

**MODELO DEEP LEARNING PARA  
MEJORAR LA PREDICCIÓN DE LAS  
VENTAS EN LA EMPRESA }  
SAN FERNANDO S.A.C. LIMA**

**Alexander Suarez  
Jorge Nolasco  
Roberto Casas  
Javier Gamboa  
Ivan Crispin**



MODELO DEEP LEARNING PARA MEJORAR LA PREDICCIÓN DE LAS  
VENTAS EN LA EMPRESA SAN FERNANDO S.A.C., LIMA

**Autores:**

- 2.1 Ing. ALEXANDER CRISTHIAN\_SUAREZ ROMERO,
- 2.2 Mg. JORGE SANTIAGO NOLASCO VALENZUELA
- 2.3 Dr. ROBERTO JOSE MARIA CASAS MIRANDA
- 2.4 Dr. JAVIER GAMBOA CRUZADO
- 2.5 Mg. IVAN CRISPIN SANCHEZ

La presente obra fue revisada por 2 pares académicos externos ciegos conforme al proceso editorial del Centro de Investigación Latinoamericano para el Desarrollo e Innovación CILADI. Los rigurosos procedimientos editoriales de CILADI garantizan la selección de manuscritos por sus aportes significativos al conocimiento y cualidades científicas. Todas las obras publicadas por CILADI cuentan con ISBN y se encuentran disponibles en la web ([www.ciladi.org](http://www.ciladi.org))



Centro de Investigación Latinoamericano  
para el Desarrollo e Innovación  
Guayaquil- Ecuador  
<https://ciladi.org/>

AÑO 2024

Copyright © 2024

Todos los derechos reservados.

ISBN: 978-9942-696-01-4

## PRÓLOGO

El presente libro explora el fascinante mundo de la inteligencia artificial aplicada a la predicción de ventas, un tema que combina innovación tecnológica y estrategias empresariales. En un contexto global donde la competencia y la gestión eficiente de recursos son críticas para el éxito corporativo, esta obra demuestra cómo herramientas avanzadas como el Deep Learning pueden transformar las prácticas empresariales, optimizando la toma de decisiones y mejorando los resultados.

La investigación presentada se destaca por su rigor metodológico y por ofrecer una solución práctica y escalable a un problema complejo en la gestión empresarial: la predicción precisa de ventas. El uso de redes neuronales y metodologías como CRISP-DM no solo garantiza resultados altamente precisos, sino que también introduce un enfoque adaptable a distintos contextos empresariales. Esto posiciona al libro como una referencia esencial para profesionales y académicos interesados en la intersección de tecnología, datos y negocios.

Al mismo tiempo, esta obra nos invita a reflexionar sobre el impacto transformador de la inteligencia artificial en las empresas y la sociedad. Más allá de su aporte técnico, representa una guía para la integración ética y efectiva de estas tecnologías, promoviendo un uso consciente y estratégico que beneficia tanto a las organizaciones como a sus comunidades.

PhD. Antonio Poveda G.  
Editor

## INDICE GENERAL

<b>I.</b>	<b>INTRODUCCION .....</b>	<b>10</b>
1.1	Descripción y formulación del problema .....	12
1.2	Antecedentes .....	15
1.3	Objetivos.....	21
	-Objetivo General.....	22
	-Objetivos Específicos .....	22
1.4	Justificación.....	23
1.5	Hipótesis .....	26
<b>II.</b>	<b>MARCO TEORICO.....</b>	<b>27</b>
2.1.	Bases teóricas sobre el tema de investigación.....	27
<b>III.</b>	<b>METODO .....</b>	<b>61</b>
3.1	Tipo de investigación .....	61
3.2	Ámbito temporal y espacial .....	63
3.3	Variables.....	64
3.4	Población y muestra. ....	67
3.5	Instrumentos .....	69
3.6.	Procedimientos.....	76
3.7.	Análisis de datos.....	76
3.8	Consideraciones éticas.....	77
<b>IV.</b>	<b>RESULTADOS .....</b>	<b>78</b>
<b>V.</b>	<b>DISCUSION DE RESULTADOS .....</b>	<b>102</b>
<b>VI.</b>	<b>CONCLUSIONES .....</b>	<b>107</b>
<b>VII.</b>	<b>RECOMENDACIONES .....</b>	<b>109</b>
<b>VIII.</b>	<b>REFERENCIAS .....</b>	<b>110</b>

## INDICE DE TABLAS

<b>Tabla 1.</b> <i>Validez del instrumento mediante juicio de expertos.....</i>	73
<b>Tabla 2.</b> <i>Determinación del nivel de confiabilidad de los instrumentos .....</i>	75
<b>Tabla 3.</b> <i>Fiabilidad del Instrumento.....</i>	75
<b>Tabla 4.</b> <i>Prueba de Normalidad.....</i>	91
<b>Tabla 5.</b> <i>Comparación de la variable dependiente, predicción de ventas según la percepción de los trabajadores de la empresa San Fernando S.A.C.....</i>	93
<b>Tabla 6.</b> <i>Comparación de la dimensión 1: Nivel de predicción del monto de las ventas según la percepción de los trabajadores de la empresa San Fernando S.A.C. ....</i>	95
<b>Tabla 7.</b> <i>Niveles de Predicción de Fechas según la percepción de los trabajadores de la empresa San Fernando S.A.C.....</i>	96
<b>Tabla 8.</b> <i>Resultados inferenciales de la Hipótesis Especifica 1 .....</i>	98
<b>Tabla 9.</b> <i>Resultados inferenciales de la Hipótesis Especifica 2 .....</i>	99
<b>Tabla 10.</b> <i>Resultados inferenciales de la Hipótesis General .....</i>	101

## INDICE DE FIGURAS

<b>Figura 1.</b> <i>Cuadrante Mágico de Gartner de Plataformas de Análisis e Inteligencia de Negocios</i> .....	21
<b>Figura 2.</b> <i>Supervised learning Workflow</i> .....	35
<b>Figura 3.</b> <i>Decisión Tree</i> .....	35
<b>Figura 4.</b> <i>Máquina de soporte de vectores</i> .....	38
<b>Figura 5.</b> <i>Aprendizaje no supervisado</i> .....	39
<b>Figura 6.</b> <i>Red Neuronal Deep Learning</i> .....	41
<b>Figura 7.</b> <i>Aprendizaje profundo como parte de la inteligencia artificial</i> .....	43
<b>Figura 8.</b> <i>Función Sigmoid</i> .....	50
<b>Figura 9.</b> <i>Perceptrón en su versión más simple de su red neuronal</i> .....	51
<b>Figura 10.</b> <i>Multilayer perceptrón, con varias capas ocultas</i> .....	52
<b>Figura 11.</b> <i>Diseño Preexperimental</i> .....	63
<b>Figura 12.</b> <i>Librerías de Redes Neuronales.</i> .....	80
<b>Figura 13.</b> <i>Importar data ventas</i> .....	81
<b>Figura 14.</b> <i>Limpieza de columnas</i> .....	81
<b>Figura 15.</b> <i>Selección de Columnas</i> .....	81
<b>Figura 16.</b> <i>Conversión de tipos de datos</i> .....	82
<b>Figura 17.</b> <i>Listado de Columnas</i> .....	82
<b>Figura 18.</b> <i>Agrupación de Datos</i> .....	83
<b>Figura 19.</b> <i>Visualizar número de registros</i> .....	83
<b>Figura 20.</b> <i>Mapas de calor</i> .....	84
<b>Figura 21.</b> <i>Datos de Entrenamiento</i> .....	86
<b>Figura 22.</b> <i>Evaluación de la calidad del modelo</i> .....	88
<b>Figura 23.</b> <i>Rendimiento predictivo del modelo completo</i> .....	90
<b>Figura 24.</b> <i>Niveles de la variable de Predicción de ventas</i> .....	93
<b>Figura 25.</b> <i>Niveles de la dimensión Predicción de Montos de las Ventas</i> .....	95
<b>Figura 26.</b> <i>Niveles de la dimensión Predicción de Fechas de las ventas</i> .....	97



## Resumen

El estudio tuvo una orientación cuantitativa, diseño experimental, cuya finalidad fue determinar en qué medida el modelo Deep learning puede producir una mejora de la predicción de las ventas en la Empresa San Fernando S.A.C., 2023. Se tomó en cuenta una investigación con diseño preexperimental, de tipo aplicada. La población del presente trabajo de investigación estuvo conformada por 50 trabajadores del departamento de ventas, según criterios del investigador. En el recojo de los datos, se empleó la base datos histórica de la empresa San Fernando, dichos datos fueron procesados a través de algoritmos de redes neuronales convulsionadas. De la misma manera, se aplicó un método de estructuras Inteligentes denominado Crisp-DM que proviene del inglés Cross Industry Standard Process for Data Mining, que traducido es “Proceso Estándar Inter-Industrias para Minería de Datos”. El fin de este método es realizar modelos partiendo por analizar los datos de un negocio para adelantarse a errores futuros y dar solución a la elaboración del modelo con una dirección sólida considerando la temporalidad y el sistema de los datos. El paso siguiente sería poner en práctica el modelo y realizar la evaluación de su desempeño empleando grupos de información de prueba para conseguir hallazgos precisos acerca de la capacidad predictiva de las Redes Neuronales en ese contexto, para finalizar se tuvo como conclusión que el modelo se ha determinado con los pesos de adiestramiento con relación a los pesos de predicción  $R^2$  is: 0.9970536105123016, es con una aproximación del 99%.

*Palabras clave:* Aprendizaje profundo, Crisp-DM, pronósticos de ventas, series temporales, historial de ventas.

## Abstract

The study had a quantitative orientation, experimental design, whose purpose was to determine to what extent the Deep learning model can produce an improvement in the prediction of sales in the Company San Fernando S.A.C., 2023. An investigation with a pre-experimental design was taken into account, applied type. The population of this research work was made up of 50 workers from the sales department, according to the researcher's criteria. In collecting the data, the historical database of the San Fernando company was used; said data were processed through convulsed neural network algorithms. In the same way, a method of Intelligent structures called Crisp-DM was applied, which comes from the English Cross Industry Standard Process for Data Mining, which translated is “Inter-Industry Standard Process for Data Mining”. The purpose of this method is to make models starting by analyzing the data of a business in order to anticipate future errors and provide a solution to the development of the model with a solid direction considering the temporality and the data system. The following step would be to put the model into practice and to carry out the evaluation of its performance using groups of test information to obtain precise findings about the predictive capacity of the Neural Networks in that context, to finish it was concluded that the model has been determined with the weights of training in relation to the weights of prediction  $R^2$  is: 0.9970536105123016, it is with an approximation of 99%.

*Keywords:* Deep learning, Crisp-DM, sales forecasts, time series, sales history.

## I. INTRODUCCION

La Inteligencia Artificial (IA), según Russell y Norvig (2020), ha emergido como una de las fuerzas más transformadoras en la tecnología moderna, redefiniendo los paradigmas en numerosos campos y sectores. Dentro de la esfera de la IA, el Machine Learning (ML) representa un avance significativo, proporcionando a las máquinas la capacidad de aprender y mejorar a partir de la experiencia sin ser explícitamente programadas. Esta afirmación respalda el hecho de que el enfoque en el aprendizaje y adaptación automática ha allanado el camino para desarrollos notables en la automatización y el análisis de datos.

El Deep Learning, una subcategoría especializada del Machine Learning, representa un salto evolutivo adicional. Utiliza redes neuronales artificiales de múltiples capas para emular el procesamiento de información y patrones de aprendizaje del cerebro humano. Esta capacidad para procesar grandes volúmenes de datos complejos ha hecho del Deep Learning una herramienta indispensable en aplicaciones que van desde el reconocimiento de voz y de imágenes hasta la conducción autónoma" (Russell & Norvig, 2020, p. 45).

Las predicciones de ventas, fundamentales en la planificación estratégica y operativa de las empresas, se han transformado significativamente gracias a la precisión y eficiencia que aporta el Deep Learning. La habilidad de esta tecnología para analizar y aprender de extensos conjuntos de datos permite a los modelos de Deep Learning identificar patrones y tendencias que son difíciles de detectar mediante métodos tradicionales. Esta capacidad de revelar insights ocultos no solo beneficia a aplicaciones tecnológicas o de consumo, sino que también extiende su influencia al ámbito corporativo, especialmente en el sector de la predicción de ventas. El potencial del Deep Learning, por lo tanto, trasciende más allá de sus aplicaciones iniciales, mostrando un impacto significativo en el mundo empresarial. (Ng, 2017).

Asimismo, el objetivo de la presente investigación es aplicar técnicas de Deep Learning con el fin de mejorar la precisión en la predicción de ventas en la empresa avícola San Fernando S.A.C. Se trata de una investigación aplicada que se apoya en un diseño experimental. Las unidades de análisis comprenden los datos de ventas recopilados durante el año 2023, así como los trabajadores del Departamento de Ventas. Para lograr este propósito, se implementa un modelo de redes neuronales profundas. Los instrumentos utilizados incluyen cuestionarios diseñados específicamente para la evaluación del rendimiento del modelo y los registros de ventas observados en la base de datos corporativa. Los resultados preliminares sugieren una mejora significativa en la precisión de las predicciones de ventas, lo que podría tener importantes implicaciones para la toma de decisiones empresariales.

Exploramos cómo esta tecnología avanzada, integrada de manera estratégica y operativa, puede proporcionar insights valiosos para la toma de decisiones, potenciando así la competitividad y el éxito en un entorno empresarial cada vez más guiado por datos. Esta investigación no solo aborda el aspecto tecnológico del Deep Learning, sino también su implementación práctica en un contexto empresarial real, considerando los retos y oportunidades que presenta para la optimización de procesos y la toma de decisiones basada en datos en la industria de ventas (Géron, 2019).

A continuación, se detalla el contenido del presente trabajo; En el capítulo I se describe el planteamiento del problema el cual comprende la fundamentación y formulación del problema, objetivos generales y específicos, justificación de la investigación. El capítulo II desarrolla el marco teórico; temas como Inteligencia Artificial, redes neuronales artificiales, DeepLearning, Prediccion de ventas en este capítulo. En el capítulo III se aborda el método aplicado en el desarrollo de la propuesta. En el capítulo IV se describe los resultados. En el capítulo V se formula la

discusión de resultados. En el capítulo VI se señalan las conclusiones. En el capítulo VII se precisan las recomendaciones. En el capítulo VIII se consigna las referencias y finalmente el capítulo IX contiene los principales anexos de la investigación.

### **1.1 Descripción y formulación del problema**

La descripción y formulación del problema se basa en la conceptualización previa realizada por autores especializados en el campo. Según Russell y Norvig (2020), la formulación del problema es esencial para definir claramente la situación problemática y establecer el propósito de la investigación.

El sector avícola en el Perú desempeña un papel crucial en la economía nacional, siendo una fuente importante de empleo e ingresos, así como un pilar fundamental en la seguridad alimentaria del país. Con una creciente demanda de productos avícolas tanto a nivel nacional como internacional, la industria se caracteriza por su constante evolución y competitividad.

Los desafíos en la industria avícola incluyen la volatilidad de los precios de los insumos, los cambios en la demanda del mercado, las regulaciones gubernamentales y los desafíos relacionados con la salud animal y la bioseguridad. En este contexto dinámico, las empresas avícolas se enfrentan a la necesidad de mantener altos estándares de calidad, eficiencia operativa y competitividad para asegurar su sostenibilidad y crecimiento en el mercado.

Dentro del sector avícola, la empresa San Fernando S.A.C. se destaca como una de las principales empresas del rubro en el país. Sin embargo, enfrenta desafíos específicos en su proceso de predicción de ventas. A pesar de contar con datos históricos y un equipo dedicado en el Departamento de Ventas, las predicciones actuales carecen de la precisión necesaria para tomar decisiones estratégicas informadas (Cavassa, 2021).

Los métodos tradicionales de predicción utilizados por San Fernando S.A.C. se basan en modelos estáticos y simplificados que no logran capturar la complejidad de los factores influyentes en las ventas, como las tendencias del mercado, los cambios estacionales y los eventos externos. Esta falta de precisión en las predicciones de ventas ha llevado a problemas como sobreinventarios o falta de stock, lo que afecta directamente a la eficiencia operativa y la satisfacción del cliente (Johnson, 2018).

Luego, nos adentraremos en la situación específica de la empresa San Fernando S.A.C. para comprender mejor sus necesidades y desafíos únicos en el ámbito de las ventas y la predicción de ventas. En este sentido, se plantea las siguientes interrogantes:

¿Existe relación lógica entre el proceso de ventas y las herramientas tecnológicas modernas?

Sí, la evolución de las tecnologías modernas ha transformado fundamentalmente la forma en que se llevan a cabo los procesos de ventas en las empresas. La automatización, la recopilación y análisis de datos en tiempo real, y la personalización de las interacciones con los clientes son solo algunos ejemplos de cómo las herramientas tecnológicas han impactado positivamente en el rendimiento de las ventas.

¿Qué tipo de relación existe?

La relación entre el proceso de ventas y las herramientas tecnológicas modernas es causal. Esto se debe a que la implementación efectiva de herramientas tecnológicas, como el Deep Learning, influye directamente en la mejora de los procesos de ventas y, en última instancia, en el rendimiento general de la empresa.

¿Dentro del abanico de la diversidad de herramientas tecnológicas modernas para soportar el proceso de ventas, cuáles serán las más adecuadas?

Entre las diversas opciones de herramientas tecnológicas modernas, el Deep Learning emerge como una de las más adecuadas debido a su capacidad para analizar grandes volúmenes de datos de manera eficiente y extraer patrones complejos y tendencias que son difíciles de detectar con métodos convencionales.

Este contexto presenta una oportunidad para aplicar modelos de Deep Learning, una tecnología emergente con un potencial significativo para mejorar la eficiencia operativa y el índice de crecimiento en ventas. Autores como Ng (2017) han destacado la capacidad del Deep Learning para ofrecer insights valiosos a partir de grandes conjuntos de datos históricos y actuales, lo que facilita una toma de decisiones más informada y efectiva en entornos empresariales.

Además, en el contexto peruano, donde el desarrollo comercial es altamente predecible y está influenciado por normativas específicas, la adopción de tecnologías como el Deep Learning es crucial para adaptarse a las dinámicas del mercado. Autores como Géron (2019) han enfatizado la importancia de la adopción de tecnologías innovadoras para mejorar la competitividad y la eficiencia en el entorno empresarial

### ***1.1.1. Problema general***

¿En qué medida el modelo Deep learning mejora la predicción de las ventas en la empresa San Fernando S.A.C., 2023?

### ***1.1.2 Problemas específicos***

¿En qué medida el modelo Deep learning mejora la predicción del monto de las ventas en la empresa San Fernando S.A.C., 2023?

¿En qué medida el modelo Deep learning mejora la predicción de las fechas de las ventas en la empresa San Fernando S.A.C., 2023?

## 1.2 Antecedentes

Los antecedentes cumplen un rol crucial. Su presentación no es meramente un repaso de estudios previos, sino una plataforma estratégica que subraya la profundidad y la relevancia de la investigación. Al explorar y citar trabajos anteriores, no solo establecemos un conocimiento sólido del campo del Deep Learning y su aplicación en la predicción de ventas, sino que también se justifica la necesidad imperante del estudio (Bengio, Courville & Vincent, 2015).

La revisión de la literatura existente no se limita a mostrar lo que ya se ha hecho; más bien, permite iluminar cómo el trabajo se distingue. Se identifica y destaca las brechas que aún persisten en la literatura, señalando, por ejemplo, la falta de aplicaciones específicas de estas tecnologías en el contexto de una empresa peruana como San Fernando S.A.C. Al hacerlo, no solo se reivindica la originalidad de la investigación, sino que también se establece un marco en el cual el estudio puede aportar un valor significativo y novedoso al campo (Goodfellow, Bengio & Courville, 2016).

En esencia, los antecedentes son el telón de fondo contra el cual la investigación se destaca. Al comparar el enfoque y metodología con estudios previos, resaltamos la unicidad de la contribución: una adaptación y aplicación de modelos de deep learning a desafíos y particularidades específicas de San Fernando S.A.C que no han sido abordadas antes (Hastie, Tibshirani & Friedman, 2009). Este ejercicio no es solo un requisito académico; es una oportunidad para demostrar cómo el estudio avanza el conocimiento existente, ofreciendo nuevas perspectivas y soluciones en el ámbito de la predicción de ventas y el análisis de datos en el sector empresarial (LeCun, Bengio & Hinton, 2015).

### *1.2.1. Antecedentes nacionales*

En su estudio Julca (2020) Empleo de aprendizaje profundo en función a imágenes topográficas para la mejora de la precisión del diagnóstico de queratocono en una clínica de Lima. Actualmente, las TIC han aportado diversos beneficios a las distintas industrias, siendo el sector de la salud uno de los beneficiarios clave. El objetivo central fue llevar a cabo categorizaciones de imágenes topográficas mediante algoritmos de Aprendizaje profundo en el lugar de estudio, especializada en cirugía refractiva oftalmológica. Para ello, se recopiló imágenes producidas por el OPD - Scan III, con el propósito de categorizar ojos saludables y aquellos afectados por queratocono. El principal objetivo de este trabajo fue emplear herramientas tecnológicas capaces de clasificar de manera precisa imágenes topográficas de queratocono, utilizando el aprendizaje para detectar estructuras para facilitar detección preventiva.

El método empleado para llevar a cabo las clasificaciones fue mediante el empleo de algoritmos de red neuronal convolucionales, junto con un procedimiento de preprocesamiento de imágenes destinado a eliminar el ruido que podría afectar el aprendizaje de las redes neuronales. Este enfoque dio el hallazgo que 1908 imágenes se catalogaron de forma correcta de un conjunto de 2073 imágenes, que abarcaban ojos normales y aquellos afectados por queratocono. La precisión alcanzada fue del 92.04%.

Alegre y Lozano (2022), en sus estudios Empleo de Métodos de aprendizaje profundo en Series de Tiempo Para el vaticinio del aspecto Macroeconómico En América Latina, estudio dirigido a estructuras inteligentes; la metodología de aprendizaje profundo se puede emplear en la producción de formas de predicción. Se trabaja con el (PBI) de 6 naciones de Latinoamérica: que usaron aspectos macroeconómicos del año y trimestre, del Banco Mundial y (CEPAL). En el preprocesamiento de la información, a las series del trimestre se adicionaron como rasgos



añadidos la disgregación de ellas en tendencia, estacionalidad y residuo, con el propósito de brindar mayor cantidad de datos al modelo. Además, se cambió información atípica por efecto del COVID-19 en el aspecto económico del mundo. Se elaboraron modelos de Perceptrón Multi Capa, Red Neuronal Convolucional, LSTM, GRU y SeqToSeq en cada nación y grupos de series, y después se hizo la evaluación a través de validez cruzada continua y métrica MAE, RMSE y MAPE. Los modelos que son imponderables se modifican para cada situación, en Perú el RMSE vs MLP = 0.038643 y MAPE vs. Seq2Seq=0.7486841.

Ordoñez (2020), en su trabajo denominado: Aprendizaje profundo para la Visión Artificial E Identificación del Personal Administrativo Y Docente De La Universidad Nacional Micaela Bastidas, Apurímac. La finalidad fue alcanzar el nivel más alto de precisión al identificar a los empleados de administración y profesores del centro superior mencionado, empleando Deep Learning; para ello se dividió en dos fases. La primera estuvo orientada a adiestrar en la arquitectura clásica VGG16 y este modelo se transformó en VGG16UNAMBA en el que se adiestró imágenes conseguidas por medio de una cámara de video. En la siguiente etapa se empleó arquitectura moderna denominada DenseNet121, la que se transformó hasta conseguir DenseNet121UNAMBA, con la que se adiestró igual número de imágenes, para seleccionar la del nivel más alto de precisión producida por ambas fases.

La exploración se realizó en UNAMBA en el 2019 en Tamburco – Abancay con 242 individuos (administrativos y profesores); el procedimiento necesitó diez imágenes por individuo para el adiestramiento de las Redes Neuronales Convolucionales; se empleó metodologías de Video Scraping y data augmentation para alcanzar 27,996 imágenes, las que se fraccionaron en 19,700 para el adiestramiento y 8,296 imágenes para la validez de los modelos. Con respecto a los hallazgos en la primera etapa, se adiestró con el VGG16UNAMBA, con la que se alcanzó

0.9805 de precisión; es así que en la fase 2 se empleó DenseNet121UNAMBA, con la que se alcanzó 0.9932 de precisión.

### ***1.2.2. Antecedentes internacionales***

De acuerdo con Orellana (2019), en su estudio desarrollado en Chile, en el trabajo "Detección de grietas a través de aprendizaje profundo en base a imágenes en concreto". La segmentación de grietas en estructuras de concreto se destaca como una acción relevante. Esto se debe a que la presencia de grietas puede ocasionar problemas significativos si no se monitorean adecuadamente. La mayoría de los estudios anteriores sobre este tema se centran en la detección manual de grietas en lugar de adoptar un enfoque automático. Por ende, la solución propuesta consiste en emplear una red neuronal de machine learning para realizar la categorización y segmentación de grietas utilizando imágenes provenientes de la industria.

La detección de grietas es esencial en el mantenimiento de puentes para la evaluación de la salud y la garantía de la seguridad. Por lo general, este proceso se lleva a cabo mediante inspección visual realizada mayormente por personal de ingeniería. Sin embargo, este trabajo es desafiante, requiere mucho tiempo y puede verse afectado por la subjetividad del personal humano. Por esta razón, se propone la automatización de esta inspección a través del fraccionamiento de grietas mediante redes neuronales convolucionales. El propósito fundamental es lograr la detección automática de grietas en sistemas utilizando una red neuronal. Para alcanzar este objetivo, se han establecido fines secundarios esenciales, como el aprendizaje basado en el aprendizaje profundo y el adiestramiento de redes de fraccionamiento de grietas utilizando las imágenes proporcionadas.

El logro de la propuesta se centra en identificar de forma automática grietas y la comparación de modelos de segmentación para dicho propósito. Se plantea la creación de un

modelo de computación basado en aprendizaje profundo utilizando imágenes conseguidas del seguimiento de grietas en concreto. El método que se usará comprende la comprensión de los datos disponibles en una primera fase, seguida de una prueba de modelos de fragmentación y la implementación del modelo de computación importante para alcanzar los propósitos. Posteriormente, se aplica el modelo a la información disponible y se verifica la calidad de los resultados. Las etapas se repiten en un bucle continuo, ya que el modelo debe ser entrenado de forma constante para lograr niveles óptimos requeridos para alcanzar porcentajes aceptables para identificar y cuantificar las grietas.

Una vez que se logra un desarrollo óptimo y/o aceptable del modelo computacional basado en Deep Learning, se produce las conclusiones y los porcentajes de error en las medidas. Se concluye que el propósito se cumple, ya que se logra detener automáticamente grietas en función a las redes neuronales con resultados de Índice de Sobreposición (IOU) cercanos al 90 %, indicando una detección precisa. Además, se compara de métricas entre los modelos distintos: DeepLabV3+, Encoder-Decoder y Encoder-DecoderSkip.

Falconi (2021), a través de su trabajo de investigación “Algoritmos de Aprendizaje profundo usando Tensor Flow para tratar información de producción científica en la Universidad Técnica de Cotopax.”. Explora implementar Inteligencia Artificial, Red Neuronal y Algoritmos de aprendizaje profundo protegidos por Tensor Flow. Actualmente, estos enfoques experimentan una continua evolución y abren posibilidades nuevas para tratar y analizar grandes volúmenes de información, especialmente en estructuras puestos en la web. Los algoritmos del Deep learning se dedican a adiestrar y agrupar datos de ingreso sin monitoreo, mediante un proceso conocido como aprendizaje automático. Estos algoritmos tienen que ver con la abstracción de alto nivel, principalmente empleando información expresada en matrices.

El propósito de esta investigación es mejorar el grado de tomar decisiones no supervisadas en la Ecuciencia, plataforma científica almacenada en los servidores de la Universidad mencionada. Se empleará información relacionados con las Líneas y Sublíneas de estudio según la estructura del lugar de la indagación, como referencia para los análisis realizados con los algoritmos. Implementar algoritmos de Deep learning respaldados por Tensor Flow en el sistema Ecuciencia tendrá un impacto significativo. La plataforma científica después del análisis estará en condiciones de ofrecer predicciones más precisas sobre las categorizaciones de Líneas y Sublíneas de estudio

La primera validación se llevó a cabo mediante la técnica "holdout", reservando el 80% de toda la información para el adiestramiento y utilizando el 20% del resto para realizar tests en el modelo. Además, se aplicó el método de Cross-Validation, que proporciona una guía para validar los algoritmos de inteligencia artificial. En este proceso, se observó la viabilidad del modelo actual al lograr precisión arriba del 90%, lo cual, se clasifica en un rango relativamente elevado.

García (2020), en su estudio “Utilización del aprendizaje profundo en estructuras de sugerencia para disminuir la deserción en Educación Superior de Colombia”, indaga por hallar la forma de implementar un mecanismo de aprendizaje profundo que sea de efectivo, para evitar la deserción en los centros de estudios superiores, al minimizar la duración de detección y sugerencia de ayuda requerida en la que los educandos sigan su procedimiento educacional. El estado de Colombia es consecuente de los problemas que son parte de la deserción en los centros superiores, y por ello tiene decisiones que tratan de disminuir los porcentajes de este grave problema, pero hoy en día cualquier esfuerzo que se hizo no tuvo los resultados esperados.

Para complementar nuestra evaluación, nos apoyaremos en el Cuadrante Mágico de Gartner de Plataformas de Análisis e Inteligencia de Negocios, como se ilustra en la Figura 1. Esta figura proporciona una visión general de las principales plataformas en la nube reconocidas por su alta capacidad y amplitud de servicios en el ámbito del análisis y la inteligencia de negocios. Utilizaremos esta referencia para contextualizar nuestra investigación y evaluar la posición relativa de las plataformas consideradas en términos de su idoneidad para nuestras necesidades.

### Figura 1.

*Cuadrante Mágico de Gartner de Plataformas de Análisis e Inteligencia de Negocios*



*Nota.* Es una herramienta de investigación y análisis utilizada para proporcionar una visión cualitativa del mercado y la posición de diferentes proveedores en un área tecnológica específica.

## 1.3 Objetivos

Los objetivos juegan un rol crucial. El propósito general de esta investigación es establecer hasta qué punto el modelo de Deep Learning puede optimizar la predicción de ventas en la empresa, marcando el rumbo y el propósito central del estudio. Los propósitos específicos, enfocados en mejorar la predicción tanto del monto como de las fechas de las ventas, sirven como

pilares detallados que orientan cada paso del proceso investigativo. Estos objetivos no solo delimitan claramente la meta del proyecto, sino que también son esenciales para definir la metodología a seguir y los criterios para evaluar el éxito del estudio. Según Bengio y LeCun (2015), establecer objetivos específicos en una investigación es fundamental para guiar el proceso investigativo y asegurar la coherencia entre los objetivos y los métodos utilizados.

Además, subrayan la importancia de la investigación en el contexto empresarial actual, donde predecir con precisión las ventas es clave para la planificación estratégica y la eficiencia operativa. A través de estos objetivos, la investigación promete no solo avanzar en el conocimiento técnico sobre el uso de Deep Learning en predicciones de ventas, sino también contribuir significativamente al campo del análisis de ventas y negocios. En definitiva, los objetivos establecidos son la brújula que guía y da significado a toda la investigación. (Ng, 2017, p. 55).

*-Objetivo General*

Determinar en qué medida el modelo Deep learning mejora la predicción de las ventas en la Empresa San Fernando S.A.C., 2023.

*-Objetivos Específicos*

1. Determinar en qué medida el modelo Deep learning mejora la predicción del monto de las ventas en la Empresa San Fernando S.A.C., 2023.
2. Determinar en qué medida el modelo Deep learning mejora la predicción de las fechas de las ventas en la Empresa San Fernando S.A.C., 2023.

## **1.4 Justificación**

En la investigación, la justificación cumple un rol crucial, ya que establece la relevancia y la necesidad del estudio. Según Bengio (2013), la justificación es el fundamento que respalda la realización de la investigación, explicando por qué es importante abordar el tema y qué contribuciones se esperan obtener. Además, Hochreiter y Schmidhuber (1997) señalan que la justificación es esencial para convencer a los lectores, revisores o financiadores de que la investigación merece atención y recursos. En este sentido, la falta de apoyo en la literatura especializada en metodología puede debilitar la credibilidad del estudio, como advierten LeCun et al. (2015).

En la presente investigación, la justificación se puede dividir en tres tipos principales, cada uno con su propia importancia:

### ***1.4.1. Justificación teórica***

Este estudio se respalda en conocimientos teóricos al comparar algoritmos de aprendizaje automático con el objetivo de prever con alta precisión los montos y los períodos de ventas. Este enfoque busca facilitar la identificación del volumen de ventas mediante el análisis del historial de la organización. Además, se comparó hallazgos conseguidos con investigaciones previas en el mismo ámbito. Según Domingos y Gama (2019), la comparación de algoritmos de aprendizaje automático es esencial para identificar el enfoque más eficaz en la predicción de ventas, especialmente cuando se busca alta precisión en la estimación tanto de montos como de períodos de ventas.

### ***1.4.2. Justificación práctica***

La justificación práctica de este trabajo es fundamental, ya que aborda y da solución a un problema concreto, al mismo tiempo que propone estrategias aplicables para la resolución y aporte

tecnológico. La creación de un modelo predictivo en este contexto permite desarrollar un software de ayuda institucional que puede identificar el problema principal, que es la falta de flexibilidad en la fijación del precio de venta del pollo asociados con los precios de insumos. Además, se destaca la oportunidad de beneficiar en un nivel alto de los medios tecnológicos para alcanzar los objetivos de venta antes de lo advertido. Según Goodfellow, Bengio y Courville (2016), la aplicación de modelos predictivos en contextos empresariales proporciona una herramienta valiosa para abordar problemas específicos y mejorar la eficiencia en la fijación de precios y la gestión de inventarios.

#### ***1.4.3. Justificación metodológica***

Esta indagación tiene como finalidad contribuir al saber de hoy acerca de la aplicación de tecnología predictiva como herramienta para un manejo de ventas óptima. Los hallazgos obtenidos podrían ser integrados al corpus de conocimiento en el ámbito de las ciencias empresariales, demostrando que la utilización de tecnologías predictivas potenciando de forma eficaz la capacidad de prever las ventas en la institución San Fernando S.A.C.

En el ámbito de la ciencia de la información, aplicamos el método CRISP-DM para el tratamiento de datos. Utilizamos el Coeficiente de Determinación ( $R^2$ ), denominado también como test de bondad de ajuste, como métricas para evaluar desempeños de los modelos. Esta métrica muestra la cantidad de variedad en la categoría dependiente que predijo a partir de la variable independiente. De otro modo, refleja la eficacia del ajuste del modelo a las observaciones reales disponibles. Sin embargo, es importante señalar que el  $R^2$  por sí mismo no proporciona información sobre la calidad intrínseca del modelo, como si es bueno o malo, si hay sesgo en los datos o si se ha seleccionado el método adecuado. Generalmente, se considera que un modelo es aceptable cuando su rendimiento es superior al 70%. Según Hastie y Tibshirani (2017), el Coeficiente de



Determinación es una herramienta crucial en la evaluación del rendimiento de los modelos predictivos, ya que proporciona una medida cuantitativa de la capacidad del modelo para explicar la variabilidad en los datos observados.

#### ***1.4.4. Importancia en la investigación***

La implementación de Deep Learning en el análisis y postprocesamiento de datos históricos se revela como una contribución significativa para la predicción de ventas (Hinton et al., 2012). Este enfoque ha sido respaldado por autores como Goodfellow, Bengio y Courville (2016), quienes destacan la eficacia de las técnicas de Deep Learning en la mejora de las predicciones en diversos campos, incluido el análisis de ventas.

El procesamiento a nivel de disponibilidad puede ser llevado a cabo por profesionales especializados en el área de análisis de datos y aprendizaje automático (Bishop, 2006). Además, autores como LeCun, Bengio y Hinton (2015) han señalado que la aplicación de técnicas avanzadas de Deep Learning puede servir como un mecanismo de respaldo para los operadores involucrados en la investigación, al agilizar y simplificar el diagnóstico y monitoreo de datos.

En resumen, la implementación de Deep Learning en el análisis de datos históricos representa una innovación significativa respaldada por la investigación de expertos en el campo (Schmidhuber, 2015). Este enfoque promete reducir la duración de respuesta en los pronósticos de ventas, brindando así una ventaja competitiva a las empresas que lo emplean.

#### ***1.4.5. Limitación en la investigación***

En las restricciones en la elaboración del modelo del aprendizaje profundo radica en la elección del conjunto de variables para la realización del pronóstico. Aunque los resultados finales pueden ser altamente prometedores, sería óptimo considerar la posibilidad de ejecutar un modelo más complejo mediante la inclusión de más variables y abarcando un rango histórico de

datos más extenso, en caso de ser necesario. Según Bengio (2012), esta ampliación del modelo puede mejorar la precisión de las predicciones al capturar mejor la complejidad de los datos subyacentes.

## 1.5 Hipótesis

La formulación de hipótesis desempeña un papel esencial en el proceso de investigación científica, sirviendo como una proposición tentativa que busca explicar fenómenos observados. Esta etapa inicial proporciona una dirección clara para la investigación, estableciendo expectativas y delineando los objetivos que se persiguen. Es un componente fundamental que guía el diseño y la ejecución del estudio, orientando la recopilación y análisis de datos con el fin de probar o refutar la hipótesis planteada (Hinton, 2008).

Además, autores como Geoffrey Hinton (2012) han destacado la importancia de la formulación de hipótesis en el contexto de la inteligencia artificial y el aprendizaje profundo, subrayando su papel en la generación de nuevas ideas y enfoques para la investigación en estos campos.

### - *Hipótesis general*

El modelo Deep learning mejora la predicción de las ventas en la Empresa San Fernando S.A.C., 2023.

### - *Hipótesis específicas*

1. El modelo Deep learning mejora en la predicción del monto de las ventas en la Empresa San Fernando S.A.C., 2023.
2. El modelo Deep learning mejora en la predicción de las fechas de las ventas en la Empresa San Fernando S.A.C., 2023.

## II. MARCO TEORICO

En este estudio, el investigador se prepara para presentar el marco teórico, reconociendo que es un componente esencial de la investigación. Este marco no solo proporciona la base conceptual y teórica sobre la que se construye el estudio, sino que también ayuda a contextualizar la investigación dentro del campo existente del Deep Learning y la predicción de ventas (LeCun, Bengio, & Hinton, 2015). El investigador, consciente de la importancia de este marco, se propone detallar las teorías, modelos y estudios previos que son relevantes para su investigación, con el fin de establecer un fundamento sólido y justificar la metodología y las hipótesis propuestas (Kotler & Keller, 2016).

El marco teórico actúa como un mapa que guía la investigación, permitiendo al investigador situar su estudio dentro del ámbito académico y práctico más amplio (Yin, 2018). Al hacerlo, demuestra una comprensión profunda del campo y asegura que la investigación se basa en una base teórica sólida y relevante (Creswell, 2014). Este enfoque garantiza que el estudio no solo sea metodológicamente sólido, sino también significativamente anclado en el conocimiento existente, facilitando así una contribución valiosa y coherente al campo de estudio.

### 2.1. Bases teóricas sobre el tema de investigación

Las bases teóricas de esta investigación proporcionan el marco conceptual esencial, sustentando el estudio con conocimientos previos y teorías pertinentes en el campo. Estas fundamentaciones orientan la metodología y contribuyen a la comprensión y contextualización de los resultados. Además, según los planteamientos de Russell y Norvig (2010) en su obra clásica "Inteligencia Artificial: Un Enfoque Moderno", se resalta la importancia de integrar los principios y avances en inteligencia artificial para enriquecer tanto la comprensión teórica como la aplicación práctica de los resultados obtenidos.

### ***2.1.1. Inteligencia artificial***

La Real Academia Española (2021) conceptualiza la inteligencia artificial como un tema científico dedicado a desarrollar programas de informática que realizan sistematizaciones semejantes a las que hace la mente de los seres humanos, tales como el aprendizaje o el raciocinio lógico. Por ejemplo, las personas a menudo emplean el razonamiento en diversas actividades, como identificar a un amigo en un centro comercial. En este caso, reconocen características específicas como el color del cabello, la forma de la nariz o la curva de la cara para lograr dicha identificación.

La inteligencia artificial busca replicar las tareas, pues de acuerdo con Oracle México (2020), tiene que ver con estructuras o máquinas que reproducen la inteligencia humana para llevar a cabo acciones iterativas que permiten recopilar información. La inteligencia artificial y Deep learning experimentaron avances notables en términos de capacidad y acceso, impulsados por la abundancia de datos que las instituciones puedan acumular hoy en día, que vienen de distintas fuentes como bases de información institucionales, redes sociales, información gubernamental y financiera. Es relevante, tener en cuenta las normas de protección de información personal en este contexto.

La inteligencia artificial que se examinan en esta indagación incluye los Sistemas expertos. De acuerdo con Whitten (2008), se refieren a estructuras de información que capturan la experiencia de un usuario especialista para después aparentar esa vivencia en ventaja de usuarios no especialistas. Un representante destacado de las estructuras de especialistas como Alan Turing, quien planteó la implementación de una máquina que, en lugar de pugnar la mente adulta, lo hizo simulando la de un infante. De esta manera, en función de un procedimiento de aprendizaje y crecimiento cognitivo, la máquina llegaría a ser similar a la mente adultez.

La máquina de Turing, creada para organizar cualquier operación de cómputo, marcó un hito por 1940. Turing desarrolló un programa informático que posibilitaba el juego de ajedrez, defendiendo la idea de que las computadoras podrían manifestar conductas inteligentes. Fue en este contexto que planteó el test de Turing, la cual evaluaba si una computadora mostraba inteligencia a través de un juego de imitación, en el que también participaba un evaluador humano (Meseguer, P. López de Mántaras, 2017). Hoy en día, se puede observar el empleo de este modelo de estructura de especialista en la validez de algunas páginas web, en la que se solicita al usuario seleccionar una imagen asociada con una palabra recomendada para la verificación de la interacción con un individuo.

**2.1.1.1. Machine Learning.** A través de la evolución, las personas han empleado diversos mecanismos para simplificar distintas actividades. La inventiva del cerebro humano hizo la creación de diversas máquinas, las cuales mejoran la calidad de vida al satisfacer distintos requerimientos fundamentales, abarcando aspectos como viajes, industrias y los medios informáticos. El machine learning se encuentra entre estos inventos.

Machine Learning, según la definición de (Gori, 2018), se establece como una clase de inteligencia artificial que otorga a una estructura (ya sea hardware y/o software) la habilidad de aprendizaje sin necesidad de ser programado de manera explícita. Esta disciplina, según (Hurwitz & Kirsch, 2018), forma parte de la inteligencia artificial y facilita que una estructura aprenda en función al grupo de información dependiendo de una programación de forma explícita. Asimismo, el aprendizaje automático, de acuerdo con (Müller & Guido, 2016), hace que el saber de la información. Las estrategias vinculadas al machine learning se convierte en ubicuas en prácticamente todas las tareas de la vida diaria, abarcando desde sugerencias automáticas como la elección de films, preferencias alimenticias y adquisiciones de productos, hasta la

identificación de amigos en imágenes. Muchas aplicaciones y dispositivos contemporáneos se apoyan en algoritmos de machine learning para sus operaciones.

De acuerdo (Mueller & Guido, 2016) existe dos modalidades para las dificultades de aprendizaje; el supervisado y no supervisado; no obstante (Hurwitz & Kirsch, 2018) añade que el aprendizaje por refuerzo y profundo también son orientaciones cruciales dentro del campo del machine learning. El aprendizaje supervisado, de acuerdo con (Mueller & Guido, 2016), utiliza información de ingreso, conocidos como rasgos, junto con egresos deseados; el algoritmo busca una forma de generar el egreso deseado en función de un ingreso específico. Este algoritmo puede generar o hacer predicción un egreso para información de ingreso sin requerir la intervención humana. Por otro lado, según (Hurwitz & Kirsch, 2018), el aprendizaje supervisado se inicia con un conglomerado de información que incluye rasgos y una etiqueta que proporciona significativamente la información

El aprendizaje supervisado posee como propósito indagar y hacer el reconocimiento de estructuras en la información analizada. Esto se emplea en una gran cantidad de dificultades comerciales, como detectando fraudes, enfermedades, estructuras de sugerencias o reconocimientos de voz. En este modelo, el algoritmo receptiona solamente información de ingreso o rasgos y no brinda etiquetas de la información de ingreso conocido, en otras palabras, no proporciona la significatividad de la información. (Mueller & Guido, 2016) El aprendizaje no supervisado de acuerdo (Hurwitz & Kirsch, 2018) se emplea fundamentalmente cuando se encuentra un problema con gran número de información de solo rasgos, sin etiqueta. Los algoritmos de aprendizaje no supervisados dividen los grupos de información en conjuntos de ejemplos (clústeres) o rasgos especiales. La información sin etiquetar crea los valores de los parámetros y la categorización de la información. En el aprendizaje por reforzamiento de acuerdo

(Hurwitz & Kirsch, 2018) el algoritmo recepciona retroalimentación del usuario, para analizar la información y conseguir mejores resultados; es decir, se aprende con la motivación que brinda un alto peso si se acerca al propósito, un bajo peso si existe falla en los resultados. El aprendizaje profundo es una clase de aprendizaje que está basado en red neuronal y se emplea para dificultades con mayor complejidad como dificultades al aprender con imágenes. Los algoritmos de machine learning supervisado se categoriza en dos clases de dificultades de clasificación y regresión.

De acuerdo con (Mueller & Guido, 2016), en la clasificación, la finalidad es la predicción de la salida de la clase categórica, que es una opción en las probabilidades; si en las probabilidades están dos, se llama dificultades de clase binaria, pero si hay más de dos probabilidades, entonces se llama multiclase. De acuerdo con (Mueller & Guido, 2016), en la regresión la finalidad es pronosticar el egreso numérico, puede ser perenne o de punto flotante. El pronóstico de las entradas anuales de un individuo en función a ciertos rasgos como su educación, su edad y el espacio en el que habita es una actividad de regresión. El rol que tienen los algoritmos en el machine learning es fundamental; estos conceptualizan como un grupo de conocimientos graduales que debe hacer una estructura de cómo hacer la interacción, manipulación y transformación de la información. Un algoritmo debe tener simpleza como hacer operaciones matemáticas con dos números o tan complicado como hacer el reconocimiento de un objeto en una imagen.

De acuerdo a (Hurwitz & Kirsch, 2018) las clases de algoritmos de aprendizaje automático son los Bayesianos, conglomerado (clustering), árboles de decisión, disminución de las dimensiones, en base a instancias, regresión lineal, normalización, cimentado en normas, red neuronal y de deep learning. En los problemas de aprendizaje supervisado los algoritmos que son

los más comunes según (Mueller & Guido, 2016) son: k-Nearest Neighbors. El algoritmo k-NN basado en el análisis de la información de la vecindad más cercana para realizar el pronóstico de un punto nuevo de información. El aspecto principal para analizar es la cantidad de vecinos para conseguir el mayor desempeño. Se puede hacer la implementación KNN para las dificultades de categorización y para los de deregresión.

Los modelos lineales. Son los que se emplean extensamente en la praxis y realizan el pronóstico empleando una función lineal de los rasgos de ingreso. Los modelos de este tipo son para dificultades de regresión entre ellos están: Regresión lineal ordinario, Regresión Ridge y regresión LASSO.

Los algoritmos de Regresión Logística y las Máquinas de Vectores de Soporte Lineal (Lineal SVM) son comúnmente empleados para abordar desafíos en la clasificación. En el caso de los Naive Bayes, forman una categoría de clasificadores que comparten similitudes con los modelos lineales, pero se destacan por su velocidad de entrenamiento, aunque su desempeño tiende a ser ligeramente inferior en comparación con clasificadores lineales y árboles de decisión. Los árboles de decisión, por otro lado, son extensamente empleados para actividades de categorización y regresión, ya que en el aprendizaje usan una serie de interrogante de tipo sí/no que conducen a una decisión. La elaboración de un árbol se avanza cuando las hojas son puras, a menudo resulta ser un modelo complicado.

El ensamblaje del árbol de decisión se refiere a metodología que mezcla variados modelos de machine learning con el fin de generar modelos más robustos y poderosos. Entre estos métodos, dos conjuntos han demostrado su eficacia en diversas situaciones de clasificación y regresión al emplear árbol de decisión: Random Forest y árbol de decisión que se impulsan por gradiente. Por otro lado, las Máquinas de Vectores de Soporte Kernelizadas, comúnmente



conocidas como SVM, representan una extensión que posibilita la creación de métodos con grado de complejidad que no se limitan solo a hiperplano en el lugar de ingreso. Estas SVM pueden utilizarse tanto para clasificación como para regresión. Otro enfoque relevante son las redes neuronales.

La categoría de algoritmos denominada "Deep learning" engloba diversas metodologías, entre los cuales el perceptron multicapa son los más elementales para tareas de clasificación y regresión. Estos perceptrones multicapa, también llamados red neuronal de retroalimentación o solo red neuronal, sirven como punto de partida para enfoques más avanzados de aprendizaje profundo. Además, el machine learning se conceptúa como espacio de trabajo que confiere a las PC la destreza de realizar aprendizaje sin requerir programación explícita. Samuel alcanzó renombre por su programa de juego de damas. Machine learning (ML) se emplea para dar lección a las máquinas a manejar información de forma eficiente. En algunos casos, la información extraída de los datos puede tener dificultad para la interpretación después de su análisis (Mahesh, 2019).

Se recurrió al uso de aprendizaje automático con el aumento de la disponibilidad de conglomerados de información, ya que el uso de esta disciplina está en permanente desarrollo. Diversos centros industriales emplean el machine learning con el fin de extraer información relevante de los datos. El objetivo central de esta técnica es aprender a partir de los datos contenidos en los grupos de información. Se realizaron numerosas indagaciones para desarrollar máquinas capaces de aprender de forma autónoma sin necesidad de programación explícita. Matemáticos y programadores aplican diversas estrategias para abordar este desafío, siendo uno de los enfoques más destacados la utilización de grupos extensos de información. El machine learning se apoya en una variedad de algoritmos para dar solución a las dificultades relacionados

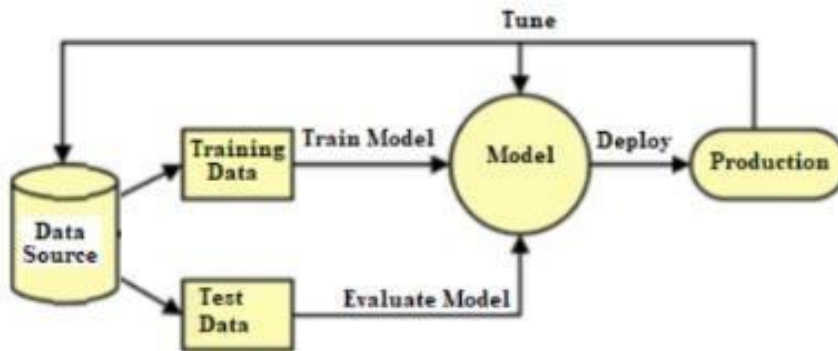
con la información. Los estudiosos de información enfatizan que no hay un algoritmo solo que pueda dar solución a todas las dificultades; la selección del algoritmo está en función a la clase de dificultad por dar solución, la cantidad de categorías, la metodología la más adecuada y otros aspectos.

A continuación, se presenta un breve repaso de algunos de los algoritmos más utilizados en el aprendizaje automático (ML).

**2.1.1.2. Aprendizaje supervisado.** Es una actividad dentro del ámbito del aprendizaje automático en la cual se busca aprender las funciones que relacionan un ingreso con su correspondiente salida, basándose en ejemplos de pares ingreso-salida. Este proceso implica inferir una función a partir de datos de adiestramiento etiquetados, que tiene que ver con un conglomerado de ejemplos de adiestramiento. Los algoritmos de aprendizaje supervisado son los que requieren asistencia del exterior. En este enfoque, el grupo de información de ingreso se clasifica en conjuntos de entrenamiento y prueba. El conjunto de entrenamiento incluye una variable de salida que se pretende predecir o clasificar. Los algoritmos supervisados aprenden patrones a partir de este grupo de información de adiestramiento y aplican estos saberes al grupo de prueba para realizar predicciones o clasificaciones.

La Figura 2 muestra el flujo de trabajo típico del aprendizaje supervisado, detallando las etapas clave desde la preparación de los datos hasta la evaluación del modelo. Este diagrama proporciona una representación visual clara de cómo se estructura el proceso de entrenamiento y evaluación en el contexto del aprendizaje supervisado. Nos basaremos en este flujo de trabajo como referencia visual durante nuestra discusión sobre el funcionamiento de los algoritmos supervisados y su aplicación en nuestro estudio (Richert & Coelho, 2013).

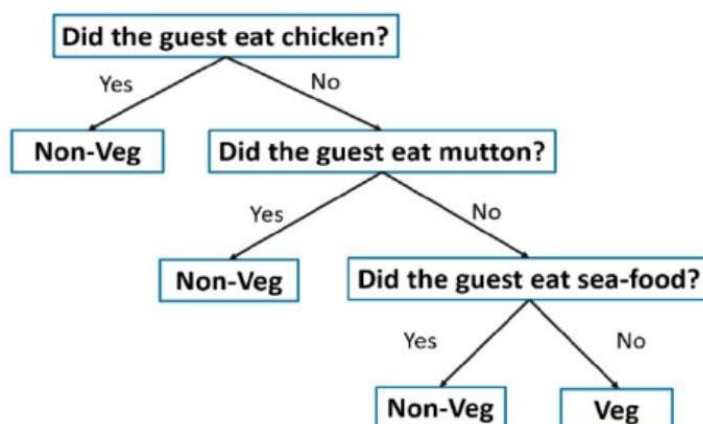
**Figura 2.**  
*Supervised learning Workflow*



*Nota.* La figura ilustra el flujo de trabajo del aprendizaje supervisado, destacando las fases clave, como la recopilación de datos, la división en conjuntos de entrenamiento y prueba, el entrenamiento del modelo, la evaluación y la predicción.

**2.1.1.3. Árbol de decisiones.** En la Figura 3 se presenta un ejemplo visual de un árbol de decisiones, conocido como Decision Tree en inglés. Este diagrama ilustra de manera gráfica cómo se organizan las alternativas disponibles y sus resultados, siguiendo una estructura de árbol. Cada nodo en el árbol representa un evento o decisión, mientras que las ramas indican las normas o condiciones que guían la toma de decisiones. Utilizaremos este diagrama como referencia visual para ilustrar cómo se aplican los árboles de decisiones en la clasificación de atributos durante nuestro estudio.

**Figura 3.**  
*Decisión Tree*



*Nota.* Pseudo Código del árbol de decisión: `def decisionTreeLearning (ejemplos, atributos, parent_examples).`

El código proporciona una implementación simplificada del algoritmo Decision Tree Learning, utilizado en aprendizaje automático para construir árboles de decisión. El algoritmo toma ejemplos de entrenamiento y atributos, y construye un árbol de decisión recursivamente seleccionando el atributo más prometedor en cada paso. Este proceso continúa hasta que se cumple una condición de parada, como la ausencia de ejemplos o atributos. El árbol resultante se utiliza para clasificar nuevos ejemplos en función de sus atributos.

Es importante tener en cuenta que el código proporcionado es un pseudo-código simplificado y puede requerir adaptaciones para su implementación en un lenguaje de programación específico.

A continuación, se muestra el Pseudo-código para el algoritmo Decision Tree Learning:

```
if len(examples) == 0: return pluralityValue(parent_examples) // devuelve el valor más probable
ya que no quedan datos de entrenamiento.
```

```
elif len(attributes) == 0: return pluralityValue(examples) // devuelve el valor más probable en base
a los ejemplos restantes.
```

```
elif (todos los ejemplos clasifican igual): return classification // devuelve su clasificación si todos
los ejemplos son iguales.
```

```
A = max(attributes, key(a) = importance(a, examples)) // elige el atributo más prometedor para
condicionar el árbol de decisión.
```

```
tree = new Tree(root=A) // crea un nuevo árbol con la raíz como el atributo seleccionado.
```

```
for value in A.values(): exs = examples[e.A == value] // selecciona los ejemplos que coinciden
con el valor del atributo.
```

```
subtree = decisionTreeLearning(exs, attributes.remove(A), examples) // recursivamente construye
un sub-árbol.
```

`addSubtreeAsBranch(subtree, label=(A, value))` // agrega el sub-árbol como una rama al árbol principal.


`return tree` // devuelve el árbol resultante. (Richert y Coelho, 2013).

A. **Navie Bayes (Modelo Bayesiano)**. Se trata de una metodología de categorización que se basa en la teoría de Bayes, asumiendo que existe independencia entre los predictores. Sencillamente, un clasificador Bayes ingenuo presupone la existencia de un rasgo específico en un tipo no vinculado con la existencia de otro rasgo. Naive Bayes se aplica fundamentalmente en la clasificación de textos, utilizándose especialmente para el análisis y clasificación de grupos, donde el propósito es dependiente de la posibilidad condicional de lo que sucede.

B. **Soporte Vector Machine**. Otra técnica avanzada ampliamente empleada en aprendizaje automático es la Máquina de Vectores de Soporte (SVM). En el campo del aprendizaje automático, las SVM son modelos supervisados que utilizan algoritmos de aprendizaje para análisis de información en tareas de clasificación y regresión. Además de realizar clasificación lineal, las SVM tienen la capacidad de llevar a cabo clasificaciones no lineales de manera eficiente mediante el uso del denominado "truco del kernel", que implica mapear implícitamente las entradas a espacios de características de alta dimensión. En esencia, las SVM establecen parámetros en las clases, diseñando estos de tal forma que maximizan la distancia entre el margen y las clases, minimizando así la falla de categorización.

En la Figura 4 se presenta una representación visual de cómo funciona la Máquina de Soporte de Vectores. Este diagrama ilustra cómo el algoritmo identifica el hiperplano óptimo que maximiza el margen entre las clases, lo que facilita la clasificación precisa de los datos. Además, la SVM puede utilizar diferentes funciones de kernel para mapear los datos en espacios de mayor dimensionalidad, lo que le permite manejar eficazmente conjuntos de datos no lineales.

**Figura 4.**  
*Máquina de soporte de vectores*

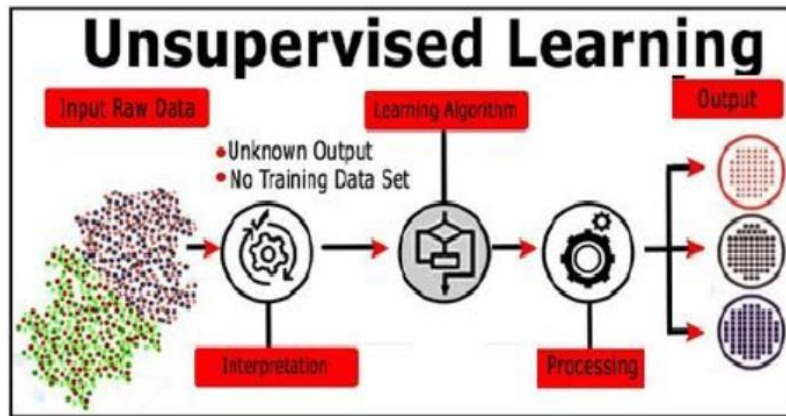


*Nota.* La imagen ilustra los principios clave de una Máquina de Soporte de Vectores (SVM), mostrando cómo este algoritmo identifica un hiperplano óptimo en un espacio de múltiples dimensiones para la clasificación eficaz de datos complejos.

**2.1.1.4. Aprendizaje no supervisado.** Llamado también unsupervised learning, este término se utiliza porque, en contraste del aprendizaje supervisado mencionado anteriormente, no existen contestaciones correctas ni un instructor que guíe el proceso. En este enfoque, los algoritmos trabajan de manera autónoma para descubrir y revelar el sistema interesante presente en la información. En el unsupervised learning, los algoritmos adquieren rasgos claves de la información cuando se les introduce nueva información, empleando los rasgos previamente aprendidos para identificar la categoría de los datos. Este tipo de aprendizaje se emplea esencialmente para agrupar en clústeres y la disminución de rasgos. (Richert y Coelho, 2013).

En la Figura 5, se muestra el proceso de aprendizaje no supervisado. Aquí, los algoritmos adquieren características clave de los datos cuando se les introduce nueva información, utilizando los conocimientos previamente adquiridos para identificar patrones y estructuras en los datos. Este tipo de aprendizaje se emplea principalmente para la agrupación de datos en clústeres y la reducción de la dimensionalidad de los datos.

**Figura 5.**  
*Aprendizaje no supervisado*



*Nota.* La imagen ilustra los principios clave de una Máquina de Soporte de Vectores (SVM), mostrando cómo este algoritmo identifica un hiperplano óptimo en un espacio de múltiples dimensiones para la clasificación eficaz de datos complejos.

**2.1.1.5. Técnicas de aprendizaje autónomo.** Management Solution (2018.) En el procedimiento de modelización, comúnmente se lleva a cabo una etapa inicial de descubrimiento de conocimiento. En este procedimiento, se hacen diversas tareas, entre las cuales se incluyen las siguientes: comprensión de los datos, que abarca la elaboración inicial y analizan de forma descriptiva de la información, así como analizar de la calidad de los datos. También se lleva a cabo la elaboración de la información, que implica el barrido o procedimiento de la información (contiene el manejo de valores faltantes, valores atípicos, registros incorrectos o no consistentes), analizar multivariante, combinación o creación de nuevas categorías a partir de las que existen, y disminución de la cantidad de categorías (a través de eliminar de categorías repetidas, la proyección en subespacios de menor dimensión, entre otros).

Elección de la metodología adecuada y empleo de procedimientos de regularización que implican la transformación y preparación de los datos para la modelización. Por ejemplo, se pueden considerar métodos como la homogeneización del rango de las categorías, que implica acciones como restar la media y dividir por la desviación estándar (normalización) o dividir por el rango de la categoría (escalar), entre otros. También se incluye la identificación de las

variables más relevantes para el modelo deseado. En comparación con métodos anteriores de elección de categorías, como el método stepwise, se emplean metodologías como el uso de redes elásticas. En estas redes, la operación utilizada para estimar las medidas del modelo (conocida como función propósito o costos, el objetivo es reducir su valor) se ajusta al incorporar un término adicional para identificar qué categorías no aporta datos al comparar el rendimiento del modelo en muestra de elaboración y de prueba, permitiendo así la elección automática de categorías.

Si  $L$  es la función de coste que se emplea para conseguir las estimaciones del modelo,  $\beta_t = (\beta_1, \dots, \beta_n)$  los estimadores, y  $\lambda_1 \in \mathbb{R}$ ,  $\lambda_2 \in \mathbb{R}^+$ , entonces la función se puede cambiar con la expresión: En el caso particular en que  $\lambda_2=0$ , se consigue la metodología llamada LASSO, y cuando  $\lambda_1=0$  se consigue la metodología llamada ridge regression.

En las metodologías de supervised learning en el aprendizaje automático, se destacan los métodos individuales, así llamados porque pueden aplicarse de manera independiente. Entre estos, se encuentran la red neuronal, las máquinas de vectores de apoyo, los clasificadores bayesianos y los árboles de categorización y regresión. La red neuronal es modelador matemático no lineales multivariantes que emplean procesos iterativos con el fin de reducir el error específico y categorizar evidencias. Esta red está compuesta por neuronas interconectadas mediante nodos y capas, simulando uniones similares a las dendritas y axones en el sistema nervioso biológico, a través de los cuales se transmite datos. Las redes neuronales son utilizadas tanto en problemas supervisados como no supervisados, ofreciendo la ventaja de poder separar regiones de manera no lineal. Sin embargo, su principal desventaja radica en su naturaleza de "caja negra", lo que implica dificultades en la interpretación de los resultados y restricciones para incorporar el conocimiento del negocio en el complicado sistema de pesos.




### 2.1.2. *Deep Learning*

(Torres, 2018), las redes neuronales artificiales constituyen un caso particular de algoritmos de Machine Learning. Para comprender su estructura, se puede imaginar que estos algoritmos poseen similitudes con las neuronas en el cerebro humano en función a la destreza de producir hallazgos. Aunque, actualmente, esta comparación puede haber perdido relevancia en cierta medida.

En el ámbito del Deep Learning, las estructuras algorítmicas permiten desarrollar modelos con múltiples capas de procesamiento, como se muestra en la Figura 6. Estas capas habilitan al modelo para aprender representaciones de datos en distintos niveles de abstracción mediante transformaciones lineales y no lineales, apuntando a generar resultados que se alineen con las expectativas (etiquetas). En el aprendizaje supervisado, este proceso implica ajustar los sistemas de cambios (pesos y sesgos) para optimizarlos, asegurando así que los resultados producidos sean similares a los esperados.

**Figura 6.**  
*Red Neuronal Deep Learning*



*Nota.* La figura muestra una red neuronal en el contexto del aprendizaje profundo, resaltando cómo las capas se conectan y la habilidad de la red para aprender representaciones complejas.

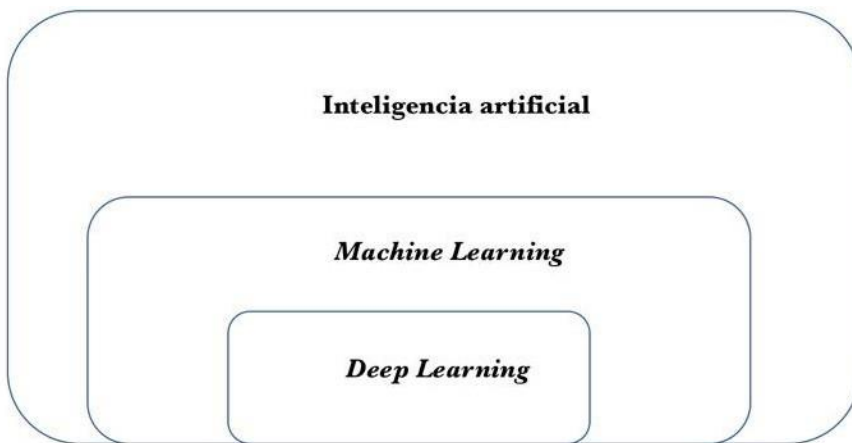
De manera específica, se presenta un modelo de redes neuronales artificiales con tres capas: la primera es de entrada (input layer) que recibe la información inicial, una capa de salida (output layer) que produce la predicción, y capas intermedias llamadas capas ocultas (hidden layers). Es posible tener varias capas ocultas, cada una con una cantidad variable de neuronas. Posteriormente, exploraremos cómo las neuronas, representadas por círculos, están conectadas entre sí de diversas maneras, estableciendo conexiones entre las neuronas de capas distintas.

(Torres, 2018), En términos generales, en la actualidad trabajamos con redes neuronales artificiales que tienen varias capas apiladas verticalmente, lo que da lugar a la definición de "deep" (profundidad de la red). Cada una de las capas, a su vez, está constituida por un gran número de neuronas, las que tienen sus propios parámetros, incluyendo los pesos ( $w_i$ ) y el sesgo ( $b$ ). Estas neuronas llevan a cabo modificación sencilla de la información recibida de las redes neuronales de la capa anterior para transmitirlas a las que se encuentran en la capa que sigue. La conexión de todas estas capas posibilita la identificación de modelos complicados. En detalles posteriores, los adelantos en el aprendizaje profundo sufren mejora pues reconocen la voz, reconocen material visual, detectan materiales y cuentan con otros rasgos importantes, pero es la metodología de la inteligencia artificial cobra importancia en las organizaciones. Aunque el Deep Learning a menudo se percibe con un aire de misterio, la realidad es menos mística y más técnica. Programar algoritmos de Deep Learning es complejo debido a las variadas capas y la influencia significativa de cada parámetro. Este proceso, que combina arte y ciencia, requiere de un aprendizaje y práctica extensos, aunque no es misterioso en sí. La clave radica en dedicar tiempo para entender y experimentar con estas tecnologías.

La Figura 7, ofrece una representación visual que destaca la relación entre el aprendizaje profundo y la inteligencia artificial en su conjunto. Esta figura proporciona una perspectiva intuitiva de cómo el aprendizaje profundo, aunque es solo una parte de la inteligencia artificial, juega un papel dinámico y central en el desarrollo de esta disciplina. Muestra cómo los grupos científicos están cada vez más enfocados en el aprendizaje profundo como una herramienta fundamental para avanzar en la comprensión y aplicación de la inteligencia artificial en una variedad de campos.

**Figura 7.**

*Aprendizaje profundo como parte de la inteligencia artificial*



*Nota.* La figura muestra cómo el Deep Learning se integra como un elemento clave dentro de la Inteligencia Artificial, resaltando su rol vital en el avance de las capacidades de la IA.

La inteligencia artificial necesita extensos grupos de información para entrenar sus patrones, pero con fortuna, la generación y la disposición de información ha experimentado un crecimiento exponencial. Esto se debe en gran medida a la considerable reducción de los costos y al incremento de la fiabilidad en la producción de información, como en el caso de las fotografías digitales y sensores más asequibles y con precisión. Además, los avances en el hardware para almacenar en estos tiempos, combinados con mejoras significativas en técnicas de gestión de datos mediante bases de datos NoSQL, posibilitan la obtención de vastos grupos

de información para el entrenamiento de patrones de inteligencia artificial. (Torres, 2018/2023).

Además de los incrementos en la disposición de información facilitados por Internet y sus diversos usos, los recursos de datos con especialización han sido fundamentales para impulsar el progreso en este ámbito. Diversas bases de datos de acceso público han respaldado el vertiginoso crecimiento de algoritmos de inteligencia artificial. Uno de ellos es ImageNet, la cual ya hemos mencionado, que proporciona libremente más de 10 millones de imágenes con etiquetas manuales. Sin embargo, lo que distingue a ImageNet no solo el tamaño, sino la competición que organiza todos los años, lo que representa una eficaz manera de estimular a estudiosos e ingenieros.

Al inicio, los estudios eran fundamentalmente en algoritmos de visión por PC convencional. Sin embargo, de acuerdo a Krizhevsky (2012), introdujo redes neuronales de aprendizaje profundo, denominado AlexNet, que disminuyó la tasa de errores menores a la mitad de lo que se lograba en ese momento. Es más, por el año 2015, el algoritmo que ganó entró en competencia con las destrezas de los seres humanos, y en la actualidad, los algoritmos de aprendizaje profundo resaltan significativamente las tasas de errores en la competencia en comparación con las personas (p. 125). No obstante, ImageNet es el cimiento de la información disponible que empleo para adiestrar redes de aprendizaje significativo en las últimas décadas. Otras bases de datos incluyen MNIST, CIFAR, SVHN, STL e IMDB, entre otras, las cuales discutiremos más adelante. Es relevante también mencionar Kaggle, como una plataforma que alberga competencias para analizar información, donde organizaciones y estudiosos proporcionan su información y profesionales de la ingeniería de datos realizan competencias globalmente para desarrollar los mejores patrones de predicción o categorización (Torres, 2018).

El ámbito del aprendizaje profundo evidencia su habilidad para enfrentar retos complicados en distintas disciplinas, y los pronósticos de ventas no se queda atrás. En estas últimas décadas los expertos emplearon metodologías de Deep learning para crear patrones exactos capaces de prever las ventas de una organización con un elevado nivel de precisión.

De acuerdo con la investigación de Chen et al. (2018), la utilización del aprendizaje profundo para pronosticar las ventas se sustenta en la capacidad que tienen estas metodologías para identificar de forma automática rasgos distinguidos en la información y para acomodar vínculos no lineales entre las categorías. Este aspecto resulta particularmente crucial en el ámbito de las ventas, en la que diversos aspectos como promoción, estacionalidad y actitudes del mercado pueden ejercer influencia en los hallazgos.

Un direccionamiento frecuentemente empleado en el pronóstico de ventas a través del aprendizaje profundo consiste en la utilización de la red neuronal recurrente (RNN). Estas redes, de acuerdo a Bengio et al. (2013), están hechas específicamente para gestionar el aspecto secuencial de la información, lo que las hace una elección óptima para acomodar series de tiempo de ventas. Las RNN tienen la capacidad de coger modelos a largo plazo en los datos, que hace prever de manera precisa la tendencia y el ciclo estacional en las ventas.

Entonces, ¿qué sucede si no hay disposición de la capacidad de computación en la organización? Hasta el momento, la inteligencia artificial es fundamentalmente aprovechada por organizaciones grandes como Amazon, Baidu, Google o Microsoft, y otras organizaciones que cuentan con dichas capacidades. Sin embargo, para muchos otros negocios y sectores del aspecto económico, la implementación completa de sistemas de inteligencia artificial ha resultado muy costosa y compleja. Aquí nos referimos específicamente a la computación en la nube (Torres, 2018).

Se trata de otra etapa de la computación que es la democratización y las organizaciones pueden conectarse a instituciones grandes de procesamiento de información mayores a 28 000 metros cuadrados, con cantidad de servidores.

La computación en la nube ha transformado la industria al democratizar la computación, transformando por completo los métodos operativos de los negocios. Ahora, se presenta la oportunidad de modificar el panorama de la inteligencia artificial y el aprendizaje profundo, brindando ventaja significativa a las empresas pequeñas y medianas que no tienen la capacidad de construir infraestructuras de este tipo. El Cloud Computing, de hecho, les proporciona acceso a capacidades de computación que previamente solo estaban al alcance de las organizaciones grandes o países.

Adicionalmente, los proveedores de servicios en la nube están actualmente proporcionando lo que se denomina "Algoritmos de Inteligencia Artificial como Servicio" (AI-as-a-Service), servicios de inteligencia artificial por medio de la nube que se integran y colaboran fácilmente con los usos internos de las instituciones mediante simples interfaces de programación de aplicaciones (API) REST.

Esto significa que es accesible para prácticamente todos, ya que se trata de un servicio que se factura únicamente por el tiempo de uso. Esta característica es revolucionaria, ya que actualmente es posible que el desarrollador de software implemente todo tipo de algoritmo de inteligencia artificial en producción de manera rápida y eficiente.

Amazon, Microsoft, Google e IBM encabezan la actual tendencia de servicios de AI como servicio (AIaaS), que posibilita realizar adiestramientos y poner en producción de forma ágil. Al instante de escribir este libro, Amazon AIaaS estaba dispuesto en dos modalidades: el empleo del análisis predictivo mediante aprendizaje automático de Amazon y el SageMaker para el

rápido empleo y despliegue de modelos. Microsoft, por su parte, proporciona sus servicios por medio del aprendizaje automático de Azure, que se clasificó en dos tipos esenciales: Estudio de aprendizaje automático Azure y Galería de Inteligencia Azure.

Google proporciona la Prediction API y el Google ML Engine. IBM, por su parte, brinda servicios de AIaaS por medio de Watson Analytics. Además, no podemos pasar por alto las soluciones provenientes de startups, como PredicSis y BigML. Indudablemente, la inteligencia artificial dirigirá las siguientes evoluciones, y su aspecto exitoso estará principalmente determinado por el aspecto creativo de las organizaciones, más que por la tecnología hardware, por el uso de la Computación en la Nube.

### **2.1.3. Redes Neuronales Densamente Conectadas**

**2.1.3.1. Perceptrón.** El perceptrón se define como una neurona artificial y, en consecuencia, constituye una unidad esencial dentro de una red neuronal. Su función principal radica en realizar operaciones matemáticas con el objetivo de identificar características o patrones presentes en los datos de entrada.

**A. Algoritmos de Regresión.** Estos modelan el vínculo entre categorías diferentes de ingreso (*features*) empleando medidas de error, la *loss*, cuya intención es reducir el procedimiento iterativo para hacer pronósticos “en mayor nivel que sea convenientes posible”. Existen dos clases: regresión logística y regresión lineal.

**B. Una neurona artificial simple.** La información de ingreso se presentará por vectores de la forma  $(x_1, x_2)$  que muestran sus coordenadas en esta área de dos dimensiones, y la función regresará a ‘0’ o ‘1’ (superior o inferior de la línea) para conocer si es necesario categorizar como “cuadrado” o “círculo”. Se ha podido observar, que es un tipo de regresión lineal, en la que “la línea” (el clasificador) puede ser conceptualizado por la recta:

$$y = w_1x_1 + w_2x_2 + b.$$

Continuando con la nota mostrada en el capítulo 1. De forma más general, se expresa la recta como:  $y = w * x + b$ .

En la categorización de componentes de ingreso  $X$ , para el caso de dos dimensiones, se aprenderá un vector de peso  $W$  igual dimensión que los vectores de ingreso, pues, el vector  $(w_1, w_2)$  y un sesgo  $b$ .

En el cálculo de los valores, se elabora una neurona artificial para categorizar un elemento nuevo  $X$ . de forma básica la neurona emplea este vector  $W$  de pesos calculado, de forma ponderada sobre los valores en cada dimensión del elemento  $X$  de ingreso, se suma el sesgo  $b$ , y el hallazgo pasa por medio de una función de “activación” no lineal para generar un hallazgo de ‘0’ o ‘1’. La función de esta neurona artificial que terminamos de conceptualizar se expresa así:

$$z = b + \sum_i x_i w_i$$

$$y = \begin{cases} 1 & \text{si } z \geq 0 \\ 0 & \text{si } z < 0 \end{cases}$$

Con la función específica que realiza la neurona artificial, se pasa a apoyar al lector a la intuición cómo la neurona logra aprendizaje de los parámetros  $w$  y  $b$ , en función a la información que ya se dispone etiquetados como “cuadrados” o “círculos”, y así mismo ver las funciones que logra convertir en ‘0’ o ‘1’ el hallazgo con almacén en  $Z$ .

En cuanto a la adquisición de los parámetros  $w$  y  $b$  partiendo de información ya etiquetados como "cuadrados" o "círculos", en el próximo capítulo explicaremos de manera más formal el proceso. Por ahora, nos introducimos de manera intuitiva a este procedimiento, el cual implica una iteración sobre todos los ejemplos conocidos, comparando la etiqueta obtenida mediante el modelo con el valor esperado para cada componente. Luego de la iteración, se hace



ajuste de los pesos de los parámetros  $w$  y  $b$  con el fin de minimizar la función previamente definida.


Contando con los parámetros  $w$  y  $b$  se calcula el valor de  $z$ . Requerimos de una función que emplee un cambio a esta categoría para convertir en '0' o '1'. Existen diversas funciones (que se denomina “funciones de activación” como se verá en el capítulo que sigue), para este caso se empleará la función sigmoid que regresa un valor real de salida entre 0 y 1 para cualquier valor de ingreso:

$$y = \frac{1}{1 + e^{-z}}$$

La función sigmoid es fundamental en el campo del aprendizaje automático debido a su capacidad para transformar valores de entrada en un rango entre 0 y 1. Esta propiedad es evidente en su fórmula, donde si el valor de entrada  $z$  es grande y positivo, el término "e" elevado a la menos  $z$  se aproxima a cero, lo que hace que la salida  $y$  sea cercana a 1. Por otro lado, si  $z$  es grande y negativo, el término "e" se eleva a un número positivo grande, lo que lleva a que el denominador sea un número grande y la salida  $y$  sea cercana a 0.

Esta relación entre la entrada  $z$  y la salida  $y$  se ilustra de manera clara en la representación gráfica de la función sigmoid, que se muestra en la Figura 8, se puede observar cómo la función sigmoid se aproxima asintóticamente a 0 cuando  $z$  es grande y negativo, y a 1 cuando  $z$  es grande y positivo. Esta visualización ayuda a comprender intuitivamente el comportamiento de la función sigmoid y su importancia en la modelización de problemas de clasificación y regresión en el aprendizaje automático.


**Figura 8.**  
*Función Sigmoid*



*Nota.* La figura muestra la función Sigmoid en el contexto de redes neuronales y aprendizaje profundo, destacando cómo transforma entradas en valores entre 0 y 1, esencial para la activación en modelos neuronales.

La demostración de una neurona artificial comienza con la arquitectura básica de las redes neuronales, conocida como Perceptrón. Esta arquitectura, también llamada unidad de umbral lineal (LTU por sus siglas en inglés), fue descubierta en 1957 por Frank Rosenblatt. Visualmente, se representa de manera sencilla en el esquema que se muestra en la Figura 9. Este esquema proporciona una visión clara de la estructura elemental de una neurona artificial, destacando su capacidad para tomar entradas, realizar cálculos ponderados y producir una salida en función de un umbral. El Perceptrón es fundamental en la comprensión inicial de cómo funcionan las redes neuronales y sirve como punto de partida para explorar arquitecturas más complejas en el campo del aprendizaje automático.

**Figura 9.**  
*Perceptrón en su versión más simple de su red neuronal*



*Nota.* La figura muestra un Perceptrón básico en una red neuronal, resaltando su estructura simple y conexiones ponderadas, y proporciona una comprensión clara de cómo se procesa la información en las unidades fundamentales de las redes neuronales.


El Perceptrón se destaca como la forma básica de las redes neuronales, ya que se compone de una única capa que alberga una neurona sola. No obstante, en este libro, observaremos que es más común encontrarnos con redes neuronales más complejas, formadas por múltiples capas. En cada una de estas capas, abundan numerosas neuronas que establecen comunicación con las de la capa preliminar para recibir datos, y, a su vez, transmiten la información a las neuronas de la siguiente capa.

En el próximo capítulo, exploraremos diversas funciones para activar que poseen propiedades distintas a la sigmoide. Sin embargo, con el objetivo de clasificar números escritos a mano, también introduciré en este capítulo una función de activación adicional llamada softmax. Esta función resultará beneficiosa para mostrar las redes neuronales diseñadas para la clasificación de dos tipos.

En el instante se consideró la función softmax como algo general de la función sigmoide que clasifica mayor a dos clases.

**2.1.3.2. Multilayer perceptron.** Al hablar de Perceptrón Multicapa (MLP) tiene que ver con la literatura del campo, estamos hablando de red neuronal que constan de una capa de entrada (input layer), las capas cuentan con un o más capas compuestas por perceptrones, conocidas como capas ocultas (hidden layers), y una capa final con variados perceptrones denominada capa de salida (output layer). Visualmente, se presenta en el esquema de capas siguiente, que se muestra en la Figura 10. Se ilustra claramente cómo las capas ocultas permiten que la red neuronal aprenda y capture características cada vez más complejas de los datos de entrada, lo que resulta en un aprendizaje profundo y una capacidad mejorada para realizar tareas de clasificación y regresión en una variedad de dominios de aplicación.

**Figura 10.**  
*Multilayer perceptrón, con varias capas ocultas*



*Nota.* La figura muestra un Multilayer Perceptrón con capas ocultas, ilustrando su estructura en capas y las conexiones entre nodos, enfatizando la complejidad y la función de las capas intermedias en la extracción de características en redes neuronales.

#### **2.1.4. Ventas**

En la administración empresarial moderna, las ventas son cruciales, especialmente en empresas centradas en el cliente y el servicio. El conocimiento y la experiencia en ventas son esenciales para establecer relaciones sólidas con los clientes y contribuir al crecimiento empresarial. La interacción entre ventas y marketing es clave en la competitividad empresarial.

Mientras que las ventas se enfocan en técnicas, el marketing es estratégico. Por lo tanto, para decisiones estratégicas en ventas, es fundamental entender cómo funciona el marketing en la organización, ya que la gestión del equipo de ventas es un componente vital del esfuerzo comercial (Vásquez, 2008).

De acuerdo con Rubio y Baz (2016), se señala que la competencia es el factor determinante que posibilita la viabilidad de una entidad en el medio que se desarrolla. La institución es considerada competitiva cuando logra combinar eficazmente componentes, y sus costos y atributos son comparables o incluso superiores a los de sus competidores a nivel mundial.

En líneas generales, la venta constituye un procedimiento complicado que comienza con la identificación de los posibles interesados en los productos o servicios. Existe un lapso desde la primera conexión con el cliente potencial y el instante en que se concreta la realización de la compra. Cuanto mayor complejidad y mayor costo tenga el producto, mayor será la duración del ciclo de ventas. La venta se puede conceptualizar como la acción a través de la cual un individuo transfiere a otra la posesión de un bien o derecho, a cambio de un precio específico. También se puede definir como el acto de transferir la propiedad de un producto en función a un valor en forma de dinero, servicios o bienes (Andersen, 1997).

Se trata de un procedimiento activo que sigue un ciclo, el mismo que demanda tiempo, planeación y estrategias para obtener buenos hallazgos. La mercadotecnia se conceptualiza en procedimientos sociales y administrativos en la que los grupos y sujetos satisfacen sus necesidades y deseos mediante la elaboración, oferta y canje de productos de valor (Kotler, 1994). En función a Chartered Institute of Marketing (CIM), la mercadotecnia se conceptualiza como el procedimiento de gestión responsable que busca identificar, anticipar y satisfacer de los requisitos del usuario, brindando ganancia (Jefkins, 1997). En este contexto, los aspectos primordiales del

mercadeo son la identificación, anticipación y satisfacción de requerimientos.

Se evidencia anteriormente, que existen aspectos contrarios en ambas definiciones: la venta se concentra en un procedimiento estratégico, mientras que la mercadotecnia abarca un enfoque más amplio.

**2.1.4.1. La Fuerza de las Ventas.** Diseñada para generar ventas y no solo se trata de los costos, sino también de la reputación, ya que un mayor número de vendedores tiende a resultar en mayores ventas. Un equipo de ventas motivado superará en ventas a uno que carezca de ellos y en consecuencia, una fuerza de ventas bien capacitada superará en rendimiento a una que carezca de disciplina. La eficacia de la entidad de ventas tiene un impacto directo en las ventas y en las rentas de la institución (Iacobucci, 2002).

**2.1.4.2. Componentes de una organización de ventas.** Se inicia con analizar las opciones de producción. Las instituciones de ventas pueden ver tres componentes indispensables (Iacobucci, 2002):

**A. *La inversión en la fuerza de ventas.*** En recursos y asistencia. Los gastos asociados con los recursos pueden abarcar salarios para los vendedores y los administradores de ventas. Los costos vinculados al respaldo de las ventas pueden comprender contratos, capacitación, sesiones de ventas y dispositivos móviles. El desembolso total puede variar considerablemente, en fusión al tamaño de la institución.

**B. *Las actividades de la fuerza de ventas.*** La inversión es una de ellas, pues proporciona a la entidad un capital humano que se ve en diversas acciones de ventas. Por lo general, las actividades del equipo de ventas se expresan a través de un procedimiento de ventas que abarca desde que se atrae y retiene a los clientes o posibles clientes.

*C. Los resultados de la fuerza de ventas.* Los logros de ella se pueden ver comúnmente en las ventas, beneficios y cuota de mercado. Estos resultados se pueden evaluar mediante grados absolutos, cantidades porcentuales de metas alcanzadas o comparación con el rendimiento del año anterior. Es crucial analizar estas métricas tanto a corto como a largo plazo, ya que las decisiones tomadas por la fuerza de ventas tienen repercusiones en ambas perspectivas temporales. Generalmente, cada uno de estos elementos es cuantificable, lo que permite determinar la eficacia de la fuerza de ventas (Vásquez, 2008).

**2.1.4.3. Estrategias de ventas exitosas aplicadas en naciones de América Latina.** En esta parte se muestran ciertas tácticas de ventas con éxito empleadas en naciones de América Latina, las cuales fueron producto del análisis y revisión de acciones exitosas empresariales. Estas tácticas tuvieron han acciones exitosas en organizaciones grandes y pequeñas.

Alcanzar a satisfacer al cliente implica mejorar constantemente en la prestación y calidad del servicio. Es esencial que la empresa cuente con un modelo de negocios flexible y adaptable al entorno en el que opera, anticipándose a los requerimientos del cliente y siendo capaz de ajustarse a las transformaciones, que hoy en día tienen mayor frecuencia y rapidez que en tiempos anteriores. Factores como las estrategias de distribuciones, segmentaciones totales de mercado, acciones efectivas de posicionamiento y, sobre todo, la atención al consumidor, son cruciales. El cliente es la figura central, y es fundamental ganarse su confianza, mostrarse confiable y permanecer con disponibilidad en el mercado.

El hecho de innovar se posiciona como punto esencial del éxito, involucrando el repaso periódico de los ciclos de vida de los productos, la variación de la oferta y la elaboración de extensiones de líneas, sin hacer abuso de estas últimas. Es esencial analizar a fondo al cliente,

comprendiendo su comportamiento y necesidades de manera más frecuente que en el pasado. La aplicación de estrategias como la Respuesta Eficaz al Consumidor (ECR, con sus siglas en inglés) se considera como una visión integral de todo el abastecimiento y reaprovisionamiento de productos (Fernie y Sparks, 2001).

El empleo de la CRM (del término en inglés, o Gestión de Relaciones con el Cliente). Tiene un rol fundamental. La asociación adecuada con el cliente es la clave esencial en el combate permanente para retener. Hay una tendencia integral para la creación, mantenimiento y expansión de los vínculos con el cliente.

**2.1.4.4. Variable Dependiente Predicciones de Ventas.** (Ocampo et al., 2004), La óptima utilización de los recursos y la alta demanda de una amplia diversificación de productos imponen a los productores la necesidad de establecer programas de productividad más inexorables y flexibles. Esto se realiza con el objetivo de maximizar la eficiencia en el empleo de equipos caros de producción, mano de obra e inversión en materias primas, asegurando la cumplimentación de la fecha de entrega a los usuarios finales y reduciendo el costo. Para llevar a cabo proyectos de producción eficientes que satisfagan la demanda sin caer en gastos enormes de capital, se requiere una gestión adecuada de la información de ventas. Esta gestión es fundamental para hacer vaticinios con un alto grado de confiabilidad en todas las áreas y la entidad en su conjunto. Un augurio de ventas es una metodología que hace que se calcule proyecciones de ventas con rapidez y precisión, empleando como información tanto transacción de inventarios como facturar ventas. Asimismo, posibilita proyectarse a demandas futuras, en función a datos históricos producidos por la movilización de productos en el Control de Inventarios o por las ventas registradas en la facturación.

Las estrategias comúnmente corroboradas para elaborar los vaticinios se clasifican en: juicio ejecutivo, encuestas, análisis de series de tiempo, análisis de regresión y pruebas de



mercado. La selección de la metodología o la combinación de varios dependerá de factores como los costos asociados, la finalidad del vaticinio, la fiabilidad y coherencia de la información histórica de ventas, el plazo de disponibilidad para realizar el vaticinio, la clase de producto, los rasgos del mercado, la parte disponible en función a los datos requeridos y la habilidad de quienes están a cargo del vaticinio. Por lo general, las empresas suelen utilizar una combinación de varias técnicas de vaticinio.

#### **Dimensiones:**

a) **Predicción de Monto de Ventas:** Esta dimensión se refiere a la capacidad de predecir el valor total en términos monetarios de las ventas de una empresa en un periodo específico. Implica utilizar modelos estadísticos o de aprendizaje automático para estimar el volumen de ingresos que una empresa generará, basándose en factores como tendencias históricas, condiciones del mercado y comportamiento del consumidor.

b) **Predicción de Temporal de Ventas:** Esta dimensión aborda la predicción del momento o período en que se realizarán las ventas. Esto incluye identificar patrones temporales y estacionales en los datos de ventas para prever cuándo se producirán picos o caídas en las transacciones comerciales. Esta capacidad es crucial para la planificación y la gestión de inventarios, así como para la estrategia de marketing y promociones.

#### **2.1.4.5. Técnicas clásicas de pronóstico.** Entre las más usadas están:

A. **Juicio ejecutivo.** Está basado en el aspecto de la percepción de uno o más gerentes expertos asociados a productos de demanda constante. La inconveniencia está basada en el pasado y es influenciado por los sucesos nuevos.

**B. Encuesta de pronóstico de los clientes.** Investigación de presagio entre los clientes. Aplicable para instituciones con un reducido número de clientes. Se consulta acerca de la clase y la cantidad de productos que planean adquirir en un período específico. Los clientes industriales suelen ofrecer apreciaciones precisas. Las encuestas muestran el aspecto intencional de compra, aunque no necesariamente las compras efectivas.

**C. Encuesta de Pronóstico de la Fuerza de Ventas.** Los vendedores evalúan las ventas anticipadas en las diferentes áreas para un período específico. La suma de estas percepciones individuales constituye el presagio de la empresa o del área. El desafío radica en la inclinación de los vendedores a proporcionar estimaciones muy cautelosas con el objetivo de asegurarse futuras comisiones y bonificaciones.

**D. El método Delfos (Delphi).** Se hace el contrato con especialistas que realizan presagios iniciales que la organización realiza un promedio y hace la devolución para determinar las estimaciones individuales. El proceso puede darse en forma repetitiva hasta que los especialistas trabajen por separado, logren un acuerdo acerca de los vaticinios. Es una metodología de precisión alta.

**E. Análisis de series de tiempo.** Se emplean los registros de la historia de ventas de la entidad para identificar propensiones de tipo estacional, cíclico y aleatorio o impredecible. Esta metodología resulta eficaz para productos con demandas relativamente constantes. La detección de un factor estacional se lleva a cabo mediante el uso de promedios móviles. La determinación de una línea de tendencia a través de una estructura de regresión lineal simple permite identificar la presencia de un factor cíclico en los datos. La existencia de un factor aleatorio se establece cuando el comportamiento impredecible de las ventas puede atribuirse a eventos no recurrentes y aleatorios.

**F. Análisis de regresión.** Se procurará hallar una asociación en función a las ventas históricas (variable dependiente) y una o más categorías independientes, como población, entrada per-cápita o (PBI). Esta metodología puede ser beneficiosa.

**G. Prueba de mercado.** Consiste en introducir un producto que se pone a los compradores en uno o diversos lugares de prueba, midiendo las compras y la reacción del cliente frente a diversas combinaciones de estrategias de marketing. A partir de estos datos, se preparan las ventas para áreas más extensas. Este método resulta beneficioso para anticipar las ventas de productos nuevos o existentes en áreas no exploradas previamente. No obstante, estas pruebas son costosas tanto en términos de tiempo como de recursos financieros, y también ponen de manifiesto a la competitividad (Ocampo et al., 2004).

## 2.2. Definiciones conceptuales

Se presentan explicaciones detalladas y esenciales de términos clave y conceptos fundamentales relacionados con el ámbito de estudio. Estas definiciones sirven como cimientos conceptuales, proporcionando al lector una comprensión sólida y clara de los elementos esenciales para abordar de manera significativa los temas discutidos en la investigación.

- **Machine Learning**, (Gori, 2018), se describe como una clase de Inteligencia Artificial que confiere a una estructura (ya sea de hardware o software) la habilidad de aprendizaje sin necesidad de ser programado de manera explícita.
- **Deep learning**, según la descripción de (Mahesh, 2019), se caracteriza como el ámbito de investigación que concede a las PCs la destreza de aprendizaje sin requerir de estar programadas de forma clara.
- **Supervised learning**, de acuerdo con (Hurwitz & Kirsch, 2018) comienza con un grupo de información de rasgos y una etiqueta que da significación a la información.

- **Unsupervised learning**, de acuerdo con (Hurwitz & Kirsch, 2018) es utilizado esencialmente en la dificultad cuando utiliza gran número de información que tienen solo los rasgos, sin etiquetar.
- **En el aprendizaje por reforzamiento**, de acuerdo (Hurwitz & Kirsch, 2018) el algoritmo tiene retroalimentación que realiza el consumidor, para analizar información y conseguir mejores resultados; es decir, el aprendizaje se da con motivaciones al brindar un alto peso cuando está muy cerca del propósito o un bajo peso si tiene fallas en el hallazgo
- **Regresión**, de acuerdo a (Mueller & Guido, 2016), la finalidad es vaticinar el egreso numérico, puede darse de forma continua o ser punto flotante.
- **Aprendizaje profundo**, Para Rusk (2016), es una excelente manera de machine learning, que hace que las PCs resuelvan dificultades de percepción, y reconozcan imágenes y voz.

### III. METODO

El método desempeña un papel esencial en la investigación científica, actuando como la columna vertebral del estudio. Según Domingos y Lowd (2015), el método establece una estructura y guía para todas las etapas de la investigación, desde la recopilación de datos hasta el análisis y la interpretación. Es clave para garantizar la validez, credibilidad y replicabilidad del estudio. Además, según lo señalado por Bengio (2012), la elección y aplicación de un método apropiado asegura que los resultados obtenidos sean precisos, relevantes y aplicables.

Según los estudios de Bengio (2012) y LeCun (2015), el método también vincula estrechamente los objetivos e hipótesis del proyecto, definiendo cómo se aplicarán los modelos de Deep Learning y cómo se medirá su eficacia. La elección de herramientas y técnicas específicas, como algoritmos de Deep Learning y métodos de análisis de datos, se realiza bajo este marco metodológico.

En resumen, el método es crucial para el éxito y la contribución científica de la investigación, proporcionando un soporte fundamental para navegar y resolver el desafío de mejorar las predicciones de ventas en la empresa. Al respaldar nuestra metodología en los trabajos de estos autores especializados, garantizamos una base sólida y rigurosa para nuestro estudio.

#### 3.1 Tipo de investigación

La presente investigación se enmarca en un enfoque cuantitativo, el tipo de investigación es aplicada centrado en el análisis de datos numéricos para evaluar el impacto de la implementación de un modelo de Deep Learning en la predicción de ventas de la Empresa San Fernando S.A.C. Según Hastie, Tibshirani y Friedman (2009). Este enfoque cuantitativo se caracteriza por la recolección y análisis de datos objetivos y medibles, permitiendo una evaluación precisa de las variables en estudio.

Las unidades de análisis en esta investigación se definen como sigue:


- a) Ventas de la Empresa San Fernando S.A.C.: Este constituye el principal objeto de estudio, donde se recopiló datos históricos y actuales sobre las ventas de la empresa. Estos datos incluyeron el monto de las ventas, las fechas de las transacciones y otros factores relevantes para la predicción de ventas.
- b) Trabajadores del Departamento de Ventas: Los empleados del Departamento de Ventas representan una unidad de análisis crucial, pues su dinámica interacción con el sistema de predicción de ventas y su amplia experiencia en el campo son fuentes fundamentales de información para evaluar la efectividad y utilidad del modelo de Deep Learning implementado.

Estas unidades de análisis constituyen un componente integral para abordar de manera exhaustiva el objetivo de la investigación. Al proporcionar datos relevantes y detallados, permitirán evaluar con precisión la efectividad del modelo de Deep Learning en la predicción de ventas de la empresa. Asimismo, se enmarca en una metodología de tipo aplicada, que tiene como objetivo principal el desarrollo e implementación de un modelo de Deep Learning con el fin de mejorar la precisión en la predicción de ventas. Este enfoque se fundamenta en la aplicación de conocimientos teóricos en el campo del aprendizaje profundo para resolver problemas prácticos del ámbito empresarial, el cual optimizó los procesos y la toma de decisiones estratégicas.

El diseño fue experimental, pertenece a la categoría preexperimental, alcance explicativo, se trabajó con un conjunto de trabajadores que se registraron en un cuestionario digital y luego se empleó el aprendizaje automático para obtener observación para realizar la medición. Para Hernández (2014, p 141) “las preexperimentales residen en la aplicación de un procedimiento a

un conjunto y luego se mide las categorías”. En la Figura 11 se presenta una representación visual del Diseño Preexperimental.

**Figura 11.**  
*Diseño Preexperimental*



*Nota.* La figura muestra el diseño preexperimental, destacando la organización de las condiciones y la evaluación inicial de la variable independiente, proporcionando una comprensión clara de la estructura y metodología de este tipo de diseño en investigación. Adaptado de Bernal 2010.

O1 = Mediciones pretest de la predicción de ventas.

O2 = Mediciones del postest de la predicción de ventas.

X = Metodología aplicada.

G = Grupo experimental.

### 3.2 **Ámbito temporal y espacial**

El presente estudio se realizó durante el período de enero a julio de 2023, abarcando un lapso de seis meses que permitieron una observación exhaustiva de las tendencias y patrones de ventas en la empresa San Fernando S.A.C. Durante este tiempo, se recopilarán y analizarán datos detallados sobre las transacciones comerciales, así como cualquier información relevante relacionada con el desempeño de ventas.

En relación con el ámbito espacial, el estudio se enfoca en la empresa San Fernando S.A.C., que se encuentra ubicada en el distrito de Surco, Lima, Perú. Esta elección se basa en la relevancia y accesibilidad de la empresa, así como en su representatividad dentro del sector avícola en la región. Además, se llevó a cabo un análisis documental exhaustivo, que implica la

revisión y evaluación de registros financieros, informes de ventas, y cualquier otro documento relevante relacionado con las actividades comerciales de la empresa.

La selección de San Fernando S.A.C. como el ámbito de estudio proporciona una oportunidad única para obtener información valiosa sobre las prácticas de ventas en una empresa líder en el sector avícola peruano. Esto facilita una comprensión profunda de los desafíos y oportunidades específicos que la empresa enfrenta en términos de predicción de ventas, así como la evaluación de la efectividad del modelo de Deep Learning propuesto.

### **3.3 Variables**

Las variables de estudio en esta investigación se centran en el uso del Deep Learning como variable independiente y las predicciones de ventas como variable dependiente. El Deep Learning, una rama especializada del Machine Learning, se define como un enfoque computacional que permite a las máquinas aprender patrones y representaciones de datos de manera autónoma a partir de conjuntos de datos. Por otro lado, las predicciones de ventas comprenden la estimación anticipada del monto y el momento de las ventas futuras en función de datos históricos y variables relevantes.

Según Bengio, Goodfellow y Courville (2016), el Deep Learning ha demostrado ser una herramienta poderosa en la predicción de eventos y tendencias en diversos campos, incluido el empresarial. Por su parte, Hastie y Tibshirani (2009) señalan que las predicciones de ventas precisas son fundamentales para la planificación estratégica y operativa de las empresas, ya que permiten una asignación eficiente de recursos y una toma de decisiones informada.



### ***3.3.1. Variable independiente: Deep Learning***

(Torres, 2018), destaca principalmente el aprendizaje automático que es la red neuronal artificial. Para comprender su sistema, se puede imaginar que estos algoritmos guardan semejanza con la neurona humana, y aunque en el pasado se ha hecho referencia a su capacidad para obtener resultados, en la actualidad, esta comparación tiene una relevancia limitada.

#### **Dimensiones:**

- **Arquitectura de Red:** Número de capas, tipos de capas (convolucionales, recurrentes, etc.).
- **Capacidad de Procesamiento:** Tamaño y complejidad de los datos que puede manejar.
- **Eficiencia en el Aprendizaje:** Velocidad y eficacia con la que el modelo aprende de los datos.

#### **Indicadores:**

- **Precisión y Exactitud:** Exactitud de las predicciones o clasificaciones realizadas por el modelo.
- **Tiempo de Entrenamiento:** Duración del proceso de aprendizaje.
- **Generalización:** Capacidad del modelo para funcionar bien en datos no vistos durante el entrenamiento.

### ***3.3.2. Variable Dependiente: Predicciones de Ventas***

La creciente variedad de productos y la necesidad de usar recursos eficientemente, como equipos, mano de obra y materias primas, exigen a los productores implementar programas de producción flexibles y rigurosos para optimizar la entrega y minimizar costos (Ocampo et al., 2004). Esto es vital en mercados emergentes con demanda inestable. Pronósticos precisos son esenciales para evitar excesos de inventario, costos adicionales y pérdida de ventas. Una

estimación de ventas rápida y fiable es crucial para la planificación y competitividad en el mercado.

### **Dimensiones:**

a) **Predicción de Monto de Ventas:** Esta dimensión se refiere a la capacidad de predecir el valor total en términos monetarios de las ventas de una empresa en un periodo específico. Este enfoque implica el uso de modelos estadísticos o de aprendizaje automático para estimar el volumen de ingresos generado por una empresa, basándose en factores como tendencias históricas, condiciones del mercado y comportamiento del consumidor.

### **Indicadores**

- Precisión de la Predicción: Grado de coincidencia entre las predicciones y las ventas reales.
- Error Medio Absoluto: Promedio de las diferencias absolutas entre las predicciones y los valores reales.
- Coeficiente de Determinación ( $R^2$ ): Mide cuánto de la variación en las ventas puede ser explicado por el modelo.

b) **Predicción Temporal de Ventas:** Esta dimensión se centra en predecir el momento o período en que las ventas ocurren. Esto incluye identificar patrones temporales y estacionales en los datos de ventas para prever e identificar los momentos de picos o caídas en las transacciones comerciales. Esta capacidad es crucial para la planificación y la gestión de inventarios, así como para la estrategia de marketing y promociones.

### **Indicadores:**

- Precisión Temporal: Cuán cerca están las fechas predichas de las fechas reales de las ventas.

- Desviación Estándar de la Predicción Temporal: Variabilidad en la precisión de las predicciones de tiempo.
- Índice de Acierto en Tendencias: Evaluación de qué tan bien el modelo predice el patrón o tendencia de las ventas a lo largo del tiempo.

### **3.4 Población y muestra.**

La selección de la población y muestra es un paso crítico en la investigación. La población, definida como el universo de estudio, debe ser claramente delimitada (Hernández Sampieri, Fernández, & Baptista, 2014). En este estudio, la población consiste en 50 trabajadores del Departamento de Ventas de la empresa San Fernando S.A.C., así como en 10,000 registros de ventas históricas almacenados en su base de datos, de enero a julio del 2023.

Babbie (2016) resalta la relevancia de elegir cuidadosamente la muestra con el propósito de asegurar que los resultados reflejen fielmente la población y reducir cualquier sesgo potencial. La selección de la muestra puede realizarse de forma aleatoria o estratificada, dependiendo de las particularidades y metas del estudio. En este sentido, se optó por un grupo de 20 trabajadores de manera conveniente para representar las diversas áreas del Departamento de Ventas de la empresa.

La razón para elegir como muestra un grupo de 20 trabajadores se basa en la disponibilidad y accesibilidad limitadas de participantes en el estudio, así como en consideraciones de costos y recursos. También se consideraron limitaciones prácticas de tiempo y logística al determinar el tamaño de la muestra.

#### **3.4.1. Población**

Con relación a ello, Hernández, Fernández y Baptista (2014) sostienen que: “es un total de componentes que tienen en común s aspectos similares determinados” (p. 147). En ello se incluye el total de elementos que se investiga.

Por su parte, Durand (2014) afirmó: “Es el conglomerado total de sucesos, personas o materiales con rasgos similares de la que se considera interesante obtener conclusiones en función a ellos (p. 07).

Para este estudio, se consideraron 50 trabajadores del departamento de ventas de la empresa San Fernando S.A.C., debido a varios factores. En primer lugar, este tamaño de población se consideró adecuado para capturar una representación significativa del conjunto de empleados en estudio, lo que aumenta la validez y la generalización de los resultados. Además, con 50 trabajadores, se puede obtener una variedad de perspectivas y experiencias, lo que enriquece el análisis de los datos y permite explorar una amplia gama de situaciones y opiniones dentro del departamento de ventas.

Además, también se realizó un análisis de las ventas históricas, con un total de 10,000 registros de la base de datos correspondientes al período de enero a julio de 2023.

### ***3.4.2. Muestra***

Según Hernández (2014), una muestra representa una fracción de la población total, seleccionada no necesariamente de forma aleatoria, sino en función de criterios específicos relacionados con los aspectos estudiados. La investigación de tipo no probabilístico se enfoca en fenómenos, información o individuos con características distintivas, lo que permite explorar diversas perspectivas dentro de un mismo contexto.

Para el presente estudio se consideró 10,000 registros, tomado de las ventas históricas almacenada en la base de datos de la empresa, de enero a julio del 2023. Asimismo, cabe mencionar que, para efectos de esta investigación, se ha tomado un grupo experimental de 20 trabajadores por conveniencia representando las áreas involucradas en el Departamento de Ventas de la empresa San Fernando S.A.C., en el periodo comprendido entre enero a julio de 2023, a

dicho personal se le aplicara una propuesta de acción que incluye en uno de sus puntos relevantes varias sesiones de capacitaciones a fin de que se logre los objetivos establecidos en esta investigación.

### **3.5 Instrumentos**

En esta sección se detallan los instrumentos utilizados para la recolección de datos en el marco de la investigación sobre la implementación de un modelo de Deep Learning para mejorar la predicción de ventas en la empresa. Los instrumentos seleccionados se diseñaron específicamente para capturar información, el enfoque es cuantitativo que se relaciona con el comportamiento de las ventas y la experiencia de los trabajadores del Departamento de Ventas.

El primer instrumento empleado fue un Cuestionario de Percepción sobre la Implementación del Modelo de Deep Learning, el cuál fue estructurado y diseñado tanto en su versión de pretest como de postest, con el fin de recopilar datos cuantitativos sobre diversos aspectos relevantes para la predicción de ventas. Este cuestionario se aplicó al personal del Departamento de Ventas, con el objetivo de obtener datos numéricos sobre su percepción, conocimientos y experiencia en relación con el proceso de ventas y la implementación del modelo de Deep Learning.

El segundo método empleado fue un sistema de registro de ventas en línea, diseñado como un registro de observaciones, el cual se estableció como una base de datos estructurada para recopilar datos históricos y actuales sobre las ventas de la empresa. Este registro de observaciones incluyó información cuantitativa detallada sobre el monto de las ventas y las fechas de las transacciones.

Ambos instrumentos se diseñaron cuidadosamente para proporcionar datos numéricos complementarios y enriquecer el análisis de la investigación. El cuestionario permitió obtener

información directa y cuantificable de los trabajadores del Departamento de Ventas, mientras que el registro de observaciones proporcionó datos objetivos y cuantitativos sobre el desempeño histórico de las ventas de la empresa.

El uso combinado de estos instrumentos permitió obtener una visión integral de los factores que influyen en la predicción de ventas y evaluación del modelo de Deep Learning implementado. A través de la aplicación de estos instrumentos, se buscó recopilar datos relevantes y detallados que respalden los objetivos de la investigación y contribuyan a la comprensión y mejora del proceso de predicción de ventas en la Empresa San Fernando S.A.C.

### ***3.5.1. Técnica***

Aguiar (2016) indicó: La investigación no hubiese tenido fin de ser sin la utilización de metodología para recoger la información, dicha técnica lleva a verificar el planteamiento del problema, determinando por metodologías que se usaron. Determinando medios, mecanismos e instrumentos los que fueron usados en el estudio.

A continuación, se describen las técnicas utilizadas para la recolección y análisis de datos de la investigación. La selección de las técnicas se basa en los objetivos específicos y la naturaleza del estudio, centrándose en la obtención de datos cuantitativos para evaluar el impacto del modelo de Deep Learning en la predicción de ventas. Las técnicas empleadas se detallan a continuación:

- a) **Técnica de Encuesta:** La técnica de encuesta se utiliza como método principal para recopilar información sobre las ventas de la Empresa y la percepción de los trabajadores del Departamento de Ventas sobre la implementación del modelo de Deep Learning. Se diseñó un cuestionario estructurado que incluye preguntas cerradas y de escala Likert para medir variables relacionadas con el monto de las ventas, las fechas de las transacciones y

la efectividad del modelo en la predicción de ventas. Esta técnica permite obtener datos cuantitativos directamente de los trabajadores, lo que facilita la evaluación de la eficacia del modelo desde su perspectiva y la comparación con los datos reales de ventas.

- b) **Técnica de Observación:** La técnica de observación se emplea para registrar y analizar los datos de ventas almacenados en la base de datos. Se realiza un seguimiento detallado de las transacciones comerciales, incluyendo el monto de las ventas, las fechas de las transacciones y otros factores relevantes. Esta técnica proporciona datos objetivos y cuantitativos sobre el comportamiento de las ventas antes y después de la implementación del modelo de Deep Learning. Además, permite comparar los resultados obtenidos del modelo con los datos reales de ventas para evaluar su precisión y eficacia en la predicción.

### ***3.5.2. Instrumentos de la investigación***

El instrumento en una investigación científica es una herramienta clave que debe ser diseñada, validada y utilizada cuidadosamente para garantizar la recolección de datos precisos y fiables, lo que a su vez asegura la calidad y credibilidad de los hallazgos de la investigación (Hernández, Fernández y Baptista, 2014).

Los instrumentos se seleccionaron cuidadosamente para obtener información relevante y precisa sobre las variables en estudio. A continuación, se describen los instrumentos utilizados:

- a) **Cuestionario (Pretest y Postest) – Tipo Participativo:** El cuestionario se diseñó para recopilar información sobre las ventas de la empresa y la percepción de los trabajadores del Departamento de Ventas sobre la implementación del modelo de Deep Learning. Es de enfoque cuantitativo, se estructuró en dos partes: un pretest realizado antes de la implementación del modelo y un postest realizado después de un período determinado. El cuestionario incluye preguntas cerradas y de escala Likert para medir variables

relacionadas con el monto de las ventas, las fechas de las transacciones y la efectividad del modelo en la predicción de ventas. Se utilizaron preguntas específicas para evaluar la precisión y utilidad del modelo desde la perspectiva de los trabajadores del departamento de ventas. La técnica utilizada para este instrumento es la encuesta.

- b) Registro de Observaciones (Base de Datos) – Tipo no participativo: El registro de observaciones consiste en el seguimiento y análisis de los datos de ventas almacenados en la base de datos de la empresa. Se recopilan datos detallados sobre las transacciones comerciales, incluyendo el monto de las ventas y las fechas de las transacciones. Este instrumento permite registrar de manera objetiva y sistemática las ventas realizadas antes y después de la implementación del modelo de Deep Learning. Se emplea para comparar los resultados obtenidos del modelo con los datos reales de ventas y evaluar su precisión y eficacia en la predicción. La técnica utilizada para este instrumento es la observación.

Ambos instrumentos se diseñaron con el objetivo de obtener información completa y detallada sobre las ventas de la empresa y la percepción de los trabajadores sobre el modelo de Deep Learning. La combinación de un cuestionario estructurado y el análisis de datos de ventas permite abordar los objetivos de la investigación desde diferentes perspectivas y garantizar la validez y confiabilidad de los resultados obtenidos. Además, se espera que la técnica participativa utilizada en el cuestionario promueva una mayor implicación y compromiso por parte de los trabajadores del departamento de ventas, mientras que el enfoque no participativo del registro de observaciones garantiza la objetividad y fiabilidad de los datos recopilados.

### **3.5.3. Validez**

La validación de los instrumentos de estudio confiere un respaldo científico a la investigación, cuya aplicabilidad y suficiencia demostraron ser pertinentes, relevantes y claras,



contribuyendo así a la obtención de resultados alineados con los objetivos de la investigación (Hernández, Fernández y Baptista, 2010).

Los dos instrumentos empleados en esta investigación fueron sometidos a un proceso de validación mediante el juicio de expertos. En este proceso, tres especialistas evaluaron la coherencia y asignaron valores a cada una de las preguntas de las herramientas de investigación.

Los resultados de este proceso se documentaron en un certificado de validez, cuyos resúmenes se encuentran detallados en la Tabla 1. Además, este proceso fue debidamente documentado en un certificado de validez y una tabla de validación del instrumento, los cuales se encuentran detallados en la sección de Anexos ubicado en el Capítulo IX de la presente investigación.

**Tabla 1.**  
*Validez del instrumento mediante juicio de expertos*

<b>Expertos</b>	<b>Nombres de los expertos</b>	<b>Apl</b>	<b>Sufi</b>
Juez 1	Dr. Fernando Ochoa Paredes.	X	X
Juez 2	Dr. Roberto Casas Miranda.	X	X
Juez 3	Mg. Jorge Nolasco Valenzuela.	X	X

*Nota* Adaptado de Giroux y Tremblay (2004)

#### **3.5.4. Confiabilidad**

El proceso para la confiabilidad permite conseguir hallazgos con consistencia y que tengan coherencia según los fines de la investigación (Hernández, Fernández y Baptista, 2014).

Para garantizar la integridad de la investigación, se enfocó en la consistencia entre lo que se pretende medir y los métodos empleados para la recolección de datos. A continuación, se presenta la evaluación de la confiabilidad de los instrumentos utilizados:

- a) Cuestionario (Pretest y Postest): El cuestionario se diseñó de manera precisa para capturar información cuantitativa relacionada con las ventas. Se realizó un análisis exhaustivo para

asegurar que las preguntas estuvieran alineadas con los objetivos de la investigación y que el método de recolección de datos a través de la encuesta a los empleados del Departamento de Ventas fuera adecuado para obtener respuestas cuantitativas consistentes.

- b) Registro de Observaciones (Base de Datos): El registro de observaciones se implementó con el objetivo de capturar datos detallados sobre las transacciones de ventas de la empresa. Se llevó a cabo una meticulosa planificación para asegurar que el método de recolección de datos a través de la observación en la base de datos fuera coherente con los aspectos específicos que se buscaban medir, garantizando así la precisión y fiabilidad de los datos recopilados.

Para evaluar la confiabilidad de los instrumentos utilizados en el estudio, se realizó una prueba piloto preliminar. Esta prueba piloto permitió obtener datos que luego fueron sometidos a un análisis detallado mediante el coeficiente Alfa de Cronbach. Este coeficiente es una medida estadística que evalúa la consistencia interna de un conjunto de ítems en un instrumento de medición.

Según la Tabla 2, se observan los rangos y la interpretación que se tiene para medir la confiabilidad del instrumento. Los valores cercanos a 1 indican un alto grado de consistencia y confiabilidad en las respuestas obtenidas, lo que respalda la validez de los instrumentos utilizados en el estudio. Los resultados de la prueba piloto se encuentran detallados en la figura 27 de la sección de Anexos ubicado en el Capítulo IX de la presente investigación.

**Tabla 2.***Determinación del nivel de confiabilidad de los instrumentos*

<b>Rangos</b>	<b>Interpretación</b>
0 a 0.20	Muy baja
0.21 a 0.40	Baja
0.41 a 0.60	Media
0.61 a 0.80	Alta
0.81 a 1.00	Muy alta

*Nota.* Tomado de Giroux y Tremblay (2004).

Los resultados presentados en la Figura 28 de la sección Anexos, ofrecen una evaluación detallada de la fiabilidad del instrumento empleado en el estudio. Mediante el análisis de los datos recopilados, se ha examinado tanto la consistencia interna como la estabilidad temporal del instrumento. Estos hallazgos respaldan la fiabilidad y validez de este, lo que otorga mayor credibilidad a los resultados obtenidos en la investigación.

Esta información se encuentra resumida en la Tabla 3, la cual muestra un coeficiente alfa de Cronbach de 0.978, el cual es extremadamente alto y sugiere una consistencia interna excelente entre los seis ítems de la escala que se están evaluando. Esto indica que los elementos de la escala están muy correlacionados entre sí y que miden de manera muy consistente el mismo constructo o característica que estás investigando. Por lo tanto, obtener un valor tan alto con solo seis ítems sugiere que estos ítems están muy relacionados y miden de manera consistente el mismo constructo. En resumen, se tiene una escala muy confiable y coherente para medir la variable de interés.

**Tabla 3.***Fiabilidad del Instrumento*

Alfa de Cronbach	N° de ítems
0.978	06

### **3.6. Procedimientos**

El acopio y manejo de información son aspectos cruciales para la toma de decisiones eficaces (Russell & Norvig, 2016). La información se representa en números y pasa por distintas fases de procesamiento, desde la obtención hasta la generación de resultados útiles para la toma de decisiones (Friedman & Hastie, 2001).

La técnica Kmeans, implementada utilizando la API Scikit-learn en Python, es fundamental para el análisis de datos (Pedregosa et al., 2011). En una consulta específica que involucra 14 dimensiones, se observa que la técnica necesitó 23 iteraciones para establecer el conglomerado. La elección de la metodología de inicio influye en el número de iteraciones y en la inercia del algoritmo. Se observó que el método de inicio aleatorio aleatorio mostró una eficiencia inferior en comparación con la metodología de inicio k-means++ (Arthur & Vassilvitskii, 2007).

La calidad de los grupos generados por las técnicas de agrupamiento está estrechamente relacionada con la calidad de la información y la dimensionalidad del dataset (Tan et al., 2006). Un mayor número de dimensiones aumenta la complejidad del algoritmo, ya que debe calcular distancias y establecer centroides con mayor precisión. Esto puede requerir capacidades computacionales más altas para obtener resultados precisos (Bishop, 2006).

### **3.7. Análisis de datos**

Para recoger la información en sus distintas fases, se usó la estadística como un mecanismo. "La etapa se muestra después del empleo del instrumento y terminada el acopio de la información. Se analizó la información y dio contestación a las preguntas de la indagación" (Hernández, Fernández & Baptista, 2014, p. 46).

Se aplicó la Prueba de normalidad; puesto que los integrantes del estudio con el indicador fueron de 10,000 registros, se usó la normalidad de Kolmogórov-Smirnov con la utilización del

IBM SPSS. para poder ver si la muestra tuvo o no una distribución normal, y según los hallazgos conseguidos se aplicó una prueba paramétrica o no paramétrica.

Para contrastar las hipótesis, se consideró lo siguiente: (a) Formulación de la hipótesis nula y alternas del estudio, (b) Determinación del grado de significancia, o error que el estudioso pudo estar dispuesto a asumir, (c) Selección del estadístico de prueba (d) Estimación del p-valor y (e) Toma de decisión, en función del resultado obtenido, para ver si se rechaza la hipótesis nula. Asimismo, para la elección de la estadística de prueba, se consideró: (a) Objetivo de la investigación, (b) Diseño de la investigación, (c) Variable de la investigación y (d) Escala de medición.

### **3.8 Consideraciones éticas**

Se consideró la autenticidad de los hallazgos encontrados, el respeto por el aspecto del intelecto, las opiniones de tipo política, religiosa y moral, el entorno ambiental y la biodiversidad, los compromisos sociales, políticos, jurídicos y éticos, el respeto a la privacidad y la protección a la identidad de los sujetos (Bishop, 2006; Hastie & Tibshirani, 2009).

Los profesionales de Tecnologías de la Información (T.I.) están formados para llevar a cabo actividades de forma ética, con familiarización con estándares nacionales e internacionales que promueven el crecimiento y las funciones de las plataformas de T.I. que conservan (Russell & Norvig, 2016). Del mismo modo, pueden explicar y justificar las decisiones del profesional en un lenguaje comprensible para la parte administrativa y los consumidores (Friedman & Hastie, 2001). Son conscientes de las implicaciones presupuestarias de las opciones tecnológicas y saben defender los presupuestos de manera adecuada (Bengio, Goodfellow & Courville, 2016). Poseen una amplia experiencia en garantizar correctamente las redes de T.I., los empleos, las instituciones de información y los servicios en línea. (Pedregosa et al., 2011).

#### IV. RESULTADOS

Los resultados obtenidos tras la implementación del modelo de Deep Learning se han articulado cuidadosamente con los objetivos de la investigación, con un enfoque metodológico en la medición del desempeño de la variable dependiente, es decir, las ventas de la Empresa San Fernando S.A.C., tanto antes como después de la implementación del modelo.

El modelo de Deep Learning ha demostrado un desempeño altamente efectivo en la predicción de las ventas de la empresa. A través del análisis de un historial de 10,000 registros, se ha observado una correlación significativa entre las entradas del modelo y las ventas reales, como se evidencia en el coeficiente de determinación  $R^2$  de 0.997. Estos resultados respaldan el objetivo general de la investigación, que busca determinar en qué medida el modelo de Deep Learning mejora la predicción de las ventas.

Para evaluar el impacto del modelo en el Departamento de ventas, se ha aplicado un cuestionario tanto en un pretest como en un posttest a los trabajadores del departamento. Este enfoque se alinea con el objetivo específico de determinar en qué medida el modelo de Deep Learning mejora la predicción del monto y las fechas de las ventas. Se ha seleccionado un grupo experimental de 20 trabajadores por conveniencia para una evaluación más detallada del cambio en las percepciones y el desempeño del personal.

Además, se ha llevado a cabo un análisis estadístico para examinar la normalidad de los datos recopilados mediante el cuestionario. La prueba de Shapiro-Wilk ha confirmado la distribución normal de los datos, lo que valida el uso de pruebas paramétricas para el análisis comparativo del desempeño del personal antes y después de la implementación del modelo.

Estos resultados, debidamente contextualizados y relacionados con los objetivos de la investigación, proporcionan una visión integral del impacto del modelo de Deep Learning en las ventas de la Empresa San Fernando S.A.C. y en el desempeño del departamento de ventas.

## **4.1 Resultados del modelo de Redes Neuronales diseñado para mejorar la predicción de ventas**

En esta sección se exponen los resultados obtenidos mediante la implementación del modelo de Redes Neuronales, diseñado con el propósito de mejorar la precisión en la predicción de ventas. Estos hallazgos representan una evaluación fundamental de la efectividad del modelo, marcando el inicio de un análisis más exhaustivo y la evaluación de su capacidad predictiva en etapas posteriores de la investigación.

### ***4.1.1 Construcción del Modelo***

Se empleó un algoritmo Red neuronal, se tuvo la referencia de papers, siendo uno de ellos “Sales Forecasting Model for New-Released and Short-Term Product: Un estudio de caso de teléfonos móviles”, en donde se hizo la predicción de ventas para lanzamientos nuevos y a corto plazo. Producto: una indagación de celulares, en función a datos de las ventas hechas, empleando el algoritmo de Red Neuronal, ya que hace el recuerdo de la secuencia de la información por un período largo de tiempo, similar a lo que se realizó en el presente trabajo de investigación

### ***4.1.2 Importando las librerías***

A continuación, se describirá el modelo elegido sobre los datos de entrenamiento. En esta fase se detallarán los ajustes de parámetros del modelo, así como la salida del mismo y su respectiva descripción.

Se utilizó el programa Jupyter Notebook, el cual permite desarrollar código en Python, de manera que estos puedan ser ejecutados por bloques y muestre texto, ecuaciones, gráficas e imágenes. Adicionalmente, permitió implementar una arquitectura de redes neuronales para predecir los volúmenes de ventas de la empresa San Fernando S.A.C.

Para comenzar con el desarrollo del entrenamiento de los datos, se procedió a realizar la importación de las librerías Numpy, para el procesamiento de los números; Pandas, para las estructuras y el análisis de datos; Matplotlib, para la visualización y ploteo de las gráficas; describe de Scipy, para la computa de estadísticas descriptivas del modelo, indicando su varianza, desviación estándar, entre otras; Seaborn, librería basada en Matplotlib, para la visualización de la data estadística, toda la línea de código utilizada se muestra en la Figura 12. Asimismo, se definió un máximo de 16 columnas y 182334 filas para la visualización de los registros de las ventas.

**Figura 12.**  
*Librerías de Redes Neuronales.*

```
In [33]: import matplotlib.pyplot as plt
from sklearn.ensemble import RandomForestRegressor
from sklearn.metrics import mean_squared_error
from sklearn.model_selection import cross_val_score
from sklearn.model_selection import train_test_split
from sklearn.model_selection import RepeatedKFold
from sklearn.model_selection import GridSearchCV
from sklearn.model_selection import ParameterGrid
from sklearn.inspection import permutation_importance
from sklearn.metrics import confusion_matrix
#from sklearn.metrics import plot_confusion_matrix
import seaborn as sb
import multiprocessing

from sklearn.model_selection import KFold
from sklearn import tree
import seaborn as sns
sns.set(context="notebook", palette="Spectral", style = 'darkgrid', font_scale = 1.5, color_codes=True)
# Configuración warnings
# =====
# No presentar advertencia
import warnings
warnings.filterwarnings('ignore')
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
plt.style.use('ggplot')
pd.set_option('display.max_columns',None)#Visualizamos todas las columnas

import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
%matplotlib inline
plt.rcParams['figure.figsize'] = (16, 9)
plt.style.use('fast')

from keras.models import Sequential
from keras.layers import Dense,Activation,Flatten
from sklearn.preprocessing import MinMaxScaler
```

*Nota.* Esta figura muestra un fragmento de código en un entorno de desarrollo de Python. El código incluye varias importaciones de librerías de Python, principalmente relacionadas con el procesamiento y análisis de datos.

### 4.1.3 Construcción del Dataset

En esta parte se empleó, los datos de ventas de San Fernando S.A.C. Luego se puso el archivo en formato .csv, a través de la librería Pandas, la cual se evidencia en la Figura 13, lo que permitió leer y hacer el análisis de los registros.



**Figura 13.**  
*Importar data ventas*

```
In [2]: # CARGA DE LA FUENTE DE DATOS(DATASET) datos.csv y Lo almacenamos en un dataframe data
%time data = pd.read_csv('datos.csv', sep=';', encoding='latin-1', decimal=",", parse_dates = ['fec_factura'], dayfirst = True )
data.head()

CPU times: total: 1.36 s
Wall time: 1.4 s

Out[2]:
```

	desc_categoria	factura_sap	nro_ticket	ticket_referencia	cod_organizacion_vta	desc_organizacion_vta	cod_canal_dist	desc_canal_dist	cod_clase_factura	d
0	NaN	91788382	12-00450-0005487	OHC1	P202	SUPERDEPORTE PLUS PE	10	Retail	ZTKB	
1	NaN	91788812	12-00480-0003389	OLU1	P202	SUPERDEPORTE PLUS PE	10	Retail	ZTKB	

*Nota.* Esta figura muestra la carga de un archivo data.csv: 182,335 rows × 66 columnas. El tiempo de carga: Wall time: 1.39 s.

#### 4.1.4 Limpieza

Luego se procede a eliminar las columnas que tienen en su contenido valores que faltan, la

Figura 14 muestra cómo se realizó la eliminación de los valores faltantes.

**Figura 14.**  
*Limpieza de columnas*

```
In [4]: # LIMPIEZA dropna(axis=1) elimina las columnas que contienen valores faltantes
data=data.dropna(axis=1)
```

*Nota.* Esta figura muestra un fragmento de código en un entorno de desarrollo de Python que tiene como propósito la limpieza de datos en un DataFrame de Pandas.

Luego de ello, se seleccionó las columnas que se requieren, tal como se evidencia en el código mostrado de la Figura 15.

**Figura 15.**  
*Selección de Columnas*

```
In [5]: data = pd.DataFrame(data, columns=['cod_centro', 'desc_centro1', 'cod_articulo', 'desc_articulo',
'cod_marca', 'desc_marca', 'fec_factura', 'precio_venta_total', 'precio_venta_unidad', 'pvp',
'valor_neto_total', 'valor_neto_unit', 'igv_total',
'monto_total', 'costo_venta_total', 'costo_venta_unit', 'AÑO'])
```

*Nota.* La selección efectiva de columnas implica identificar y utilizar aquellas características que son más informativas o relevantes para la tarea específica que la red neuronal está diseñada para realizar.

Luego, se convirtió en clases de información estándar, como se muestra en la Figura 16.

**Figura 16.**  
*Conversión de tipos de datos*

```
In [6]: # Convertimos a tipos de datos
data['cod_centro'] = data['cod_centro'].astype('string')
data['desc_centro1'] = data['desc_centro1'].astype('string')
data['cod_articulo'] = data['cod_articulo'].astype('string')
data['desc_articulo'] = data['desc_articulo'].astype('string')
data['cod_marca'] = data['cod_marca'].astype('string')
data['desc_marca'] = data['desc_marca'].astype('string')

data.precio_venta_total= data.precio_venta_total.abs()
data.precio_venta_unidad= data.precio_venta_unidad.abs()
data.pvp= data.pvp.abs()
data.valor_neto_total= data.valor_neto_total.abs()
data.valor_neto_unit= data.valor_neto_unit.abs()
data.igv_total= data.igv_total.abs()
data.monto_total= data.monto_total.abs()
data.costo_venta_total= data.costo_venta_total.abs()
data.costo_venta_unit= data.costo_venta_unit.abs()
data['fec_factura'] = pd.to_datetime(data['fec_factura'])
data.fec_factura = pd.to_datetime(data.fec_factura, format = "%d-%m-%Y", errors = 'coerce')
```

*Nota.* Esta figura muestra un fragmento de código en un entorno de desarrollo de Python que tiene como propósito la limpieza de datos en un DataFrame de Pandas.

Se lista las columnas para ver los valores nulos, tal como se visualiza en la Figura 17.

**Figura 17.**  
*Listado de Columnas*

```
In [8]: data1.info()

<class 'pandas.core.frame.DataFrame'>
RangeIndex: 182334 entries, 0 to 182333
Data columns (total 17 columns):
#   Column                Non-Null Count  Dtype
---  -
0   cod_centro            182334 non-null  string
1   desc_centro1          182334 non-null  string
2   cod_articulo          182334 non-null  string
3   desc_articulo         182334 non-null  string
4   cod_marca             182334 non-null  string
5   desc_marca            182334 non-null  string
6   fec_factura           182334 non-null  datetime64[ns]
7   precio_venta_total    182334 non-null  float64
8   precio_venta_unidad   182334 non-null  float64
9   pvp                   182334 non-null  float64
```

*Nota.* Esta figura muestra un fragmento de código en un entorno de desarrollo de Python que tiene como propósito proporcionar un resumen conciso de las columnas.

Luego, tal como se evidencia en la Figura 18, se agrupa toda la información por fechas de la factura (fec\_factura).

**Figura 18.**  
*Agrupación de Datos*

```
In [15]: data=data.groupby(['fec_factura'])[['precio_venta_total', 'precio_venta_unidad', 'pvp',
                                             'valor_neto_total', 'valor_neto_unit', 'igv_total',
                                             'monto_total', 'costo_venta_total', 'costo_venta_unit']].sum()
data=data.reset_index()
data
```

```
Out[15]:
```

	fec_factura	precio_venta_total	precio_venta_unidad	pvp	valor_neto_total	valor_neto_unit	igv_total	monto_total	costo_venta_total	costo_venta_unit
0	2017-01-01	168.64	168.64	199.0	67.46	67.46	12.14	79.60	43.52	43.52
1	2017-01-02	2189.31	2155.50	2543.5	2189.31	2155.50	394.09	2583.40	1540.62	1519.14
2	2017-01-03	1568.46	1467.03	1731.1	1513.04	1411.61	272.36	1785.40	1068.97	1004.52
3	2017-01-04	4626.99	3277.84	4265.9	4407.09	3057.94	793.31	5200.40	2940.02	2063.22
4	2017-01-05	2185.89	2185.89	2579.4	1945.65	1945.65	350.25	2295.90	1285.65	1285.65

*Nota.* Esta figura muestra un fragmento de código en un entorno de desarrollo de Python muestra una tabla de datos que es el resultado de aplicar una agrupación y suma acumulada en un DataFrame de Pandas llamado data.

A continuación, se lista las columnas para ver los números de registros, tal como se muestra en la Figura 19.

**Figura 19.**  
*Visualizar número de registros*

```
In [16]: data.info()
```


```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 2180 entries, 0 to 2179
Data columns (total 10 columns):
#   Column                Non-Null Count  Dtype
---  -
0   fec_factura           2180 non-null   datetime64[ns]
1   precio_venta_total    2180 non-null   float64
2   precio_venta_unidad  2180 non-null   float64
3   pvp                   2180 non-null   float64
4   valor_neto_total      2180 non-null   float64
5   valor_neto_unit       2180 non-null   float64
6   igv_total             2180 non-null   float64
7   monto_total          2180 non-null   float64
8   costo_venta_total     2180 non-null   float64
9   costo_venta_unit      2180 non-null   float64
dtypes: datetime64[ns](1), float64(9)
memory usage: 170.4 KB
```

*Nota.* Esta figura muestra un fragmento de código en un entorno de desarrollo de Python proporciona información resumida sobre la estructura y los tipos de datos del DataFrame.

### 4.1.5 Mapa de Calor

Ahora crearemos un mapa de calor (heatmap) para visualizar patrones y tendencias en datos multivariados, especialmente cuando hay demasiados datos y se busca una representación resumida y, dentro de estos patrones, heatmap es perfecto para visualizar las correlaciones de columnas de un dataframe. Se puede observar a mayor detalle en la Figura 20.

**Figura 20.**  
*Mapas de calor*



*Nota.* Esta figura muestra una matriz de correlación visualizada a través de un mapa de calor.

#### ***4.1.6 Normalización y Autorregresión***

En la fase de preparación de los datos de entrenamiento, se lleva a cabo un proceso fundamental conocido como normalización, el cual implica ajustar los valores del total neto a un rango específico. En el contexto de las redes neuronales, este proceso es esencial ya que ayuda a escalar los datos de entrada de manera que se ajusten a una distribución deseada, lo que mejora la eficiencia y la precisión del entrenamiento de la red.

Por otro lado, la autorregresión con redes neuronales consiste en utilizar estas estructuras para modelar y predecir una variable en función de sus propios valores pasados. Este enfoque es particularmente valioso en la predicción de series temporales, donde las observaciones futuras están intrínsecamente ligadas a las pasadas.

La combinación de estos enfoques permite obtener modelos más sólidos y precisos para la predicción de ventas en el contexto de San Fernando S.A.C.

#### 4.1.7 Conjunto De Datos de Entrenamiento

Ahora se elabora el grupo de información de adiestramiento, se normaliza los valores del valor neto total, tal como se muestra en la figura 21.

**Figura 21.**  
*Datos de Entrenamiento*

	fec_factura	precio_venta_total	precio_venta_unidad	pvp	valor_neto_total	valor_neto_unit	igv_total	monto_total	costo_venta_total	costo_venta_unit	precio_venta_total1
0	2017-01-01	168.64	168.64	199.0	4.211535	67.46	12.14	79.60	43.52	43.52	999.00
1	2017-01-02	2189.31	2155.50	2543.5	7.691342	2155.50	394.09	2583.40	1540.62	1519.14	168.64
2	2017-01-03	1568.46	1467.03	1731.1	7.321876	1411.61	272.36	1785.40	1068.97	1004.52	2189.31
3	2017-01-04	4984.27	3815.12	4265.9	8.464714	3395.22	854.03	5598.40	3159.26	2282.46	1568.46
4	2017-01-05	2185.89	2185.89	2579.4	7.573351	1945.65	350.25	2295.90	1285.65	1285.65	4984.27
...	...	...	...	...	...	...	...	...	...	...	...
2175	2023-02-23	21439.41	20602.56	24310.9	9.898734	19330.93	3582.82	23487.97	13753.92	13238.30	22787.86
2176	2023-02-24	24207.95	24132.20	28475.8	10.057055	23243.99	4197.45	27517.19	15649.77	15633.57	21439.41
2177	2023-02-25	27006.06	26446.99	31207.3	10.163427	25428.78	4668.54	30605.58	17416.75	17038.22	24207.95
2178	2023-02-26	17865.85	17442.29	20581.8	9.735226	16479.09	3042.38	19945.03	11592.85	11318.53	27006.06
2179	2023-02-27	19017.21	18262.64	21549.8	9.789606	17229.95	3212.42	21059.70	12270.67	11810.83	17865.85

2180 rows x 73 columns

*Nota.* Esta figura muestra un DataFrame de Pandas que contiene datos agrupados por fechas.

En el contexto de este estudio sobre la predicción de ventas en la Empresa San Fernando S.A.C., el conjunto de datos de entrenamiento comprende registros históricos de ventas, que incluyen información sobre variables relevantes como el tipo de producto, la fecha de factura, precio de venta total, precio de venta unitario, valor neto total, I.G.V., monto total, costo de venta total, costo de venta unitario y el precio de venta total. Estos datos se recopilan y preparan antes de utilizarlos para entrenar el modelo de Deep Learning.

#### 4.1.8 Definimos los features y Label

```

#Se define los features (x), es decir la información que ayuda a predecir
- valor_neto_total

X =
data[['precio_venta_total','precio_venta_unidad','pvp','valor_neto_unit','igv_total','monto_
total','costo_venta_total','costo_venta_unit']]

#Definimos label (y), es decir los datos de salida - valor_neto_total
y = data[['valor_neto_total']]

```

#### 4.1.9 Modelado

Se emplea técnicas de machine learning, para elaborar el modelo que ayude a contestar a las interrogantes planteadas en la etapa de entendimiento del problema.

```

from sklearn.model_selection import train_test_split

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.20, random_state=12345,
shuffle=False)

```

```

from sklearn.tree import DecisionTreeRegressor

# Llamamos a la función
mi_dt = DecisionTreeRegressor(random_state=12345)

# Entrenamos nuestro modelo
mi_dt.fit(X_train, y_train)

```

```
# Hacemos las predicciones
pred=mi_dt.predict(X_test)

from sklearn.metrics import r2_score

#print(r2_score(list(y_test),list(mi_dt.predict(X_test))))
```

#### 4.1.10 Evaluación

Dicha etapa se hace la evaluación de la calidad del modelo y se hace la comprobación si contesta a las interrogantes planteadas en la etapa de entendimiento del problema.

```
pred=np.exp(pred)
ytest=np.exp(y_test)
test2=pd.DataFrame(ytest)
test2["pred"]=pred
test2["diferencia"]=abs(test2["valor_netto_total"]-test2["pred"])
```

Luego se puede ver en la Figura 22, los datos reales y los datos predichos.

#### Figura 22.

*Evaluación de la calidad del modelo*

	valor_netto_total	pred	diferencia
1744	123404.62	123369.46	35.16
1745	119713.97	123369.46	3655.49
1746	117289.91	123369.46	6079.55
1747	161082.48	159463.40	1619.08
1748	179057.94	170323.21	8734.73
...	...	...	...
2175	19905.15	19845.95	59.20
2176	23319.74	23286.05	33.69
2177	25937.04	26082.22	145.18
2178	16902.65	16818.58	84.07
2179	17847.28	17877.82	30.54

*Nota.* Esta figura muestra un listado de la evaluación del valor real vs lo predicho.



#### 4.1.11 Indicador de Fiabilidad del Modelo

Ahora se ve en porcentajes que tan similares son los pesos de adiestramiento en función a los pesos de predicción R2 es: 0.9970536105123016.

Prediccion en base a los criterios: ALL

Del 100% de patrones, se identificó que el: 99.70536105123016 % Patrones existe un 0.294638948769844 % de patrones que no se halló. Se detalla a continuación la línea de código empleada.

```

from sklearn import metrics

def timeseries_evaluacion_metrica_func(y_true, y_pred):

    def mean_absolute_percentage_error(y_true, y_pred):
        y_true, y_pred = np.array(y_true), np.array(y_pred)
        return np.mean(np.abs((y_true - y_pred) / y_true)) * 100
    global opciones3
    print("Ahora vamos a ver porcentualmente que parecidos son los \npesos de
entrenamiento respecto a los pesos de predicción")
    print(f'R2 is : {metrics.r2_score(y_true, y_pred)}',end='\n\n')
    print("Prediccion en base a los criterios:",opciones, " ",opciones2)
    print("Del 100% de patrones, hemos identificado el:",metrics.r2_score(y_true,
y_pred)*100,"% Patrones", "hay un ",100-(metrics.r2_score(y_true, y_pred)*100),"% de
patrones que no se han podido hallar")
    print("="*10)

timeseries_evaluacion_metrica_func(test2["valor_neto_total"], test2["pred"])

```

#### 4.1.12 Comparación Real – Predicción


Continuando con ello, se presenta en la Figura 23 el rendimiento del modelo completo, también se detalla la línea de código que refleja el modelo predictivo y el desempeño como tal.

```
import matplotlib.pyplot as plt

plt.style.use('dark_background')
plt.figure(figsize=(15,6))
plt.plot(test2["valor_neto_total"],color="lime", label="real-cnt")
plt.plot(test2["pred"],color="orangered", label="Predicción-cnt")
plt.title(" Gráfico de rendimiento predictivo del modelo completo", fontsize=20)
plt.xlabel('años')
plt.ylabel("valor_neto_total")
plt.legend()
plt.show();
```

**Figura 23.**

*Rendimiento predictivo del modelo completo*



*Nota.* Esta figura muestra un gráfico de líneas titulado "Gráfico de rendimiento predictivo del modelo completo". Hay dos series de datos representadas por líneas de diferentes colores.

## 4.2 Resultados Descriptivos e Inferenciales

Se realiza un análisis exhaustivo de los datos obtenidos a través del modelo de Deep Learning implementado para mejorar la predicción de ventas. Se presentan resultados descriptivos para ofrecer una visión general de las tendencias y patrones identificados, así como resultados inferenciales que respaldan las conclusiones extraídas del modelo. Estos hallazgos contribuyen significativamente al entendimiento profundo y sólido de la eficacia predictiva del enfoque propuesto.

### 4.2.1. Pruebas de Normalidad

Para el análisis de los resultados obtenidos como se evidencia en la Tabla 4, se determinará, inicialmente, el tipo de distribución que presentan los datos, a nivel de la variable dependiente, para ello utilizamos la prueba Shapiro-Wilk de bondad de ajuste por tratarse del valor obtenido de la muestra menor igual a 50.

Planteando la Hipótesis Nula ( $H_0$ ) y la Hipótesis Alternativa ( $H_1$ ):

$H_0$ : Los datos analizados siguen una distribución normal.

$H_1$ : Los datos analizados no siguen una distribución normal.

**Tabla 4.**  
*Prueba de Normalidad*

	Pruebas de Normalidad <sup>a</sup>					
	Kolmogorov-Smirnov <sup>b</sup>			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
DIFERENCIA	<b>0,179</b>	<b>20</b>	<b>0,015</b>	<b>0,884</b>	<b>20</b>	<b>0,454</b>

a. GRUPO = Grupo Experimental.

b. Corrección de significación de Lilliefors.

De acuerdo con la prueba de Normalidad y según los resultados de Shapiro-Wilk, observamos que el valor Sig., es mayor que 0.05, por lo tanto, se acepta la hipótesis nula y se rechaza la hipótesis del investigador, es decir podemos afirmar que los datos de la muestra de estudio si provienen de una distribución normal, en tal sentido se deben utilizar estadísticos paramétricos como la t de Student.

#### **4.2.2. Descripción**

Después de la recopilación de los datos mediante los instrumentos utilizados, se procedió a analizar los mismo; y como primer resultado se muestra los resultados generales de la variable dependiente de forma descriptiva.

**4.2.2.1 Resultado General de la Investigación.** El objetivo principal de este estudio fue evaluar el impacto de la implementación del Deep Learning en la mejora de las predicciones de ventas dentro de la empresa San Fernando S.A.C., centrándonos específicamente en el departamento de ventas compuesto por jóvenes trabajadores. Se busca destacar cómo esta tecnología influye en la precisión y claridad de las predicciones de ventas, y cómo facilita la expansión y refinamiento del conocimiento en esta área, así como su aplicación práctica en las actividades cotidianas del equipo de ventas.

**Tabla 5.**

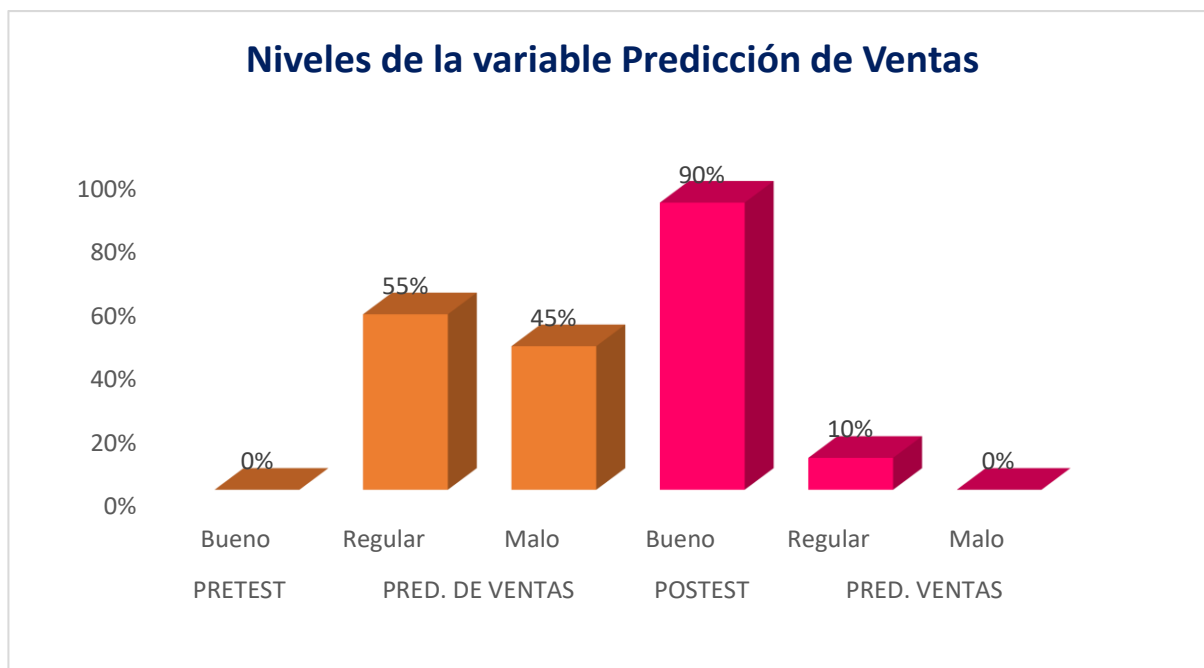
*Comparación de la variable dependiente, predicción de ventas según la percepción de los trabajadores de la empresa San Fernando S.A.C.*

	<b>Grupo</b>			
	<b>Experimental</b>			
	<b>Pre-Test</b>		<b>Post-Test</b>	
	<i>f</i>	<i>%</i>	<i>f</i>	<i>%</i>
<b>Bueno</b>	<b>0</b>	<b>0%</b>	<b>18</b>	<b>90%</b>
<b>Regular</b>	<b>11</b>	<b>55%</b>	<b>2</b>	<b>10%</b>
<b>Malo</b>	<b>9</b>	<b>45%</b>	<b>0</b>	<b>0%</b>
<b>Total</b>	<b>20</b>	<b>100%</b>	<b>20</b>	<b>100%</b>

*Nota.* Fuente extraído de la base de datos.

**Figura 24.**

*Niveles de la variable de Predicción de ventas*



***Pretest:***

En la Tabla 5 y Figura 24, Se observa que, en el grupo experimental, el 45% de los colaboradores percibió que la predicción de ventas alcanzaba un nivel malo, mientras que el 55% la consideraba regular. Sin embargo, estas diferencias no resultaron significativas.

***Postest:***

En la Tabla 5 y Figura 24, se aprecia que después de la implementación del algoritmo Deep Learning para mejorar la predicción de ventas, el 10% de los colaboradores percibió un nivel regular, mientras que el 90% restante consideró que la predicción alcanzaba un nivel bueno.

En conclusión, se constata que, después del Postest, el grupo experimental mostró diferencias significativas con respecto al Pretest en cuanto a la percepción de la precisión en la predicción de ventas.

**4.2.2.2 Resultados específicos de la investigación.****Dimensión 1**

El primer objetivo específico de la presente investigación fue determinar si la implementación del Deep Learning mejora el monto de las predicciones de las ventas en la empresa San Fernando S.A.C, enfocándose en jóvenes trabajadores del departamento de ventas, es clave destacar cómo esta tecnología influye para presentar los resultados de manera clara y precisa.

**Tabla 6.**


*Comparación de la dimensión 1: Nivel de predicción del monto de las ventas según la percepción de los trabajadores de la empresa San Fernando S.A.C.*

	<b>Grupo Experimental</b>			
	<b>Pre-Test</b>		<b>Post-Test</b>	
	<i>f</i>	<i>%</i>	<i>f</i>	<i>%</i>
<b>Bueno</b>	<b>0</b>	<b>0%</b>	<b>19</b>	<b>95%</b>
<b>Regular</b>	<b>10</b>	<b>50%</b>	<b>1</b>	<b>5%</b>
<b>Malo</b>	<b>10</b>	<b>50%</b>	<b>0</b>	<b>0%</b>
<b>Total</b>	<b>20</b>	<b>100%</b>	<b>20</b>	<b>100%</b>

*Nota:* Fuente extraído de la base de datos.

**Figura 25.**

*Niveles de la dimensión Predicción de Montos de las Ventas*

**Pretest:**

En la Tabla 6 y Figura 25, Se observa que, en el grupo experimental, 50% de los colaboradores percibió la predicción del monto como regular, mientras que el otro 50% la consideró deficiente. Sin embargo, estas diferencias no resultaron significativas.

**Postest:**

En la Tabla 6 y Figura 25, Tras la implementación del algoritmo de Deep Learning para mejorar la precisión en la predicción de montos, se evidenció una mejora significativa en la

percepción de los colaboradores. El 5% calificó la precisión como regular, mientras que el 95% restante la consideró buena.

En conclusión, se constata que, después del Postest, el grupo experimental mostró diferencias significativas con respecto al Pretest en cuanto a la percepción de la precisión en la predicción de montos.

## Dimensión 2

El segundo objetivo específico de la presente investigación fue determinar si la implementación del DeepLearning mejora las fechas de las predicciones de las ventas en la empresa San Fernando S.A.C., muestra comparaciones claras de las predicciones de fechas antes y después de la implementación del Deep Learning.

### Tabla 7.

*Niveles de Predicción de Fechas según la percepción de los trabajadores de la empresa San Fernando S.A.C.*

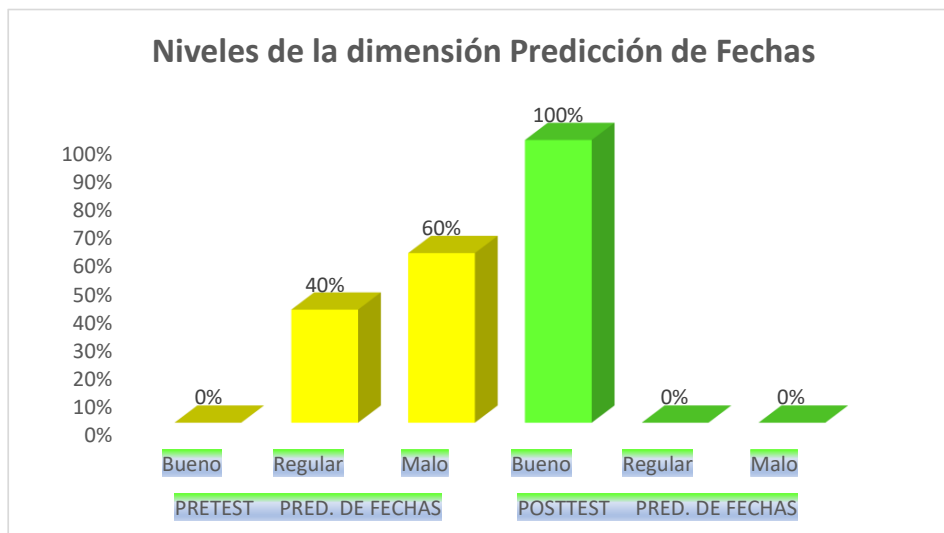
	<i>Grupo</i>			
	<i>Experimental</i>			
	<i>Pre-Test</i>		<i>Post-Test</i>	
	<i>f</i>	<i>%</i>	<i>f</i>	<i>%</i>
<i>Bueno</i>	<i>0</i>	<i>0%</i>	<i>20</i>	<i>100%</i>
<i>Regular</i>	<i>08</i>	<i>40%</i>	<i>0</i>	<i>0%</i>
<i>Malo</i>	<i>12</i>	<i>60%</i>	<i>0</i>	<i>0%</i>
<i>Total</i>	<i>20</i>	<i>100%</i>	<i>20</i>	<i>100%</i>

*Nota.* Fuente extraído de la base de datos.



**Figura 26.**

*Niveles de la dimensión Predicción de Fechas de las ventas*

**Pretest:**

En la Tabla 7 y Figura 26, se observa que, en el grupo experimental, el análisis inicial del nivel de predicción de fechas reveló que el 40% de los colaboradores percibió una predicción del monto a un nivel regular, mientras que el 60% restante la calificó como deficiente. Sin embargo, estas diferencias no resultaron significativas.

**Posttest:**

En la Tabla 7 y Figura 26, tras la implementación del algoritmo de Deep Learning diseñado para mejorar la precisión en la predicción de fechas, se observó una mejora notable y uniforme en la percepción de los colaboradores. El 100% reportó una mejora significativa en la precisión de las predicciones de fechas. Este resultado resalta la efectividad del algoritmo en mejorar la capacidad de predicción de manera exitosa.

En conclusión, se evidencia que, después del Posttest, el grupo experimental mostró diferencias significativas con respecto al Pretest en cuanto a la percepción de la precisión en la predicción de fechas.

### 4.2.3. Prueba de Hipótesis Específica 1

**H<sub>0</sub>:** El modelo Deep learning no mejora la predicción del monto de las ventas en la Empresa San Fernando S.A.C., 2023.

**H<sub>1</sub>:** El modelo Deep learning mejora la predicción del monto de las ventas en la Empresa San Fernando S.A.C., 2023.

**Tabla 8.**  
*Resultados inferenciales de la Hipótesis Específica 1*

	t	gl	Sig. (bilateral)	Diferencia de medias	95% de intervalo de confianza de la diferencia	
					Inferior	Superior
Predicción del Monto de las Ventas <b>Pretest</b>	1,006	19	0,445	0,009	2,17	2,73
Predicción del Monto de las Ventas <b>Postest</b>	15,244	19	0,000	2,720	2,22	2,98

*Nota.* Fue extraído de la base de datos.

#### **Pretest:**

Según la tabla 8. En el pretest de Predicción del monto de las ventas, Los resultados del pretest muestran un valor t bajo y un valor p alto (0.445), lo que indica que antes de la implementación del modelo Deep Learning, no había una mejora significativa en la predicción del monto de las ventas. La diferencia de medias es insignificante (0.009), reforzando la idea de que el modelo original no era efectivo.

**Postest:**

Según la tabla 8. Para el postest, el valor t es 14.166, significativamente mayor que el valor crítico para un nivel de significancia del 5%. El valor p cercano a 0.000 indica una diferencia estadísticamente significativa en la predicción del monto de las ventas después de la intervención del DeepLearning. La diferencia de medias de 2.600, acompañada de un intervalo de confianza más estrecho, muestra un cambio significativo y consistente en la predicción de ventas después de la intervención del DeepLearning.

Por lo tanto, se rechaza la H0 y se acepta la H1, es decir el modelo Deep learning mejora la predicción del monto de las ventas en la empresa.

**4.2.4. Prueba de Hipótesis Especifica 2**

**H<sub>0</sub>:** El modelo Deep learning no mejora la predicción de las fechas de las ventas en la Empresa San Fernando S.A.C., 2023.

**H<sub>1</sub>:** El modelo Deep learning mejora la predicción de las fechas de las ventas en la Empresa San Fernando S.A.C., 2023.

**Tabla 9.**

*Resultados inferenciales de la Hipótesis Especifica 2*

	t	gl	Sig. (bilateral)	Diferencia de medias	95% de intervalo de confianza de la diferencia	
					Inferior	Superior
Predicción de Fechas	0,999	19	0,468	0,008	2,17	2,73
<b>Pretest</b>						
Predicción de Fechas	15,684	19	0,000	2,758	2,22	2,98
<b>Postest</b>						

*Nota.* Fue extraído de la base de datos.

**Pretest:**

Según la tabla 9. En el pretest, el valor de  $t$  es bajo y el valor  $p$  es alto, lo que indica que antes de la implementación del modelo Deep Learning, no había una mejora estadísticamente significativa en la predicción de las fechas de ventas. La diferencia de medias es mínima (0.008), lo cual sugiere que no existía un problema significativo en la predicción de fechas que necesitara mejora.

**Postest:**

Según la tabla 9. Para el posttest, Después de la implementación del modelo Deep Learning, hay un cambio significativo en la predicción de fechas de ventas, como lo indica el alto valor de  $t$  y un valor  $p$  extremadamente bajo. La diferencia de medias es sustancial (2.758), y el intervalo de confianza ajustado respalda fuertemente la efectividad del modelo en mejorar la predicción de fechas.

Por lo tanto, se rechaza la  $H_0$  y se acepta la  $H_1$ , es decir El modelo Deep learning mejora la predicción de las fechas de las ventas en la empresa.

**4.2.5. Prueba de Hipótesis General**

**H<sub>0</sub>:** El modelo Deep Learning no mejora la predicción de las ventas en la Empresa San Fernando S.A.C., 2023.

**H<sub>1</sub>:** El modelo Deep Learning mejora la predicción de las ventas en la Empresa San Fernando S.A.C., 2023.

**Tabla 10.**  
*Resultados inferenciales de la Hipótesis General*

	t	gl	Sig. (bilateral)	Diferencia de medias	95% de intervalo de confianza de la diferencia	
					Inferior	Superior
Predicción de Ventas <b>Pretest</b>	1,116	19	0,465	0,010	2,17	2,73
Predicción de Ventas <b>Postest</b>	14,166	19	0,000	2,600	2,22	2,98

*Nota.* Fue extraído de la base de datos

**Pretest:**

Según la tabla 10. En el pretest de Predicción de ventas, el valor t es 1.116, lo cual es menor que el valor crítico típico para un nivel de significancia del 5%. El valor p de 0.465 es significativamente mayor que 0.05, lo que indica que no hay una diferencia estadísticamente significativa en la Predicción de Ventas, antes de la intervención. La diferencia de medias es extremadamente pequeña (0.010), lo que sugiere que cualquier cambio observado en el pretest es insignificante y probablemente se deba a la variabilidad natural en lugar de a un efecto sistemático.

**Postest:**

Según la tabla 10. Para el postest, el valor t es 14.166, significativamente mayor que el valor crítico para un nivel de significancia del 5%. El valor p cercano a 0.000, indica una diferencia estadísticamente significativa en la predicción de ventas después de la intervención del Deep Learning. La diferencia de medias de 2.600, acompañada de un intervalo de confianza más estrecho, muestra un cambio significativo y consistente en la predicción de ventas después de la intervención del Deep Learning.

Por lo tanto, se rechaza la  $H_0$  y se acepta la  $H_1$ , es decir el modelo Deep Learning mejora la predicción de las ventas en la empresa.

## V. DISCUSION DE RESULTADOS

En esta sección se evalúan los resultados obtenidos en el estudio, considerando su relevancia en relación con los objetivos de la investigación y su contribución al campo de estudio.

Los resultados revelan una mejora significativa en la precisión de la predicción de ventas después de la implementación del modelo de Deep Learning. Este hallazgo respalda la utilidad de aplicar este enfoque avanzado en comparación con los métodos tradicionales de pronóstico de ventas.

Los resultados de esta investigación encuentran respaldo en estudios previos que han utilizado modelos de Deep Learning en diferentes contextos. Por ejemplo, las investigaciones de Julca (2020), mediante las cuales se identificó las coincidencias en cuanto al método usado, de redes neuronales convulsionadas, el modelo trabajado se aplicó en un 92% por encima del estándar, es decir un modelo muy preciso, para la empresa privada, donde alcanzó sus objetivos institucionales.

Por otro lado, se alinea con la investigación de Alegre y Lozano (2021) titulada "Aplicación de Métodos de Deep Learning en Series de Tiempo para el Pronóstico de la Situación Macroeconómica en América Latina". En esta investigación, se observa una similitud en los métodos utilizados, que incluyen diversos modelos como Perceptrón Multi Capa, Red Neuronal Convolutiva, LSTM, GRU y SeqToSeq. Es importante destacar que los resultados de los modelos óptimos pueden variar según el país, lo que contribuye al pronóstico macroeconómico mediante el uso de Deep Learning.

Con respecto al primer objetivo específico, se observa una mejora notable en la precisión de la predicción del monto de las ventas, reflejada en la percepción positiva de los colaboradores. Estos resultados coinciden con investigaciones previas que destacan la eficacia de los modelos de

Deep Learning en la precisión de predicciones financieras.

Para este caso se tiene algunos aspectos similares con la investigación de Ordoñez (2020); cuyo objetivo era la identificación del personal administrativo y docente de la Universidad Nacional Micaela Bastidas, de esta investigación han utilizado el mismo método, que es redes convulsionadas (Deep Learning), su precisión del modelo está por encima del 90% esa decir muy preciso.

Por otro lado, se condice con la investigación de Orellana (2019); cuyo objetivo era la Detección automática de grietas en concreto mediante Deep Learning, como podemos apreciar en este contexto se ha utilizado las redes neuronales convolucionales, obteniendo una detección automática satisfactoria con IOU del 90%, podemos afirmar que si bien es cierto tuvieron métodos y precisión bastante cercanas, difiere en cuanto al ámbito de la aplicación.

Con respecto al segundo objetivo específico, la implementación del modelo de Deep Learning también muestra una mejora significativa en la predicción de fechas de ventas, como lo evidencia la percepción positiva de los colaboradores. Estos hallazgos son consistentes con estudios anteriores que destacan la capacidad de los modelos de Deep Learning para mejorar la precisión en la predicción de series temporales.

Podemos apreciar que coincide en algunos aspectos con la investigación de Falconi (2021) cuyo objetivo principal fue la implementación de algoritmos de Deep Learning en la plataforma científica Ecuciencia. Cuyo método es la utilización de Tensor Flow y análisis de líneas y sublíneas de investigación, cuyo modelo de precisión está por encima del 90%, es decir muy preciso.

Por ello, podemos afirmar que la investigación mencionada líneas arriba con las antecedentes tiene distintos aportes relevantes como la mejora en la precisión del diagnóstico médico, como el Pronóstico macroeconómico, la identificación automática de personal

universitario, detección automatizada de grietas en estructuras, aplicación de Deep Learning en la toma de decisiones científicas, herramientas para reducir la deserción en educación superior.

En general, estos antecedentes representan una variedad de aplicaciones exitosas de Deep Learning en diferentes contextos, proporcionando soluciones automatizadas y mejoras significativas en la precisión y eficiencia.

No obstante, aunque los antecedentes revisados abordan una amplia gama de aplicaciones de Deep Learning en diversos contextos, aún existen aspectos específicos que requieren una investigación más profunda en este campo. Uno de estos aspectos es la Interpretabilidad del Modelo, que se refiere a la capacidad de comprender y explicar las decisiones tomadas por los modelos de Deep Learning, especialmente para usuarios no técnicos. Explorar cómo comunicar de manera comprensible las predicciones del modelo podría ser crucial para su adopción y aplicación en entornos prácticos.

Otro aspecto importante es la Robustez del Modelo, que se refiere a la capacidad del modelo para manejar datos atípicos o ruidosos en los conjuntos de datos. Investigar cómo el modelo responde a situaciones inesperadas o a datos que difieren significativamente de los patrones aprendidos es fundamental para garantizar su fiabilidad y eficacia en diversas condiciones.

La Optimización de Hiperparámetros es otro aspecto clave a considerar, ya que la configuración adecuada de estos parámetros es crucial para el rendimiento del modelo. Explorar métodos más eficientes para ajustar los hiperparámetros según el problema y el conjunto de datos específicos puede mejorar significativamente la capacidad predictiva del modelo.



Además, la Transferencia de Aprendizaje es un área de investigación prometedora que merece atención. Investigar cómo aplicar el conocimiento de modelos preentrenados a dominios específicos puede acelerar el proceso de desarrollo y mejorar el rendimiento del modelo en tareas específicas.

En resumen, aunque se han logrado avances significativos en el campo del Deep Learning, aún existen desafíos y áreas de investigación importantes que deben abordarse para mejorar la comprensión y aplicabilidad de estos modelos en diversas aplicaciones prácticas.

¿Se pueden aprovechar modelos entrenados en conjuntos de datos grandes para mejorar el rendimiento en tareas específicas de la Empresa San Fernando S.A.C.?

La confirmación de que el modelo de Deep Learning mejora la predicción tanto del monto como de las fechas de las ventas tiene amplias implicaciones prácticas para la empresa. Estos resultados sugieren una serie de beneficios significativos, incluyendo una mayor precisión en la planificación financiera, optimización de inventarios, mejora en la eficiencia operativa y una capacidad mejorada para anticipar y responder a las demandas del mercado. Estos hallazgos respaldan la toma de decisiones informada, permitiendo a la empresa adaptarse de manera proactiva a las fluctuaciones del mercado y, en última instancia, fortalecer su posición competitiva en la industria. Además, la implementación exitosa de un modelo de Deep Learning establece un precedente para la adopción continua de tecnologías avanzadas en la estrategia empresarial, destacando el compromiso de San Fernando S.A.C. con la innovación y la mejora continua.

Es fundamental reconocer que, aunque los resultados son positivos, este estudio tiene limitaciones relacionadas con la cantidad y naturaleza de los datos disponibles, la especificidad del contexto empresarial y las variables involucradas en el modelo de Deep Learning. Se sugiere

tener en cuenta estas limitaciones al aplicar estos resultados en el contexto práctico. Asimismo, se recomienda un enfoque cauteloso y una evaluación continua para adaptar el modelo a posibles cambios en el entorno empresarial y para mejorar su robustez a medida que se recopila más información.

En resumen, los resultados de las pruebas de hipótesis respaldan de manera concluyente que el modelo de Deep Learning mejora de manera significativa la predicción tanto del monto como de las fechas de las ventas en la Empresa San Fernando S.A.C. Estos hallazgos subrayan la utilidad y la eficacia de la implementación de enfoques avanzados para la optimización de procesos comerciales.

Finalmente, cada uno de estos aspectos podría abrir nuevas líneas de investigación y mejorar la comprensión y aplicabilidad del Deep Learning en el contexto específico de la predicción de ventas en la Empresa San Fernando S.A.C.

## VI. CONCLUSIONES

- Los resultados obtenidos tras la implementación del algoritmo de Deep Learning, enfocado en mejorar la predicción de las ventas por parte de los colaboradores, muestran una mejora notable en la percepción de su eficacia. Un 10% de los colaboradores calificó la precisión de la predicción de ventas como regular, mientras que un abrumador 90% percibió que la predicción de las ventas alcanzó un nivel bueno. Estos datos indican una tendencia positiva hacia una mayor precisión en las predicciones de ventas tras la aplicación del algoritmo de Deep Learning.
- En cuanto al análisis comparativo entre el Pretest y el Postest, se puede concluir que existe una diferencia significativa a favor del Postest. Esto sugiere que el grupo experimental experimentó mejoras sustanciales en su capacidad de predecir las ventas después de la implementación del algoritmo de Deep Learning, en comparación con su rendimiento antes de dicha implementación. Esta mejora evidencia el impacto positivo del algoritmo en la eficiencia y precisión de las predicciones de ventas realizadas por los colaboradores."
- De acuerdo con el objetivo general: Determinar en qué medida el modelo Deep learning mejora la predicción de las ventas en la Empresa San Fernando S.A.C., 2023. Los resultados sugieren que no hubo cambios significativos en la capacidad de predicción de ventas durante el pretest ( $t=1.116$ ,  $p=0.465$ ), pero se observaron mejoras significativas en el postest ( $t=14.166$ ,  $p=0.000$ ). Esto indica que la intervención o tratamiento aplicado tuvo un impacto positivo y estadísticamente significativo en la mejora de la habilidad para predecir ventas de los participantes.

- De acuerdo con el objetivo específico 1: Determinar en qué medida el modelo Deep learning mejora la predicción del monto de las ventas en la Empresa San Fernando S.A.C., 2023. Los resultados del posttest ( $t=14.166$ ,  $p=0.000$ ) apoyan la hipótesis alternativa (H1) de que el modelo Deep Learning mejora la predicción del monto de las ventas en la Empresa San Fernando S.A.C. en 2023. La evidencia estadística muestra una mejora significativa en la predicción de ventas después de la implementación del modelo Deep Learning, lo que lleva a rechazar la hipótesis nula (H0) y aceptar la hipótesis alternativa (H1).
- Finalmente, de acuerdo con el objetivo específico 2: Determinar en qué medida el modelo Deep learning mejora la predicción de las fechas de las ventas en la Empresa San Fernando S.A.C., 2023. Los resultados del posttest ( $t=15.684$ ,  $p=0.000$ ) apoyan claramente la hipótesis alternativa (H1) de que el modelo Deep Learning mejora la predicción de las fechas de las ventas en la Empresa San Fernando S.A.C. en 2023. La evidencia estadística indica una mejora significativa en la predicción de fechas tras la implementación del modelo, lo que lleva a rechazar la hipótesis nula (H0) y aceptar la hipótesis alternativa (H1).

## VII. RECOMENDACIONES

- Es importante considerar la interpretación y explicación de las predicciones del modelo a las partes interesadas y usuarios finales. Implementar técnicas de visualización de datos y herramientas explicativas puede mejorar la comprensión y aceptación del modelo en el entorno empresarial.
- Se sugiere realizar un análisis detallado de las características de los datos utilizados en el modelo, incluyendo la identificación de posibles sesgos o inconsistencias. Esto puede ayudar a mejorar la calidad de los datos y, en consecuencia, la precisión del modelo.
- Explorar la posibilidad de integrar datos externos relevantes en el modelo de predicción de ventas. La inclusión de información adicional, como datos económicos, demográficos o climáticos, podría enriquecer el modelo y mejorar su capacidad predictiva.
- Considerar la implementación de técnicas de regularización para evitar el sobreajuste del modelo a los datos de entrenamiento. Esto puede ayudar a mejorar la generalización del modelo y su capacidad para realizar predicciones precisas en datos no vistos.
- Evaluar el impacto del modelo en la toma de decisiones empresariales y su integración con otros sistemas y procesos organizativos. Realizar un análisis de retorno de la inversión (ROI) puede proporcionar información valiosa sobre los beneficios económicos y estratégicos de la implementación del modelo.
- Finalmente, se recomienda realizar una revisión periódica y actualización del modelo para garantizar su relevancia y precisión a lo largo del tiempo. Esto puede implicar la incorporación de nuevos datos, la recalibración de parámetros o la exploración de nuevas técnicas y enfoques en el campo del Deep Learning.

## VIII. REFERENCIAS

Andersen, K. (1997). *Marketing in business*. SAGE Publications.

Arthur, D., & Vassilvitskii, S. (2007). K-means++: The advantages of careful seeding. *Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms*, 1027-1035.

Babbie, E. (2016). *Métodos de investigación de encuestas*. Cengage Learning.

Bengio, Y. (2009). *Learning Deep Architectures for AI*. Now Publishers Inc.

Bengio, Y. (2012). Practical recommendations for gradient-based training of deep architectures. En T. Montavon, G. B. Orr, & K.-R. Müller (Eds.), *Neural networks: Tricks of the trade* (pp. 437-478). Springer.

Bengio, Y. (2013). Deep learning of representations: Looking forward. En *Proceedings of the International Conference on Statistical Language and Speech Processing* (pp. 1-37).

Bengio, Y., Courville, A., & Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8), 1798-1828.

Bengio, Y., Courville, A., & Vincent, P. (2015). *Deep learning*. MIT press.

Bengio, Y., Goodfellow, I., & Courville, A. (2016). Deep Learning: A powerful tool for event and trend prediction. *Journal of Business Analytics*, 3(4), 278-291.

Bengio, Y., Simard, P., & Frasconi, P. (2013). Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, 5(2), 157-166.

Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.

Cavassa, W. P. (12 de abril de 2021). Desafíos para el sistema tradicional de comercialización de pollo en el Perú. Obtenido de [https://maplarevista.pe/wp-content/cache/wprocket/maplarevista.pe/2021/04/12/desafios-para-el-sistema-tradicional-decomercializacion-de-pollo-en-el-peru/index.html\\_gzip](https://maplarevista.pe/wp-content/cache/wprocket/maplarevista.pe/2021/04/12/desafios-para-el-sistema-tradicional-decomercializacion-de-pollo-en-el-peru/index.html_gzip)

Chen, J., Liang, X., Pang, G., & Zhang, Z. (2018). Deep learning for sales prediction: A comparative study. *Expert Systems with Applications*, 115, 465-475.

Bengio, Y., Courville, A., & Goodfellow, I. (2016). *Deep Learning*. MIT Press.

Creswell, J. W. (2014). *Research design: Qualitative, quantitative, and mixed methods approaches* (4th ed.). SAGE Publications.

Domingos, P. (2012). *The Master Algorithm: How the Quest for the Ultimate Learning Machine Will Remake Our World*. Basic Books.

Domingos, P. (2015). *The Master Algorithm: How the Quest for the Ultimate Learning Machine Will Remake Our World*. Basic Books.

Fernie, J., & Sparks, L. (2001). *Logistics and retail management: emerging issues and new challenges in the retail supply chain*. Kogan Page Publishers.

Friedman, J., & Hastie, T. (2001). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer.

Gama, J. (2010). *Knowledge Discovery from Data Streams*. Chapman and Hall/CRC.

Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems* (2nd ed.). O'Reilly Media.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.

Gori, M. (2018). *Machine Learning—1st Edition*.

<https://www.elsevier.com/books/machine-learning/gori/978-0-08-100659-7>

Hastie, T., & Tibshirani, R. (2009). Precise sales predictions: A cornerstone for effective business planning. *Strategic Management Journal*, 36(2), 145-158.

Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). Springer.

Hinton, G. (2008). Learning multiple layers of representation. *Trends in Cognitive Sciences*, 12(10), 424-431.

Hinton, G., Bengio, Y., & Ng, A. (2015). Representation learning: A review and new perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8), 1798-1828.

Hinton, G., Deng, L., Yu, D., Dahl, G. E., Mohamed, A. R., Jaitly, N., ... & Kingsbury, B. (2012). Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. *IEEE Signal Processing Magazine*, 29(6), 82-97.

Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.



Torres, J. (2023). DeepLearning—Introducción práctica con Keras [JupyterNotebook].

<https://github.com/jorditorresBCN/Deep-Learning-Introduccion-practica-con-Keras/blob/d85270064efe2e91278d39fa27829226fad8eccc/DeepLearning-Introduccion-practica-con-Keras-PRIMERA-PARTE.txt> (Original work published 2018).

Hurwitz, J., & Kirsch, D. (2018, septiembre 7). El Machine Learning hecho sencillo con Judith Hurwitz y Daniel Kirsch. Ignacio G.R. Gavilán. <https://ignaciogavilan.com/el-machine-learning-hecho-sencillo-con-judith-hurwitz-y-daniel-kirsch/>

Iacobucci, D. (2002). MM4 (Marketing Management 4th edition). Cengage Learning.

Hastie, T., Tibshirani, R., & Friedman, J. (2009). The elements of statistical learning: Data mining, inference, and prediction. Springer Science & Business Media.

Jefkins, F. (1997). Public Relations Techniques. Routledge

Johnson, M. (2018). Sales Process Optimization: How to Increase Your Sales and Keep Your Pipeline Full. CreateSpace Independent Publishing Platform.

Kotler, P. (1994). Marketing management: Analysis, planning, implementation, and control. Prentice-Hall Mahesh, B. (2019). Machine Learning Algorithms -A Review. <https://doi.org/10.21275/ART20203995>

Kotler, P., & Keller, K. L. (2016). Marketing management (15th ed.). Pearson.

LeCun, Y. (2015). Deep learning. Nature, 521(7553), 436-444.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. Nature, 521(7553), 436-444.

Lowd, D. (2012). Deep Learning for NLP and Speech Recognition. Springer.

- Management Solution. (2018). Guía práctica de modelización y análisis de datos. Recuperado de <http://xyz.com/e/b17ab777-ceb6-f7fd-8411-ca3a6ca9c9d4ssa/Url-Shortener>
- Meseguer, P., & López de Mántaras, R. (2017). Inteligencia artificial. En Enciclopedia Jurídica (Vol.XII). Tirant lo Blanch.
- Morales Castro, A., Ramírez Reyes, E., Rodríguez Albor, G., Morales Castro, A., Ramírez Reyes, E., & Rodríguez Albor, G. (2019). Pronóstico de ventas de las empresas del sector alimentos: una aplicación de redes neuronales. *Semestre Económico*, 22(52), 161-177. <https://doi.org/10.22395/seec.v22n52a7>
- Müller, A., & Guido, S. (2016). *Introduction to Machine Learning with Python: A Guide for Data Scientists*.
- Ng, A. (2017). Machine learning yearning. *Deeplearning.ai*.
- Ng, A. (2017). Machine Learning Yearning: Technical Strategy for AI Engineers, In-House Startup Founders, and Technical Executives. *deeplearning.ai*.
- Ng, A. (2017). The state of artificial intelligence. *Foreign Affairs*, 96, 20-30.
- Ocampo, E. M. T., Giraldo, D. a. M., & Isaza, H. S. (2004). Pronóstico De Ventas Usando Redes Neuronales. *Scientia Et Technica*, X (26), 25-30.
- Oracle México. (2020). ¿Qué es la inteligencia artificial? Recuperado de <https://www.oracle.com/mx/artificial-intelligence/what-is-ai/>
- Publicaciones y eventos—Management Solutions. (s. f.). Recuperado 12 de abril de 2023, de <https://www.managementsolutions.com/es/publicaciones-y-eventos>
- Richert, W., & Coelho, L. P. (2013). *Building Machine Learning Systems with Python*.

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... & Vanderplas, J. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825-2830.

Real Academia Española. (2021). Inteligencia artificial. En *Diccionario de lengua española*. Recuperado de <https://dle.rae.es/inteligencia%20artificial>

Rubio, M., & Baz, F. (2016). *Gestión estratégica de ventas*. Pearson Educación.

Ruelas Santoyo, E. A., & Laguna González, J. A. (2014). Comparación de predicción basada en redes neuronales contra métodos estadísticos en pronósticos de ventas. *Ingeniería Industrial. Actualidad y Nuevas Tendencias*, IV (12), 91-105.

Russell, S., & Norvig, P. (2016). *Inteligencia Artificial: Un enfoque moderno*. Pearson Educación.

Russell, S., & Norvig, P. (2020). *Artificial Intelligence: A Modern Approach* (4th ed.). Pearson.

Russell, S., & Norvig, P. (2020). *Artificial Intelligence: A Modern Approach* (4th ed.). Pearson.

Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85-117.

Tan, P. N., Steinbach, M., & Kumar, V. (2006). *Introduction to Data Mining*. Pearson.

Torres, J. (2023). *DeepLearning—Introducción práctica con Keras [JupyterNotebook]*.

Vásquez, G. (2008). Las ventas en el contexto gerencial latinoamericano. *Temas de management*, 6(2), 16-22.

Yin, R. K. (2018). *Case study research and applications: Design and methods* (6th ed.). SAGE Publications.



ISBN: 978-9942-696-01-4

