones se redujeron, quizás debido a que, su precio internacional se incrementó sustancialmente.

México también es importante importador de mantequilla y queso; en 2018 se importaron del mercado internacional 30 mil toneladas de mantequilla y 123 mil toneladas de queso (CEDRSSA, 2019).

5.2. Análisis exploratorio

El cuadro 5 resume una breve estadística descriptiva de la variable a predecir (precios de la leche) y de las variables relacionadas (producción nacional de la leche fluida de bovino, precio nacional de maíz amarillo, precio nacional de la pasta de soya, importaciones de la leche descremada y suero en polvo, así como importaciones de leche entera en polvo.

Cuadro 5. Estadística descriptiva

Variable	Abrev.	Unidades	n	Media	STD	CV
Precio nacional de leche fluida de bovino.	PI	\$/litro	42	10.71	3.71	0.347
Producción nacional de leche de bovino	Prl	litros	42	9,013,720.44	2,133,444.74	0.237
Precio del maíz amarillo	Pm	\$/ton.	22	4,978.04	892.32	0.179
Precio de la pasta de soya	Ps	\$/ton.	27	8,528.70	1,686.95	0.198
Importaciones de leche descremada y suero en polvo	Ld	Ton.	41	164,070.78	68,515.65	0.418
Importaciones de	Le	Ton.	41	30,984.63	30,348.75	0.979

5.2.1. Correlación de variables

Se realizó una matriz de correlación con el fin de conocer el nivel de asociatividad que existe entre el precio de la leche y las variables relacionadas. Se obtuvo la matriz de correlación, la cual refleja la relación entre dos variables y su rango de valores es de -1 a 1, siendo 0 una nula correlación, 1 una correlación positiva perfecta y -1 una correlación negativa perfecta.

De acuerdo con el análisis de correlación (figura 9), existe una asociación negativa (-74%), entre el precio medio de la leche y la producción nacional, misma que podría explicarse, por el efecto oferta-demanda de este bien en el mercado, es decir; cuando aumenta la producción, por ejemplo, en temporada de lluvia, el precio medio rural de la leche baja, este es un fenómeno muy notorio en el país.




Figura 9. Matriz de correlación del precio de la leche con las variables relacionadas

Así mismo, se identifica una correlación negativa con la importación de quesos y la importación de mantequilla; esto se debe, a que actúan como bienes sustitutos, de acuerdo con Cervantes y Cesín, (2019), en 2003 después de la liberación del arancel de varios subproductos lácteos, como la leche evaporada, condensada, yogur, mantequilla, quesos de todo tipo, suro, lactosuero, etc. Hubo un repunte en las importaciones y de la dependencia alimentaria de México de estos productos.

5.2.2 Modelo de Red Neuronal Artificial: Entrenamiento, Prueba y Validación de red.

Se desarrolló un modelo de RNA para predecir el precio nacional de la leche (PL), utilizando las siguientes variables como valores de entrada: Producción nacional de leche (PrL), precio nacional del maíz amarillo (PM), precio nacional de la pasta de soya (PS), importaciones de leche descremada y suero en polvo (ILD), importaciones de leche entera en polvo (ILP), importaciones de yogurt (IY), importaciones de mantequilla de leche (IM), importaciones de quesos (IQ).

Los nodos en la capa oculta se variaron de 3 a 17 de acuerdo con las ecuaciones 1, 2 y 3; y la variable del precio de la leche como valor de salida.

Sustituyendo las ecuaciones 1,2 y 3:

$$h_1 = 2(8) + 1 = 17 \quad (7)$$

$$h_2 = \sqrt{(1)(8)} = 2.8 \sim 3 \quad (8)$$

$$h_3 = 8 \quad (9)$$

Los resultados de eficiencia y error cuadrado medio con cada uno de los rangos de nodos en la capa oculta se despliega en la Figura 10.




Figura 10. Error cuadrado medio y eficiencia de la red, con el rango de nodos en la capa oculta entre 3 y 17.

Una vez que se eligió la red con mayor eficiencia, se utilizó el 10% de datos faltantes, (2018 a 2021) para realizar la simulación de la predicción de la red neuronal entrenada; Figura 11. Si bien, los valores del precio de la leche simulados no son estrictamente similares si mantienen la misma tendencia, por lo que se puede argumentar, que si sirve para predecir el precio medio rural de la leche de bovino en México.




Figura 11. Simulación entre el precio real de la leche y el precio estimado por la red neuronal artificial en la etapa de evaluación (2018-2021)

5.2.3 Análisis de sensibilidad




Figura 12. Análisis de sensibilidad para la RNA con 8 variables de entrada

El análisis de sensibilidad también muestra del impacto que tienen cada una de las variables de entrada sobre la variable de entrada, es decir, sobre el precio medio rural de la leche de bovino en México. De acuerdo con el resultado obtenido en el análisis de correlación, este análisis también muestra un alto impacto de la importación de queso (IQ) y la producción (PrL).

En este análisis se destaca del impacto que tiene el precio del maíz (PM) sobre el precio pagado al productor (PL).

6. CONCLUSIONES

México sigue siendo un importador neto de lácteos, y se presenta un efecto de sobreproducción en el verano, que hace que los precios de la leche bajen en esa época del año, cuando hay más lactcinio disponible.

Con esta investigación se evidenció, que las redes neuronales artificiales pueden ser una alternativa viable y diferente a los métodos ya conocidos, para la predicción del precio medio rural de la leche en México.

Como perspectivas de la investigación, se tiene que conociendo la predicción del precio medio rural de la leche en México, se pueden implementar estrategias que ayuden a los productores primarios a superar la baja en el precio que se da durante la temporada de lluvias; y a los comercializadores a programar mejor sus importaciones.

LITERATURA CITADA

- Acevedo, M. E., Serna, A. A., & Serna, M. E. (2017). Principios y características de las redes neuronales artificiales. In *Desarrollo e innovación en ingeniería* (pp. 173–181). Retrieved from <http://fundacioniai.org>
- Aguilar, V. A., & López, L. M. (2006). Como lograr que la ganadería lechera mexicana sea competitiva a nivel internacional. *Revista Mexicana*, X, 1–14. Retrieved from <http://www.redalyc.org/articulo.oa?id=14101814>
- Banco Mundial. (2021). *Commodity Markets Outlook*.
- Basheer, M. A.-M., Abduhakeem, A. A.-M., & Fuad, N. A.-B. (2016). Forecasting using Artificial Neural Network and Statistics Models. *International Journal of Education and Management Engineering*, 6(3), 20–32. <https://doi.org/10.5815/ijeme.2016.03.03>
- Basogain, X. (1998). Redes neuronales artificiales y sus aplicaciones. In *Publicaciones de la escuela de ingenieros*.
- Brambila-Paz, J., Mora-Flores, S., Rojas-Rojas, M. M., & Pérez-Cerecedo, V. (2013). El precio mínimo al productor primario de leche para reducir las importaciones de lácteos en México. *Agrociencia*, 47, 511–522.
- Cabrera, L. A. I., & Ortiz, A. F. (2012). Pronóstico del rendimiento del IPC (Índice de Precios y Cotizaciones) mediante el uso de redes neuronales diferenciales. *Contaduría y Administración*, 57(2), 63–81.
- CANILEC. (2021). *Perspectivas del mercado de los lácteos*.
- CEDRSSA. (2019). *La Producción y el Comercio de Lácteos en México*.
- Cervantes E F, Cesín. V. J. A. (2019). *Análisis de la producción lechera e importaciones de lácteos en México ante la renegociación del TLCAN*. In *La ganadería ante escenarios complejos*. Universidad Autónoma Chapingo (pp. 15–27).
- Dairy Export. (2016). *La Industria Láctea de Estados Unidos*.
- Dávalos, F. J. L. (2020). *Panorama general de la leche en Universidad Nacional Autónoma de México facultad de medicina Veterinaria y Zootecnia departamento de economía, administración y desarrollo rural* (Foro de Perspectivas del Mercado de los Lácteos, Ed.).
- De Groot, J. O. (2018). *La cadena regional de valor de la industria de lácteos en Centroamérica*. Ciudad de México.
- Del Carpio, G. M. (2005). The artificial neural networks in finance. *Industrial Data*, 8, 1–6.
- FAO. (2009). *La agricultura mundial en la perspectiva del año 2050*.
- FEPALE. (2019). *Situación de la cadena láctea en América Latina en el 2018*.

- FEPALE. (2021). *El sector lácteo de América Latina*. Retrieved from <https://fepale.org/site/>
- FIRA. (2019). Panorama Agroalimentario Leche y Lácteos. Obtenido de <https://s3.amazonaws.com/inforural.com.mx/wp-content/uploads/2019/06/16093139/Panorama-Agroalimentario-Leche-y-la769cteos-2019.pdf>
- FORBES. (2021). *Producción de leche en México registra déficit de 4,000 millones de litros*.
- García, H. A. L. (2001). Estrategias de las Agroindustrias Lecheras Latinoamericanas. Estudio Comparativo ante el Proceso de Globalización Económica. *Revista Mexicana de Agronegocios*, 1, 263–273. Retrieved from <http://www.redalyc.org/articulo.oa?id=14100901>
- García, L. A., María, H., Carmen, D., Rivera, D. V., Álvarez Macías (coordinadores) Universidad A U T ~ N O M, A., Metropolitana, A., Xochimilco, U., De, D., Agr~cola, P., & Animal, Y. (1997). *Los Sistemas Nacionales Lecheros de México, Estados Unidos y Canadá y Sus Interrelaciones*, 157-174.
- García, M. I. (2003). Análisis y predicción de la serie de tiempo del precio externo del café colombiano utilizando redes neuronales artificiales. *Universitas Scientiarum*, 8, 45–50.
- GRAIN. (2019). *El sector lácteo de India bajo amenaza por los nuevos tratados comerciales*. Barcelona. Retrieved from <http://govindmilk.com/fdi-in-dairy-industry-in-india/>
- Hernández, V. X. C., & Gil, M. M. D. (2019). La administración de riesgos como herramienta en el control interno de organizaciones del sector lácteo. *EKOTEMAS*, 5, 51–66. Retrieved from <http://www.ekotemas.cu>
- Hurtado, P. A., Estupiñan, E. W., & Carreño, S. F. (2018). Computación inteligente para la clasificación de semillas de Trigo. *Universidad Ciencia y Tecnología*, 22, 27–33.
- Isasi, P., & Galván, I. M. (2004). *REDES NEURONALES ARTIFICIALES Un enfoque práctico* (PEARSON EDUCACIÓN). Madrid.
- López, G. M. del R. (2020). *Predicción del precio del Maíz en México*. Texcoco Estado de México.
- Magaña M., J. G., Ríos A., G., & Martínez G., J. C. (2006). Los sistemas de doble propósito y los desafíos en los climas tropicales de México. In *Introducción Arch. Latinoam. Prod. Anim* (Vol. 14, Issue 3).
- Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Rosario.
- Moreno, S. E. (2008). Predicción con series de tiempo y regresión. *PANORAMA*, 2, 36–58.
- OECD, & FAO. (2020). *OCDE-FAO Perspectivas Agrícolas 2020-2029*. Paris: OECD. <https://doi.org/10.1787/a0848ac0-es>

- Ortiz, A. F. (2017). Pronóstico de precios de petróleo: una comparación entre modelos garch y redes neuronales diferenciales. *Investigación Económica*, LXXVI, 105–126.
- Perdigón, L. R., & González, B. N. (2021). Comparación y selección de técnicas de inteligencia artificial para pronosticar las producciones de leche bovina. *Revista Cubana de Ciencias Informáticas*, 15, 24–43.
- Rivas, A. W., & Mazón, O. B. (2018). *Redes neuronales artificiales aplicadas al reconocimiento de patrones* (UTMACH). Machala. Retrieved from www.utmachala.edu.ec
- Robledo, P. R. (2019). Política de producción y comercio de leche en México en el contexto actual. In *Abordajes teóricos, impactos externos, políticas públicas y dinámica económica en el desarrollo regional*. Universidad Nacional Autónoma de México y Asociación Mexicana de Ciencias para el Desarrollo Regional (A.C, Coeditores, Vol. 1, pp. 462–488). México.
- Salas, R. (2005). Redes Neuronales Artificiales. *Academia*, pp. 1–7.
- SE. (2012). *Análisis del sector lácteo en México*.
- Shachmurove, Y. (2002). *Aplicación de redes neuronales artificiales a los negocios, la economía y las finanzas*. Philadelphia.
- Shahriary, G., & Mir, Y. (2016). Application of Artificial Neural Network Model in Predicting Price of Milk in Iran. *Modern Applied Science*, 10(4), 173. <https://doi.org/10.5539/mas.v10n4p173>
- SIAP (2023). Panorama Agroalimentario.
- Somvanshi, V. K., Pandey, O. P., Agrawal, P. K., Kalanker, N. v., Prakash, M. R., & Chand, R. (2006). Modelling and prediction of rainfall using artificial neural network and ARIMA techniques. *J. Ind. Geophys. Union*, 10(2), 141–151. Retrieved from <https://www.researchgate.net/publication/255587986>
- Sosa, S. M. del C. (2007). Inteligencia artificial en la gestión financiera empresarial. *Pensamiento & Gestión*, 153–186.
- USDA. (2021). *Dairy Production and Trade Developments*. Retrieved from <https://downloads.usda.library.cornell.edu/usda-esmis/files/5t34sj56t/sj13b3984/xw42p992f/dairy.pdf>
- Vicentin, M. J., & García, A. R. (2017). Redes Neuronales para la predicción de precios en el sector lácteo argentino. *Cuadernos Del CIMBAGE*, 115–136. Retrieved from <http://www.redalyc.org/articulo.oa?id=46251257002>
- Villada, F., Muñoz, N., & García, E. (2012). Aplicación de las Redes Neuronales al Pronóstico de Precios en el Mercado de Valores. *Informacion Tecnológica*, 23(4), 11–20. <https://doi.org/10.4067/S0718-07642012000400003>
- Villavicencio, J. (2010). Introducción a Series de Tiempo Introducción a Series de Tiempo Por: John Villavicencio CONTENIDO. *ACADEMIA*, 1–31.

- Zerecero, S. O. A. (2017). *Análisis del comportamiento del precio de maíz utilizando un modelo de redes neuronales artificiales*. Texcoco, Estado de México.
- Wolf, C. A., & Widmar, N. J. (2015). Can insurance provide the US dairy farm safety net? *Agricultural and Food Economics*, 3(1). <https://doi.org/10.1186/s40100-015-0031-8>

ANEXOS

Anexo 1. Código elaborado para la programación de la Red Neuronal Artificial

```
clear all
close all

%Importando datos
Datos=xlsread("BaseDatos2.xlsx",1,'A1:J43');

PL=Datos(:,2);
PrL=Datos(:,3);
PM=Datos(:,4);
PS=Datos(:,5);
ILD=Datos(:,6);
ILP=Datos(:,7);
IY=Datos(:,8);
IM=Datos(:,9);
IQ=Datos(:,10);

%Datos faltantes
%Sustituir el valor faltante por la media

IYf= mean (Datos(:,8),'omitnan')
IY=fillmissing(Datos(:,8),'constant',IYf)
Datos(:,8)=IY;

%Outliers
TF = filloutliers(Datos,"clip");

xlswrite('DatosLlenos2.xlsx',Datos,'A2:J43')

%Matriz de coeficiente de correlaciones
DatosC=xlsread('DatosLlenos2.xlsx',1,'B2:J43');

PL=DatosC(:,1);
PrL=DatosC(:,2);
PM=DatosC(:,3);
PS=DatosC(:,4);
ILD=DatosC(:,5);
ILP=DatosC(:,6);
IY=DatosC(:,7);
IM=DatosC(:,8);
IQ=DatosC(:,9);

CR=corrcoef(DatosC);
[R,PValue]=corrplot(DatosC,'testR','on','varnames',{ 'PL','PrL','PM','PS','ILD','ILP','IY','IM','IQ'});

xlswrite('MatrixCorr.xlsx',CR,'B2:J43')

%Componentes principales
```

```

[coeff,score,latent]=pca(Datos);

%Red neuronal estática
% 90 % de datos

Datos=xlsread('Datosllenos2.xlsx',1,'A2:J43');

%Asignando valores
TIEM=Datos(1:39,1);
PL=Datos(1:39,2);
PrL=Datos(1:39,3);
PM=Datos(1:39,4);
PS=Datos(1:39,5);
ILD=Datos(1:39,6);
ILP=Datos(1:39,7);
IY=Datos(1:39,8);
IM=Datos(1:39,9);
IQ=Datos(1:39,10);

%variables de entrada
p=[PrL,PM,PS,ILD,ILP,IY,IM,IQ];
%variable de salida
t=[PL];

[pn,ps]= mapminmax(p);
[tn,ts]= mapminmax(t);

[R,Q]= size(pn);
[S,G]= size(tn);

%Asignación de datos para entrenar
%Basado en h=4
%Algoritmo de entrenamiento trainscg

[trainP,valP,testP,trainInd,validInd,testInd]=dividerand(pn,0.5,0.25,0.25);
[trainT,valT,testT]=divideind(tn,trainInd,validInd,testInd);
net4 = newff([trainP,valP,testP],[trainT,valT,testT],4,{'tansig' 'purelin'},'trainlm','learngd','mse');

view (net4)

net4.trainParam.show=50;
net4.trainParam.epochs=1000;
net4.trainParam.goal=0.00001;
[net4,tr]=train(net4,pn,tn);

Ysim=sim(net4,pn);
Ynet=mapminmax('reverse',Ysim,ts);

Iteraciones=tr.num_epochs;

plot(tr.epoch,tr.perf,tr.epoch,tr.vperf,tr.epoch,tr.tperf)
legend('Entrenamiento','Validacion','Prueba');
ylabel('Error Cuadrado');
xlabel('Epoch');

```

```

plot(TIEM,PL',TIEM,Ynet(1,:),'-g','Linewidth',1);
title('Simulacion');
legend('Real','Simulado');
xlabel('Tiempo');
ylabel('Precio Leche [Pesos]');
grid

%Medidas de ajuste

Media=mean(PL);
MSE=sum((PL-Ynet').^2)/length(PL);
EF = 1 - ((sum((PL-Ynet').^2))/(sum((PL-Media).^2)));
R=((sum((Ynet'-Media).^2))/(sum((PL-Media).^2)));
RMSE=sqrt(MSE)
MAE=sum(abs((PL-Ynet')))/numel(PL)

L=[MSE,RMSE, MAE, EF, R];

xlswrite('ajuste.xlsx', L , 'B3:F3' );

IW=net4.IW{1,1}
LW=net4.LW{2,1}
b=net4.b{1}

save net4

xlswrite('Prec.xlsx','PESOS IW',2,'A1');
xlswrite('Prec.xlsx',IW,2,'A2');
xlswrite('Prec.xlsx','PESOS LW',2,'A16');
xlswrite('Prec.xlsx',LW,2,'A17');
xlswrite('Prec.xlsx','SESGOS b',2,'A19');
xlswrite('Prec.xlsx',b,2,'A20');

save 'net4.mat' net4

pause

%Se elige la red con 4 nodos en la capa oculta, presenta la mayor
%eficiencia (94%).

%Llamando red

net4

%Etapa de evaluación 10% de datos.
Datos=xlsread('DatosLlenos2.xlsx',1,'A2:J43');

PTIEM=Datos(40:43,1);
PPL=Datos(40:43,2);
PPrL=Datos(40:43,3);
PPM=Datos(40:43,4);
PPS=Datos(40:43,5);
PILD=Datos(40:43,6);
PILP=Datos(40:43,7);
PIY=Datos(40:43,8);
PIM=Datos(40:43,9);

```

```

PIQ=Datos(40:43,10);

Pp=[PPrL,PPM,PPS,PILD,PILP,PIY,PIM,PIQ];
tt=[PPL];

[pn1 ps1]=mapminmax(Pp);
[tn1 ts1]=mapminmax(tt);
Ysim1 = sim(net4,pn1);

Ynet1 = mapminmax('reverse',Ysim1,ts1)

plot(PTIEM,PPL',PTIEM,Ynet1,'-g','Linewidth',1);
title('Simulacion');
legend('Real','Estimado');
xlabel('Tiempo');
ylabel('Precio L $/lt');
grid

pause

subplot(1,1,1);
[mt,bt,rt]=postreg(PPL',Ynet1);
title('Regresión Lineal');
xlabel('Precio Medido');
ylabel('Precio Predicho');
grid

pause

%Medidas de ajuste

PMSE=sum((PPL-Ynet1').^2)/length(PPL);
PMedia=mean(PPL);
PEF = 1 - ((sum((PPL - Ynet1').^2))/(sum((PPL-PMedia).^2)));
PR=((sum((Ynet1'-PMedia).^2))/(sum((PPL-PMedia).^2)));
PRMSE=sqrt(PMSE)
PMAE=sum(abs((PPL-Ynet1')))/numel(PPL)

PL=[PMSE,PRMSE, PMAE, PEF, PR];

xlswrite('Pajuste.xlsx', L , 'B2:F2' );
xlswrite('Pajuste.xlsx',{'PMSE"}, 1, 'B1')
xlswrite('Pajuste.xlsx',{'PRMSE"}, 1, 'C1')
xlswrite('Pajuste.xlsx',{'PMAE"}, 1, 'D1')
xlswrite('Pajuste.xlsx',{'PEF"}, 1, 'E1')
xlswrite('Pajuste.xlsx',{'PR"}, 1, 'F1')

pause

```