



**UNIVERSIDAD TÉCNICA DE MACHALA
UNIDAD ACADÉMICA DE INGENIERÍA CIVIL**

**PROPUESTA METODOLÓGICA Y TECNOLÓGICA AVANZADA
EN OPCIÓN AL TÍTULO DE MAGÍSTER EN SOFTWARE**

TEMA

**MODELO PREDICTIVO DE LAS VENTAS DE PRODUCTOS DE PRIMERA
NECESIDAD EN EL SECTOR COMERCIAL BASADO EN TÉCNICAS DE
MACHINE LEARNING**

AUTOR

ING. CHARLES JESÚS CALI NÁJERA

TUTOR

ING. WILMER RIVAS

COTUTOR

ING MAYIYA GONZALEZ

MACHALA

2022

PENSAMIENTO

“Una línea de código a la vez”

Charles Cali, autor

DEDICATORIA

El presente trabajo lo dedico infinitamente a mi familia quienes son el pilar fundamental de mi vida, mis seres queridos que ya no están presentes, pero me acompañan en todo momento en mis pensamientos, especialmente a mi madre, esposa e hijos quienes son el motivo principal por el que me esfuerzo todos los días por ser mejor que ayer los amo.

AGRADECIMIENTO

Agradezco primeramente a Dios por todo lo que nos brinda, esa escasez de las cosas y esa abundancia de amor, gracias por darme la fortaleza de poder dar ese paso más, cuando estoy por rendirme y permitirme lograr los objetivos planteados.

Gracias a toda mi familia que están en los momentos buenos y malos porque familia es familia y cariño es cariño.

Gracias infinitas a mi tutor quien me ha sabido motivar y orientar desde el primer día en este proceso, de la misma forma a los maestros y coordinadora de la maestría por sus conocimientos brindados en todo momento.

Gracias Carla, Roberto y Rosa los amo.

RESPONSABILIDAD DE AUTORÍA

Por medio de la presente declaro ante el comité académico de la Maestría en Software de la Universidad Técnica de Machala. Que el trabajo de titulación titulado “**MODELO PREDICTIVO DE LAS VENTAS DE PRODUCTOS DE PRIMERA NECESIDAD EN EL SECTOR COMERCIAL BASADO EN TÉCNICAS DE MACHINE LEARNING**”, de mi propia autoría, no contiene material escrito por otra persona al no ser referenciado debidamente en el texto, parte de ella o en su totalidad no ha sido aceptada para el otorgamiento de cualquier otro diploma de una institución nacional o extranjera.

Ing. Charles Jesús Cali Nájera

C.I. 0920840063

Machala, 2022/08/01

tesis

INFORME DE ORIGINALIDAD

4%	3%	1%	1%
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	mcc.ubiobio.cl Fuente de Internet	1%
2	Submitted to University of Warwick Trabajo del estudiante	<1%
3	www.hoy.com.ec Fuente de Internet	<1%
4	Submitted to University College London Trabajo del estudiante	<1%
5	repositorio.utc.edu.ec Fuente de Internet	<1%
6	repositorio.unsa.edu.pe Fuente de Internet	<1%
7	repositorio.autonoma.edu.co Fuente de Internet	<1%
8	Kıymet Kaya, Şule Gündüz Öğüdücü. "Deep Flexible Sequential (DFS) Model for Air Pollution Forecasting", Scientific Reports, 2020 Publicación	<1%

CERTIFICADO DEL TUTOR

Por medio de la presente apruebo que el trabajo de titulación, titulado “**MODELO PREDICTIVO DE LAS VENTAS DE PRODUCTOS DE PRIMERA NECESIDAD EN EL SECTOR COMERCIAL BASADO EN TÉCNICAS DE MACHINE LEARNING**”, del autor Charles Jesús Cali Nájera, en opción al título de Máster en Software, sea presentado al Acto de Defensa

Ing. **WILMER RIVAS**, Mgs
C.I. 0702580192

Machala, 2022/08/01

CESIÓN DE DERECHOS DE AUTORÍA

Yo, Charles Jesús Cali Nájera, en calidad de autor del presente trabajo titulado **“MODELO PREDICTIVO DE LAS VENTAS DE PRODUCTOS DE PRIMERA NECESIDAD EN EL SECTOR COMERCIAL BASADO EN TÉCNICAS DE MACHINE LEARNING”**, Autorizo a la UNIVERSIDAD TÉCNICA DE MACHALA la publicación y distribución en el Repositorio Digital Institucional de la Universidad Técnica de Machala.

El autor declara que el contenido que se publicará es de carácter académico y se enmarca en las disposiciones definidas por la Universidad Técnica de Machala.

Ing. Charles Jesús Cali Nájera
C.I. 0920840063

Machala, 2022/08/01

RESUMEN

El presente trabajo propone desarrollar un modelo predictivo de las ventas de productos de primera necesidad en el sector comercial basado en técnicas de machine learning, utilizando modelos de redes neuronales convolucionales (CNN). Se recolectó información de las operaciones de las ventas correspondiente a los años 2018 hasta el año 2021. El enfoque utilizado es cuanti cualitativo (mixto) con un diseño experimental. La metodología que se adaptó al estudio fue Cross - Industry Standard Process for Data Mining o CRISP – DM, que es una metodología orientada a minería de datos, que permite revisar de forma jerárquica los niveles de tareas, desde lo más general a lo más específico, en fases que van desde conocer el negocio hasta el despliegue de los resultados obtenidos. Utilizando Python con sus librerías Keras y Tensorflow, se planteó 3 modelos de CNN, cambiando los hiper parámetros (filtros en relación a la cantidad de capas, el tamaño del kernel y el número de épocas), permitió generar 256 pruebas experimentales. El modelo “A” presentó el mejor rendimiento de los resultados en las métricas MSE de 0.000300 y MAE de 0.008900 con los parámetros de 64 filtros, 5 kernels y 1.000 épocas.

Palabras claves: Modelo predictivo, machine learning, redes neuronales convolucionales, metodología CRISP-DM.

ABSTRACT

The present work proposes to develop a predictive model of the sales of essential products in the commercial sector based on machine learning techniques, using convolutional neural network (CNN) models, with which predictive analysis can be achieved. Information on sales operations corresponding to the years 2018 to 2021 was collected. The approach used is quantitative-qualitative (mixed) with an experimental design. The methodology that was adapted to the study was Cross - Industry Standard Process for Data Mining or CRISP - DM, which is a methodology oriented to data mining, which allows the levels of tasks to be reviewed hierarchically, from the most general to the most specific, in phases that go from knowing the business to the deployment of the results obtained. These results evoked in 256 combinations. To measure the best predictive performance, it was considered to evaluate 3 models according to the filters in relation to the number of layers, as well as the size of the kernel, of which model A presented the best performance of the results in the MSE metrics of 0.000300 and MAE of 0.008900 with the parameters of 64 filters, 5 kernels and 1,000 epochs.

Keywords Predictive model, machine learning, convolutional neural networks, CRISP-DM methodology

Contenido

RESUMEN.....	ix
ABSTRACT.....	x
Introducción	17
Capítulo 1	24
Marco teórico	24
1.1. Antecedentes Históricos.....	24
1.2. Proceso de búsqueda	24
1.2.1. Grupo de control.....	24
1.2.2. Cadena de búsqueda.....	25
1.3. Bases conceptuales.....	26
1.3.1. Aprendizaje automático (Machine Learning).....	26
1.3.2. Modelos predictivos	27
1.3.3. Redes neuronales.....	29
1.3.4. Redes neuronales convolucionales.....	30
Capítulo 2	36
Materiales y métodos	36
2.1. Tipo de estudio	37
2.1.1. Estudio de campo	37
2.1.2. Estudio descriptivo	38
2.2. Alcance de estudio	39
2.2.1. Alcance explicativo	39
2.3. Enfoque	39
2.3.1. Enfoque cualitativo	39
2.3.2. Enfoque cuantitativo	39
2.3.3. Enfoque mixto	40
2.4. Diseño	40
2.4.1. Diseño experimental.....	41
2.5. Cálculo de población y muestra	42
2.6. Operacionalización de variables.....	42
Capítulo 3	60
Propuesta de modelo predictivo de las ventas de productos de primera necesidad en el sector comercial basado en técnicas de machine learning.....	Error! Bookmark not defined.
3.1. Selección de metodología.....	43
3.1.1. Metodología CRISP-DM.....	44

a.	Comprensión del giro del negocio o problemática a solucionar	45
b.	Comprensión de los datos	48
c.	Preparación de los datos:.....	51
d.	Modelado :.....	53
e.	Generación del modelo	53
3.1.1.1.	Modelo A.....	54
3.1.1.2.	Modelo B.....	54
3.1.1.3.	Modelo C.....	54
g.	Despliegue	57
3.2.	Modelo propuesto.....	58
Capítulo 4	60
Presentación y discusión de resultados obtenidos	60
4.1.	Estadística descriptiva de los datos	62
4.2.	Diseño experimental.....	66
4.2.1.	Experimentación de los modelos de CNN	66
Filtros	67
Tamaño del kernel	67
Pruebas de pronóstico	68
CONCLUSIONES	71
Recomendación	72
Bibliografía	Error! Bookmark not defined.

Índice de Figura

Figura 1 Producto Interno Bruto -PIB	17
Figura 2 Tasa de desempleo nacional y rural	18
Figura 3: Incidencia mensual por división de consumo	19
Figura 4 Cadena de búsqueda.....	25
Figura 5 Formulación del problema	26
Figura 6 Red neuronal artificial.....	30
Figura 7 Pronóstico de ventas utilizando la red neuronal convolucional.....	32
Figura 8 Red neuronal combinado los modelos CNN & LSTM	33
Figura 9 Resultados de modelos convolucionales.....	34
Figura 10 Metodología de investigación aplicada al estudio	37
Figura 11 Tipo de investigación.....	38
Figura 12 Enfoque mixto.....	40
Figura 13 Características de investigación experimental	41
Figura 14 Operacionalización de variable.....	42
Figura 15 Principales métodos en los proyectos de datos	43
Figura 16 Principales métodos en los proyectos de minería de datos	44
Figura 17 Metodología CRISP-DM	45
Figura 18 Fase de comprensión del negocio	46
Figura 19 Variables comerciales	47
Figura 20 Big data	47
Figura 21 Plan de trabajo.....	48
Figura 22 Fases de la comprensión de datos	49
Figura 23 Canalización de datos.....	50
Figura 24 Fases de preparación de datos.....	51
Figura 25 Fases de modelado de datos	53
Figura 26 Modelo A	54
Figura 27 Modelo B	54
Figura 28 Modelo C	55
Figura 29 Arquitectura CNN.....	55
Figura 30 Fases de evaluación de datos	56
Figura 31 Fases de despliegue de datos.....	57
Figura 32 Modelo propuesto	58
Figura 33 Ventas mensuales en el periodo de 2018 a 2021	61
Figura 34 Ventas mensuales en el periodo de 2018 a 2021	61
Figura 35 Ventas diarias en el periodo de 2018 a 2021	61
Figura 36 Ventas por años periodo de 2018 a 2021	62
Figura 37 Promedios por cada mes del 2018 al 2021.....	63
Figura 38 Periodo del 2018 al 2021	63
Figura 39 Imagen de barras de las ventas periodo 2018 2021	64
Figura 40 Ventas top 10 en periodo 2018 - 2021	65
Figura 41 grupo de artículos.....	65
Figura 42 Resultados de pruebas.....	67
Figura 43 Mejores resultados	68

Figura 44 Pruebas del primer pronóstico.....	68
Figura 45 Pruebas del segundo pronóstico.....	69
Figura 46 Pruebas del tercer pronóstico.....	69
Figura 47 Comparativa del primer y tercer resultado.....	70
Figura 48 Predicción de ventas a 60 días.....	70
Figura 49 Predicción de ventas a 60 días maximizadas.....	70

Índice de Anexo.

Anexo 1 Resultados de los experimentos científicos	73
---	----

Introducción

La dinámica de los mercados incentiva a las empresas a diseñar y aplicar estrategias de crecimiento y diferenciación, que contribuyan al logro de ventajas competitivas. En este sentido se exploran alternativas y prácticas organizacionales para alcanzar la eficiencia tecnológica y económica que aumente las posibilidades de obtener rentabilidad, como la reducción de costos y uso de recursos. No obstante, de las preocupaciones cotidianas de los empresarios, la pandemia provocada por el virus COVID-19 ha transformado el escenario económico mundial. En este contexto todos los países a nivel mundial se vieron afectados de manera significativa en el desempeño económico [1] impactando establecimientos productivos y comerciales.

Esto fue un factor fundamental e incidió para que, en el año de la pandemia, es decir 2020, el Producto Interno Bruto (PIB) del Ecuador, haya alcanzado USD 66.308 millones, que significa una dura caída de 7,8% [1] en comparación a los últimos 4 años, ver figura 1

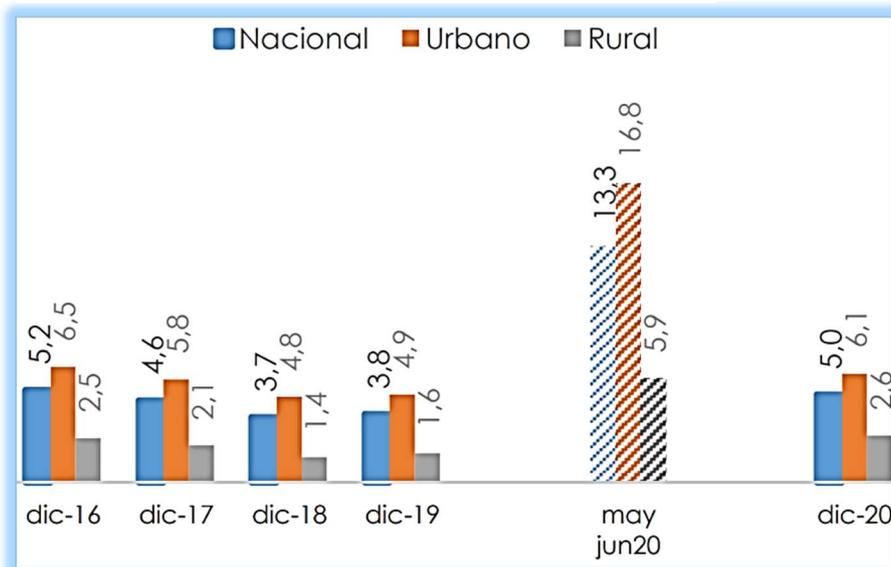
Figura 1 Producto Interno Bruto -PIB



Fuente: Banco Central del Ecuador (2020).

Otro indicador representativo en la economía nacional es el desempleo, el mismo que cuadruplicó las cifras de los últimos 4 años durante los meses de confinamiento [2] y que, para el mes de diciembre del año 2020, tuvo un incremento en relación a los cierres de año desde el periodo 2016 a nivel nacional, dicho incremento se expone en la figura 2. Los escenarios presentados, así como otros indicadores, revelan una disminución del consumo final en los hogares ecuatorianos [2]. La misma que se expone en la figura 3

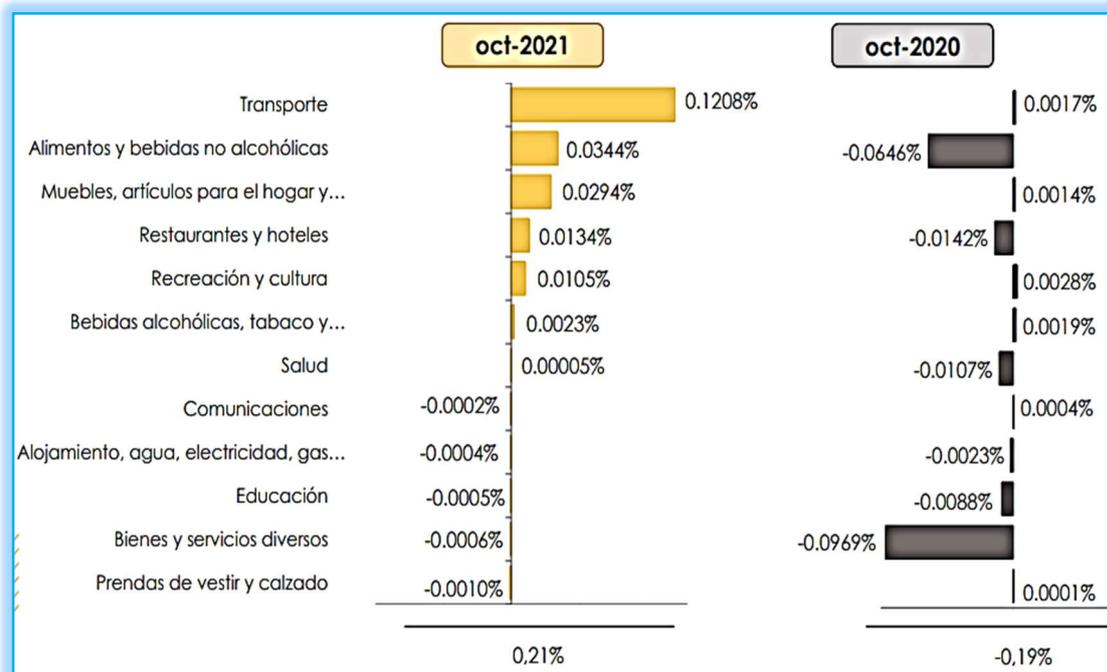
Figura 2 Tasa de desempleo nacional y rural



Fuente: Instituto Nacional de Estadística y Censo - INEC (2021)

No obstante, a pesar de los valores porcentuales decrecientes en cuanto a compras en productos de primera necesidad de parte del usuario final, hubo un repunte en un segmento específico de ventas, este es, el canal moderno (supermercados), ver figura 3, en el cual se evidenciaron incrementos en ventas, de \$45 dólares como promedio antes del confinamiento, este se aumentó a \$105 dólares durante los meses de marzo y abril [2] del año 2020. Por lo que, el modelo predictivo de ventas de productos de primera necesidad, se justifica por medio de la implementación del aprendizaje automático.

Figura 3: Incidencia mensual por división de consumo



Fuente: Instituto Nacional de Estadística y Censo - INEC (2021)

Todo este entorno hace que las empresas incorporen alternativas que ayuden a mantener sus beneficios. En la búsqueda de estas alternativas se plantea el pronóstico de ventas. Para ello, la literatura presenta muchas técnicas utilizadas, algunos investigadores plantean la solución al modelamiento del pronóstico de ventas utilizando series temporales desde los modelos estadísticos tradicionales como promedio móvil integrado autorregresivo (ARIMA), suavizado exponencial (STLF) y el kernel PLS [3].

De igual forma, el kernel regresión de componentes principales (kernel PCR), algoritmo de correlación de componentes independientes del kernel (kernel ICA) [4], red neuronal artificial (ANN) [5], máquina de vectores de soporte (SVM) [6] y muchos otros métodos de aprendizaje superficial desarrollados para resolver los problemas relacionados con diversos grados de éxito en la predicción de tendencias en diferentes y diversos dominios.

No obstante, la precisión del uso de métodos estadísticos y de aprendizaje superficial para predecir aún debe mejorarse. En los últimos años, el aprendizaje profundo o Deep learning se ha desarrollado rápidamente y ha mostrado un mejor rendimiento que los

métodos estadísticos y los métodos de aprendizaje superficial en muchos campos [7]. El aprendizaje profundo además de mejorar la precisión, también ahorra mucho tiempo, requiere menos parámetros y menos tiempo de entrenamiento.

El aprendizaje profundo es un elemento importante de la ciencia de datos, que incluye estadísticas y modelos predictivos [8]. Es extremadamente beneficioso para los científicos de datos que tienen la tarea de recopilar, analizar e interpretar grandes cantidades de datos; el aprendizaje profundo hace que este proceso sea más rápido y sencillo [9].

En su forma más simple, el aprendizaje profundo se puede considerar como una forma de automatizar el análisis predictivo. Si bien los algoritmos de aprendizaje automático tradicionales son lineales, los algoritmos de aprendizaje profundo se apilan en una jerarquía de complejidad y abstracción cada vez mayores.

Las primeras explicaciones teóricas sobre el cerebro y el pensamiento ya fueron dadas ya por Platón (427-347 a.C.) y Aristóteles (348-422 a.C.) [9]. Las mismas ideas también las mantuvieron Descartes (1569-1650) y los filósofos empiristas del siglo XVIII. La clase de las llamadas máquinas cibernéticas, a la cual la computación neuronal pertenece, tiene más historia de la que se cree: Herón (100 a.C) construyó un autómatas hidráulico [10].

Alan Turing. Fue el primero en estudiar el cerebro como una forma de ver el mundo de la computación. Sin embargo, los primeros teóricos que concibieron los fundamentos de la computación neuronal fueron Warren McCulloch, un neurofisiólogo, y Walter Pitts, un matemático, quienes, en 1943, lanzaron una teoría acerca de la forma de trabajar de las neuronas (Un Cálculo Lógico de la Inminente Idea de la Actividad Nerviosa - Boletín de Matemática Biofísica 5: 115-133). Ellos modelaron una red neuronal simple mediante circuitos eléctricos [2].

Las Redes neuronales convolucionales es un concepto creado en los años 1980 con mejoras para su implementación en el año 2012; todavía está en progreso. Si bien es cierto que el número de investigaciones aumenta cada vez más para diversos contextos, todavía no hay un modelo definido que proporcione una solución definitiva para ayudar a aplicar los parámetros adecuados para la diversidad de problemas. A este respecto se destacan los siguientes estudios:

- El estudio realizado por Chen [5] afirma que las poderosas capacidades de extracción de características y las capacidades de procesamiento de big data de CNN hacen posible la predicción de la calidad de forma más rápida y precisa, y de superar las deficiencias de los métodos de predicción tradicionales, utiliza el modelo de Tennessee Eastman (TE) como base para construir un algoritmo de CNN.

Este modelo optimizará la estructura y los parámetros CNN adecuados para el conjunto de datos, obteniendo los siguientes resultados: (a) CNN puede generar el valor predicho en poco tiempo y, de acuerdo con el error cuadrático medio (RMSE) de la salida de la red, la predicción de CNN es más precisa. (b) CNN usa menos parámetros y puede ayudar a las personas a ahorrar costos operativos de computadoras; (c) CNN puede capturar las características internas de los datos, lo que ahorra tiempo a las personas para extraer la correlación de variables.

- De igual forma Massiris [6] en su estudio llamado Detección de equipos de protección personal mediante red neuronal convolucional YOLO, afirma que el uso de una red neuronal permite efectivizar los resultados, es decir, detectar objetos con mayor precisión, donde las métricas que se utilizaron se relacionan al objetivo establecido en dicho estudio, cuyos resultados se enfocaron de acuerdo a métricas de calidad determinadas. En este trabajo se detectó la reducción de la velocidad del pronóstico, sin embargo, aumentó la tasa de acierto.

Los estudios revisados anteriormente demuestran avances importantes en la precisión de los pronósticos, no obstante, estos estudios no incorporan: las diferentes estructuras de redes neuronales convolucionales, así como tampoco incorporan el utilizar diferentes parámetros tanto en la fase de la construcción de la red neuronal convolucional como en la fase de entrenamiento.

Por todas estas razones este trabajo propone diseñar un modelo para predecir las ventas mediante la construcción de una Red Neuronal Convolucional, la cual fue diseñada con la técnica de machine learning, construyendo modelos predictivos basados en CNN, siendo objeto de validez en 256 pruebas. La metodología que respaldó la solidez y consistencia de los procesos fue CRISP-DM, que es una técnica fundamental adaptada al mundo empresarial, la misma que se desarrolla bajo métodos eficientes [39].

Exponiendo la problemática, surgen las siguientes preguntas:

Pregunta general:

¿Cómo predecir las ventas de productos de primera necesidad?

Preguntas específicas:

- ¿Cómo se mide la eficiencia de los resultados en la técnica predictiva de redes neuronales?
- ¿Qué metodología se utilizará para aplicar modelos predictivos de ventas?
- ¿Cómo está conformada la data que servirá como base fundamental en la recopilación de datos históricos?

Objetivo general

Desarrollar un modelo predictivo en las ventas de productos de primera necesidad mediante la construcción de las redes neuronales convolucionales, que permita la optimización del inventario en el sector comercial.

Objetivos específicos:

- Investigar la técnica predictiva de redes neuronales convolucionales mediante la guía metodológica de revisión sistemática de literatura.
- Recolectar datos del histórico de ventas para identificar los indicadores claves y definir el grupo de datos que servirán para entrenamiento y testeo de la Red Neuronal Convolucional
- Desarrollar el modelo de entrenamiento de la Red Neuronal Convolucional para la predicción de ventas.

Hipótesis

Se plantea la siguiente suposición a validar, si se desarrolla un modelo predictivo de ventas de productos de primera necesidad basados en CNN se obtendrán resultados más

precisos a través de las métricas el error cuadrático medio (MSE) y error absoluto medio (MAE).

Por otro lado, la metodología utilizada en el estudio, cuyo enfoque es mixto, debido a su naturaleza numérica en recopilar datos y cálculos algorítmicos [8]. De igual forma, el diseño de la investigación o método a utilizar en el proyecto realizado es experimental, donde las variables son monitoreadas y manipuladas [9] de acuerdo a las métricas establecidas. Finalmente, la tipología es de tipo descriptivo donde las variables que se presentan son las siguientes:

Variable independiente: Ventas futuras

Variable dependiente: Histórico de ventas

Por último, se presenta la estructura de la propuesta metodológica, la misma que se compone de la siguiente forma: La parte introductoria donde se describe la importancia del tema, la actualidad del estudio realizado, la formulación del problema, la delimitación del objeto de estudio, el objetivo general y la hipótesis planteada.

Mientras que el capítulo 1 está integrado por antecedentes históricos, conceptuales y contextuales. En el capítulo 2 se describe la metodología a implementar en el estudio, el tipo de investigación, la población y muestra seleccionada y que técnica se utilizó para obtener los instrumentos de información. En el capítulo 3 se desarrollan los principales resultados. El capítulo 4 se discuten dichos resultados

Capítulo 1

Marco teórico

1.1. Antecedentes Históricos

Las bases teóricas y conceptuales se presentan por la tipología descriptiva del proyecto, para lo cual se presentan términos relacionados al tema, dichos términos son conceptualizados de forma detallada para proporcionar comprensión lectora de usuarios del área de ventas y software.

1.2. Proceso de búsqueda

La búsqueda de información se realiza utilizando criterios de inclusión considerados en fuentes bibliográficas como artículos científicos con un máximo de 5 años de antigüedad desde su publicación y que se indexan en la base de datos de la institución, especialmente con IEEE, Scopus y Dialnet, cuyas palabras claves utilizadas fueron Machine Learning, Predictive Analysis, Aprendizaje Automático.

De igual forma, se consideran libros de metodología con igual máximo de años de su publicación y canales oficiales gubernamentales como el Instituto Nacional de Estadísticas y Censo INEC y Banco Central del Ecuador BCE. En las bases de datos se realizó la búsqueda con los siguientes términos:

- Término 1: Aprendizaje automático, “*Machine Learning*”
- Término 2: Modelo Predictivo, “*Predictive model*”
- Término 3: Sector Comercial “*Comercial section*”
- Término 4: Técnicas de Ventas “*Sales techniques*”
- Término 5: Aprendizaje automático de ventas, “*Sales machine learning*”.

Por otro lado, los criterios de exclusión que se utilizaron, son estudios en bases de datos no fiables, así como artículos relacionados con el tema, pero con mayor de 5 años de publicación y blog de internet de usuarios no calificados

1.2.1. Grupo de control

Se realizó el proceso de búsqueda indexada en la base de datos de la institución, específicamente IEEE y Dialnet, cuyas palabras claves utilizadas fueron Machine

Learning, Predictive Analysis, Predictive model, Comercial section, Sales techniques, Sales machine learning. De la búsqueda efectuada por cada palabra clave se procedió a realizar la selección específica de los artículos que no aplicaban al tema requerido. Finalmente, se expone la forma de selección en los motores de base de datos, del universo de temas presentados, se seleccionaba usando los siguientes criterios

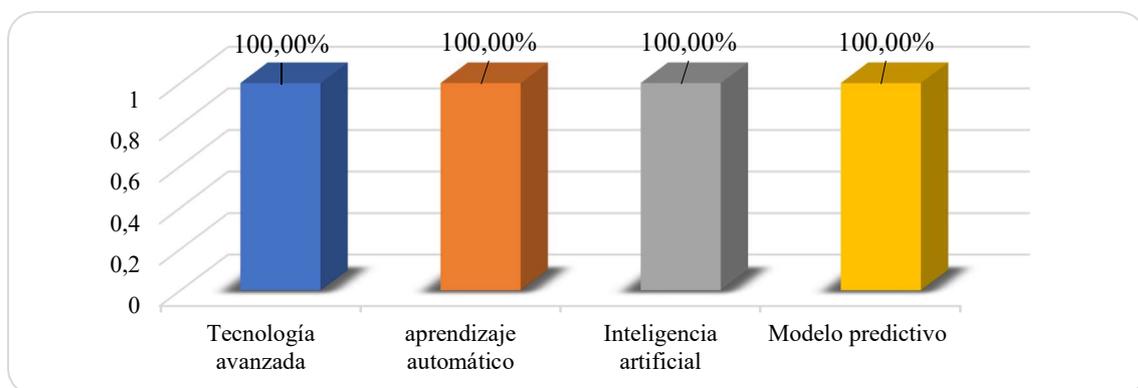
- Título del artículo
- Resumen
- Lectura de la introducción
- Lectura de conclusión
- Lectura completa del artículo

1.2.2. Cadena de búsqueda

Para el desarrollo de la bibliografía se emplearon cadena de búsqueda en las bases de datos mencionadas, con los siguientes contextos: búsqueda y búsqueda avanzada, las que se combinaron entre palabras claves en español “Modelo predictivo de ventas”, “técnicas de aprendizaje automático” “modelo predictivo del sector comercial”, “Modelo de ventas AND aprendizaje automática”, “Aprendizaje automático AND ventas”, “Aprendizaje automático OR Modelo de ventas, como se muestra en la figura 4.

Mientras que en idioma inglés se desarrolló la búsqueda con los siguientes criterios “Predictive sales model”, “Machine learning techniques”, “predictive model of the commercial sector”, “Machine Learning” AND, “Sales” “Sales model AND machine learning”, “Machine Learning OR Sales Model”

Figura 4 Cadena de búsqueda

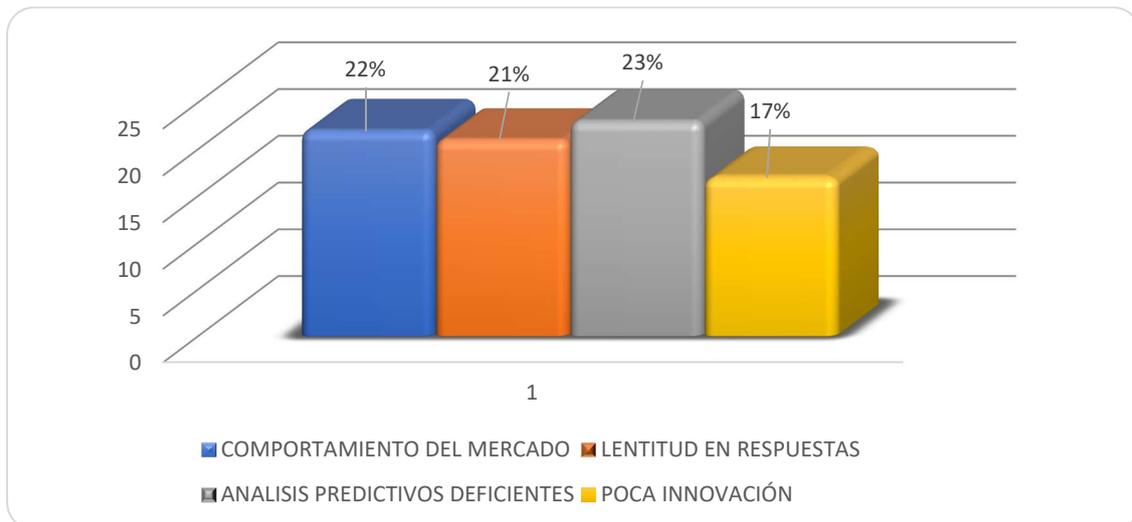


Elaboración: Charles Cali

Para una efectiva ejecución de la búsqueda de referencia bibliográfica, se subdivide en Temática del proyecto, la formulación del problema, la restricción del problema, la propuesta y los posibles escenarios de solución, los artículos identificados con el tema y cuya temática se relaciona con tecnología avanzada, aprendizaje automático, inteligencia artificial, modelo predictivo

La búsqueda bibliográfica en la formulación del problema se relaciona con el aprendizaje automático en el sector comercial está referenciado en un 22% de la bibliografía seleccionada, en un 21% las técnicas de proyecciones actuales, los modelos de aprendizaje automático en 23% y los, conocimiento tecnológico con 17% como se evidencia en la figura 5.

Figura 5 Formulación del problema



Elaboración: Charles Cali

1.3. Bases conceptuales

1.3.1. Aprendizaje automático (Machine Learning)

El aprendizaje automático (ML) se utiliza para optimizar el criterio de rendimiento manejando datos pasados, es decir basado en la experiencia [4]. Esto es, el aprendizaje automático basa sus procesos analíticos en función a datos anteriores. Para Díaz et al, El ML es una parte de la inteligencia artificial que brinda técnicas con la función de aprender de los datos o realizar pronósticos sobre ellos [10]. Estas técnicas permiten desarrollar estructuras a través de datos iniciales, cuya finalidad es hacer predicciones o tomar decisiones [11].

De igual forma, Al-Gunaid [12] menciona, en la actualidad estudiar los datos para predecir las fluctuaciones de las ventas con eficiencia, es fundamental dentro de los procesos primordiales de las organizaciones. El diseño de modelos de ML que se ajusten a determinados giros de negocio, permite predecir su conducta en el mercado con un alto nivel de precisión en situaciones específicas. Lo que permite evitar resultados desfavorables en caso de riesgos.

Lo que los autores mencionan, es la precisión con la que se puede pronosticar el comportamiento de los productos de primera necesidad [13], aún en escenarios adversos como los suscitados en tiempos de confinamiento producidos por el Covid 19, donde algunas de las estanterías de los supermercados se vaciaron por completo, en parte por una sobre demanda de productos, y en parte por desconocer este tipo de escenarios, lo que incidió en no abastecerse como se debía.

Considerando que anteriormente no se habían producido confinamientos, este comportamiento era desconocido, mientras que actualmente, con los modelos del machine learning se pueden ejercer cálculos algorítmicos que pronosticaron con precisión en contextos de mercados normales e inusuales.

1.3.2. Modelos predictivos

El desarrollo de métodos para analizar pronósticos inteligentes, necesita el estudio de análisis de datos para proyectar predicciones en las decisiones [14]. Las empresas comerciales supeditan las proyecciones de ventas en función al conocimiento del mercado, en este sentido, requieren la predicción de las tendencias de ventas para poder proyectar de forma fiable, la fiabilidad en el pronóstico de ventas y proyecciones, provee una herramienta vital para el cumplimiento de metas en los negocios [4].

Por otro lado, Ranjitha [15] señala que los centros de comercialización, específicamente la cadena de supermercados Big Mart, desarrollan un rastreo a las ventas individualizada por cada artículo, estos datos permiten pronosticar el consumo de los usuarios y hacer más efectiva la labor de bodega con un inventario adecuado. Las fluctuaciones y el volumen de demanda de cada artículo a menudo se realizan al tomar los datos del inventario.

Tabla 1 Modelos predictivos

Modelo	Descripción
Técnica de regresión	Son el pilar del análisis predictivo. El enfoque se basa en el establecimiento de una ecuación matemática como modelo para representar las interacciones entre las diferentes variables en consideración.
Modelo de regresión lineal	Este modelo analiza la relación existente entre la variable dependiente y un conjunto de variables independientes. Esta relación se expresa como una ecuación que predice la variable de respuesta como una función lineal de los parámetros. Estos parámetros se ajustan para que la medida de ajuste sea óptima. Gran parte del esfuerzo en la adaptación del modelo se centra en minimizar el error
Análisis de supervivencia o duración	Estas técnicas se desarrollaron principalmente en las ciencias médicas y biológicas, pero también se usan ampliamente en las ciencias sociales como la economía, así como en la ingeniería (fiabilidad y análisis del tiempo de falla).
Árboles de clasificación y regresión	Los árboles de clasificación y regresión son una técnica de aprendizaje de árboles de decisión no paramétrica que produce árboles de clasificación o regresión, dependiendo de si la variable dependiente es categórica o numérica, respectivamente. Cada rama del árbol finaliza en un nodo terminal. Cada observación cae en un nodo terminal, y cada nodo terminal es definido de manera única por un conjunto de reglas
Curvas de regresión adaptativa multivariable	Las curvas de regresión adaptativa multivariable son una técnica no paramétrica que construye modelos flexibles al ajustar regresiones lineales por piezas. Un concepto importante asociado con curvas de regresión es el de un nudo. Un nudo es donde un modelo de regresión local da paso a otro y por lo tanto es el punto de intersección entre dos curvas.
Máquinas de vectores de soporte	Las máquinas de vectores de soporte se usan para detectar y explotar patrones complejos de datos agrupando, ordenando y clasificando los datos. Son máquinas de aprendizaje que realizan clasificaciones binarias y estimaciones de regresión. Usualmente usan métodos basados en kernel para aplicar técnicas de clasificación lineal a problemas de clasificación no lineal.
Naïve Bayes	El clasificador bayesiano ingenuo se basa en la regla de probabilidad condicional de Bayes, que se utiliza para la tarea de clasificación. El clasificador bayesiano asume que los predictores son estadísticamente independientes, lo que hace que sea una herramienta de clasificación eficaz que sea fácil de interpretar. Se emplea mejor cuando se enfrenta al problema de la “de la dimensionalidad”, es decir, cuando el número de predicciones es muy alto.
Redes neuronales	Son técnicas de modelado no lineal sofisticadas que son capaces de modelar funciones complejas. Pueden aplicarse a problemas de predicción, clasificación o control en un amplio espectro de campos como las finanzas, la psicología cognitiva/neurociencia, la medicina, la ingeniería y la física.

Fuente: Espino Timón (2017) [18]

Para almacenes de las características de Big Mart, estos datos dan como resultados, predicciones del volumen de ventas a realizar para determinada temporada, para lo cual fue necesario manejar modelos predictivos, específicamente esta empresa diseñó un modelo predictivo utilizando Xgboost, regresión lineal, regresión polinomial y técnicas de regresión [16].

De igual forma, Zihan Qiao [17] expresa, que los modelos predictivos de las ventas contribuyen a las organizaciones a diseñar pronósticos de ventas que se ajustan a su realidad. La construcción de modelos para la previsión de ventas debe realizarse depurando los datos históricos, hallar la estructura adecuada de acuerdo a la tipología de negocios o artículos, descartando los datos irrazonables, Trabajar con modelos predictivos que permitan proyectar ventas es imprescindible en el mundo empresarial.

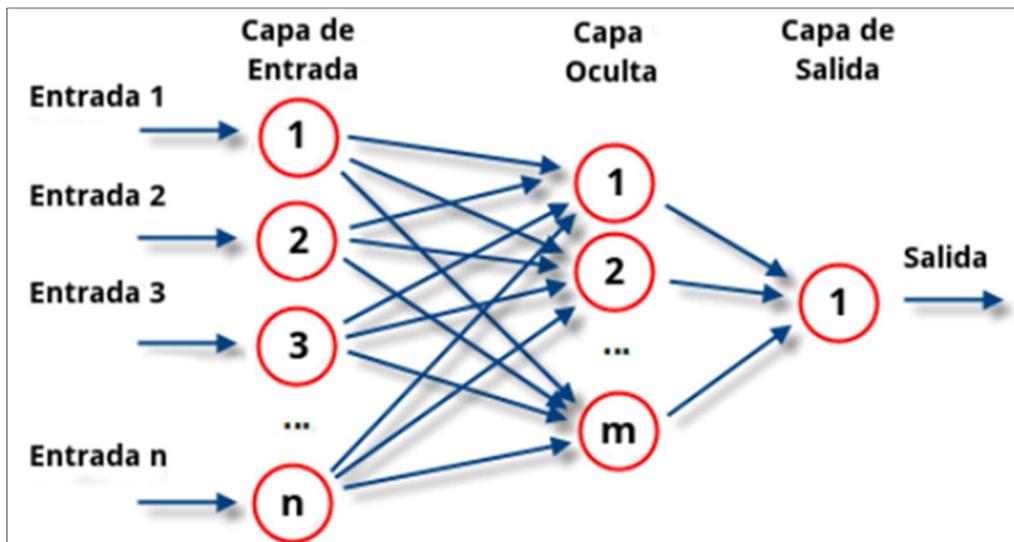
A pesar de la importancia de efectuar pronósticos de ventas fiables no es una labor sencilla. Los datos históricos no son suficientes para pronosticar las ventas debido a que estas son proclives a desviarse. No obstante, con la inclusión de los algoritmos se obtendrá información valiosa de datos a gran escala para conseguir predicciones de ventas más precisas [18].

1.3.3. Redes neuronales

Las redes neuronales (RN) se tratan de una cadena de algoritmos cuya finalidad es identificar los nexos internos en una serie de datos secuenciales, lo que hace es emular la forma en que el cerebro humano trabaja. Dicho de otra forma, las RN trabajan para comunicarse con otros elementos del cerebro [19].

El cerebro humano está compuesto por millones de neuronas, lo que hacen dichas neuronas es recoger datos de entrada, analizarlas para después enviar dichos datos de salida, de igual forma funcionan las RN por algoritmos, estas se diseñan una agrupación de capas llamadas neuronas artificiales, como se muestran en la figura 6, las cuales se acoplan y envía señales entre sí [20]. Este acoplamiento envía información y se comunican desde el ingreso de información hasta crear una salida de información.

Figura 6 Red neuronal artificial



Fuente: Jiménez Serrano (2020).

Para poder realizar algoritmos con RN y que estas desarrollen pronósticos de ventas fiables, se debe contar con una muestra de elementos significativa, es decir una big data robusta, caso contrario se minimiza la efectividad de la predicción [12]. Las RN son un método muy utilizado dentro de la inteligencia artificial, cuyo aprendizaje automático se produce en el área de reconocimiento a predecir [21]. En el presente estudio se refiere al modelo predictivo de ventas de productos de primera necesidad en el sector comercial.

1.3.4. Redes neuronales convolucionales

Una Red Neuronal Convolucional (CNN), es un diseño o tipo de arquitectura de RN más acentuadas en el mundo de la inteligencia artificial. Se empieza convirtiendo la big data en una estructura marco de datos o mapa de contenidos, después se utiliza la red neuronal convolucional en este mapa de contenido, en la cual las características seguras se extraen en las capas ocultas, la cual trabajará la salida de neuronas para finalmente, emplear el modelo predictivo para las ventas, en este caso las neuronas brindan información o capa de salida [22].

Las CNN permiten usar capas o conjuntos de neuronas que sirven para ingresar datos que luego saldrán como producto final o capa posterior, por lo que se puede afirmar que una CNN es un conjunto de neuronas que recibe información, la ejecuta y luego proporciona datos requeridos que servirán para la función que fue creada la CNN, esta tipología

neuronal funciona de forma similar a las redes neuronales del cerebro [23]. A continuación, se expone cómo fueron evolucionando de forma cronológica las redes neuronales.

Tabla 2 Evolución de las redes neuronales

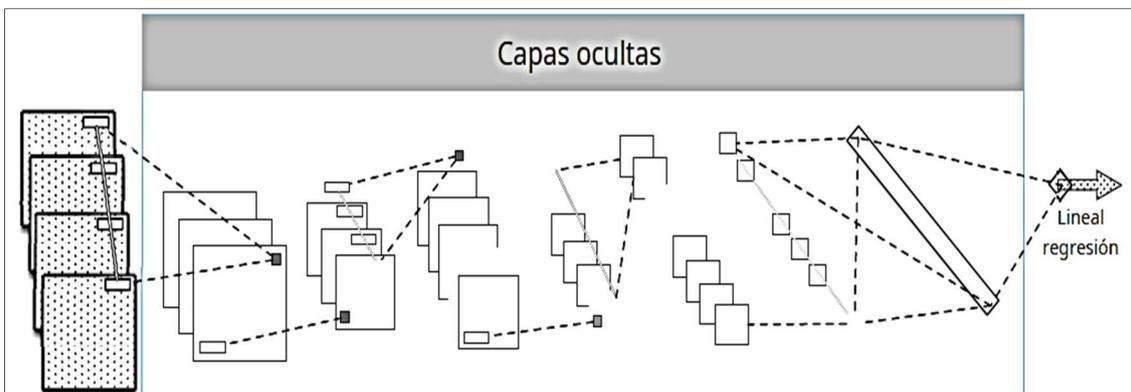
Historia de las redes neuronales	
1936	Alan Turing. Fue el primero en estudiar el cerebro como una forma de ver el mundo de la computación.
1943	Warren McCulloch, un neurofisiólogo, y Walter Pitts, un matemático, lanzaron una teoría acerca de la forma de trabajar de las neuronas (Un Cálculo Lógico de la Inminente Idea de la Actividad Nerviosa. Ellos modelaron una red neuronal simple mediante circuitos eléctricos.
1949	Donald Hebb. Se refirió a la conexión entre psicología y fisiología. Fue el primero en explicar los procesos del aprendizaje (que es el elemento básico de la inteligencia humana) desde un punto de vista psicológico, desarrollando una regla de cómo el aprendizaje ocurría. Aún hoy, este es el fundamento de la mayoría de las funciones de aprendizaje que pueden hallarse en una red neuronal.
1950	Karl Lashley. En sus series de ensayos, encontró que la información no era almacenada en forma centralizada en el cerebro, sino que era distribuida encima de él.
1956	Congreso de Dartmouth. Este Congreso frecuentemente se menciona para indicar el nacimiento de la inteligencia artificial.
1957	Frank Rosenblatt. Comenzó el desarrollo del Perceptrón. Esta es la red neuronal más antigua; utilizándose hoy en día para aplicación como reconocedor de patrones. Este modelo era capaz de generalizar, es decir, después de haber aprendido una serie de patrones podía reconocer otros similares, aunque no se le hubiesen presentado anteriormente
1960	Bernard Widrow/Marcial Hoff. Desarrollaron el modelo Adaline (ADaptative LINear Elements). Esta fue la primera red neuronal aplicada a un problema real (filtros adaptativos para eliminar ecos en las líneas telefónicas) que se ha utilizado comercialmente durante varias décadas
1967	Karl Steinbeck & Die Lernmatrix. Red neuronal para simples realizaciones técnicas (memoria asociativa)
1974	1974 - Paul Werbos. Desarrolló la idea básica del algoritmo de aprendizaje de propagación hacia atrás (backpropagation); cuyo significado quedó definitivamente aclarado en 1985.
1977	Stephen Grossberg. Teoría de Resonancia Adaptada (TRA). La Teoría de Resonancia Adaptada es una arquitectura de red que se diferencia de todas las demás previamente inventadas. La misma simula otras habilidades del cerebro: memoria a largo y corto plazo
1980	Kunihiko Fukushima. Desarrolló un modelo neuronal para el reconocimiento de patrones visuales.

- 1985 John Hopfield. Provocó el renacimiento de las redes neuronales con su libro: "Computación neuronal de decisiones en problemas de optimización.
- 1986 David Rumelhart/G. Hinton. Redescubrieron el algoritmo de aprendizaje de propagación hacia atrás (backpropagation). A partir de 1986, el panorama fue alentador con respecto a las investigaciones y el desarrollo de las redes neuronales. En la actualidad, son numerosos los trabajos que se realizan y publican cada año, las aplicaciones nuevas que surgen (sobre todo en el área de control) y las empresas que lanzan al mercado productos nuevos, tanto hardware como software (sobre todo para simulación)

Autor: Rivas & Mazón (2017) [25]

Kaunchi [24] propone un procedimiento cuyo objetivo sea la predicción en la oferta y la demanda de artículos mediante el uso de una CNN cuyo estudio permitirá observar el comportamiento dentro del segmento del comercio electrónico. Para lo cual, se detalla la presencia de dichos artículos afines con los datos del centro de distribución, que se puede convertir en una arquitectura de mapa de contenido, como se muestra en la figura 7.

Figura 7 Pronóstico de ventas utilizando la red neuronal convolucional



Fuente: Zhao & Wang (2017)

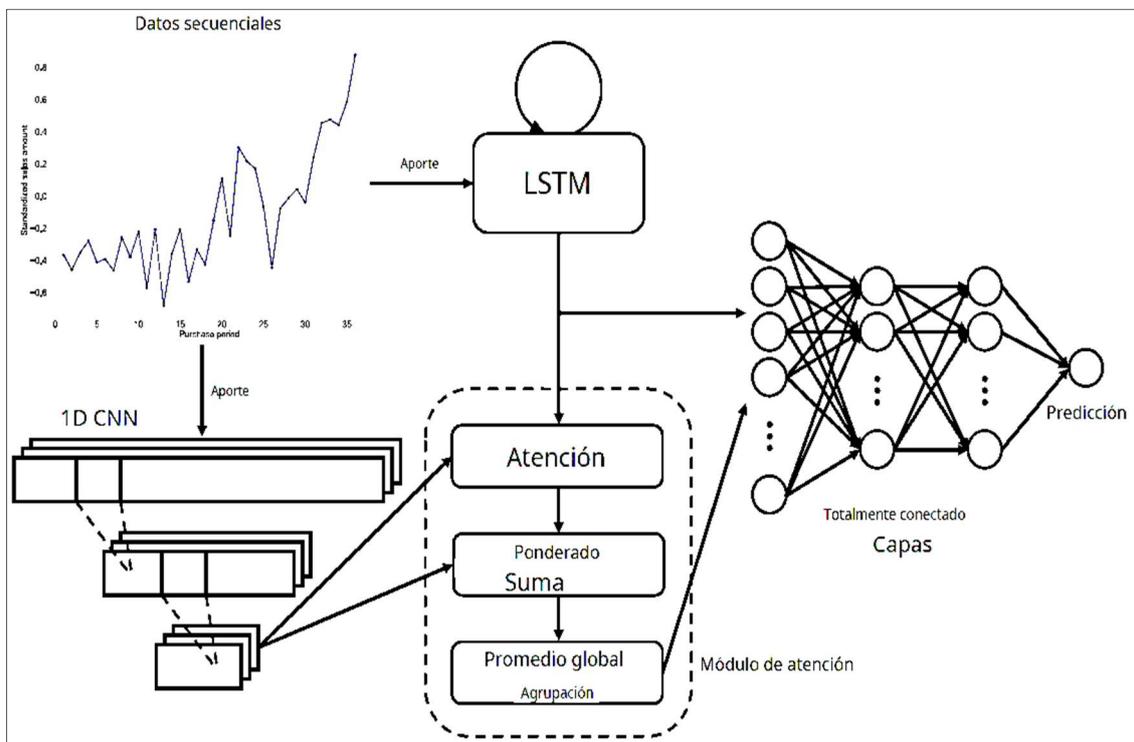
A pesar que las CNN son una fuente efectiva de predicción de ventas para artículos de primera necesidad en el sector comercial, existen nuevos estudios que afirman que, combinando con otros métodos, los análisis predictivos son aún más exactos, Zhang G asevera que las técnicas combinadas son más precisas que un solo modelo.

Por su parte Kaneko, presentó un modelo de red neuronal combinado por redes neuronales convolucionales y el modelo Memoria de largo a corto plazo (LSTM) en el que se

evidenció mayor precisión en el pronóstico de ventas. Para lo cual, y con la finalidad de confirmar su teoría, contrastó con 7 diferentes técnicas.

En dicha comparación, el modelo XGBoost presentaba indicadores más altos de precisión. No obstante, el modelo LSTM, que se preparó para identificar el origen de la big data, presentó mejores resultados, toda vez que se desarrolló una técnica basada en CNN con herramientas de atención alineadas a LSTM, cuyo resultado derivó en una mayor precisión en el mercado comercial [25], como se muestra en la figura 8.

Figura 8 Red neuronal combinado los modelos CNN & LSTM



Fuente: Kaneko Yuta (2019)

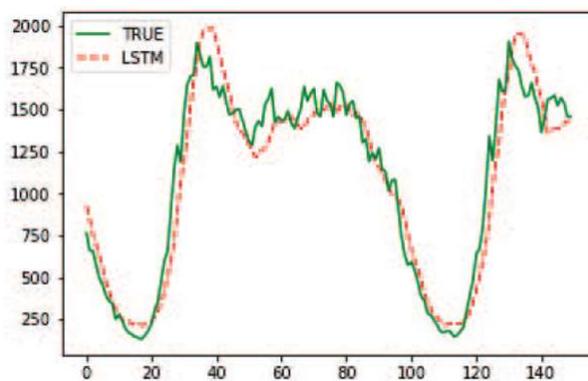
De igual forma, Kaunchi et al señala que la combinación de los modelos CNN y el modelo Memoria de largo a corto plazo (CNN-LSTM) hace posible capturar limitaciones más precisas que el modelo LSTM. Para pronosticar las ventas proyectadas, tuvo que elegir varias condiciones, en el caso de productos de primera necesidad eligió ID de local, ID de artículo, promociones. Estos parámetros sintetizan los pronósticos de las ventas en el sector comercial.

Así mismo, Zhao et al afirma que el diseño de una nueva técnica de predicción de secuencias de tiempo, plantea una técnica que pronostica con mayor fiabilidad, este

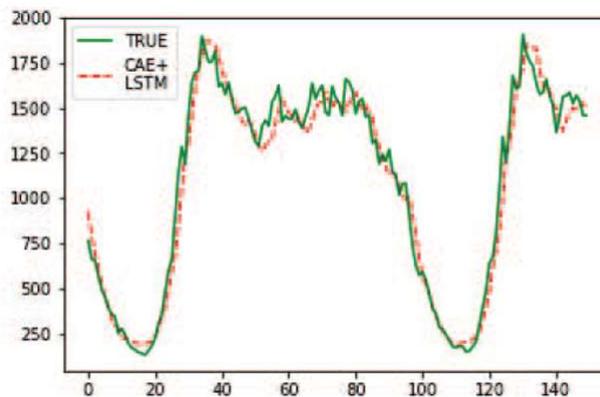
método es fusión entre codificador automático convolucional (CAE) y LSTM los cuales dieron como resultado mayor precisión y ajuste en las proyecciones de venta [26]. A continuación, en la figura 9, se presentan las imágenes de los resultados determinados por el autor mencionado, en donde se evidencia mejor precisión en las fluctuaciones frecuentes y cambios inesperados de información.

Figura 9 Resultados de modelos convolucionales

Resultado LSTM



Resultado CAE & LSTM



Fuente: Saena & Suttichaya

Los resultados anteriores se asemejan al estudio de Saena & Suttichaya [27], cuyo análisis de venta con aprendizaje automático, específicamente con el modelo CNN combinado con el modelo LSTM consigue mejores predicciones en las proyecciones de venta. Los autores mencionados, recopilaron información de los ítems que se habían vendido cada mes y los recopilaron por categorías en una base de datos, desarrollaron el modelo predictivo y luego realizaron las evaluaciones

El diseño (CNN-LSTM), está conformada por 5 capas, que son la capa de acceso, 3 capas ocultas y la capa de salida. Las capas ocultas constan de una capa convolucional y 2 capas LSTM. El resultado determinó que CNN-LSTM destacó entre otros modelos. Esto debido a que CNN detectó automáticamente los perfiles de la señal espacial, mientras que LSTM recoge perfiles de alto nivel de CNN para revelar la salida. No obstante, la eficiencia de CNN-LSTM depende del ajuste de las medidas iniciales. Para lo cual se debe realizar varias pruebas computacionales para ajustar los parámetros de CNN-LSTM [27].

Como dato importante, la base de datos se compone por datos volubles, esto debido a que las ventas no siguen patrones fijos, sino que se ven afectadas por factores relevantes, tal como sucedió en tiempos de confinamiento total y parcial. CNN-LSTM presentó mejores resultados de predicciones, esto porque CNN se desarrolla automáticamente, mientras que LSTM analiza e identifica las dependencias a través de la serie temporal.

Por otro lado, Xue [28], en su estudio de evolución de las CNN-LSTM profundas para el tiempo de inventario, expresa: De acuerdo con la tipología cambiante del inventario, los métodos predictivos utilizan el modelo LSTM para aprender dependencias temporales largas mientras que la CNN para conocer las particularidades locales. A pesar de ello, desarrollar una red CNN-LSTM eficiente es un reto por su complejidad, por lo que se necesita realizar muchas pruebas y validaciones.

Para desarrollar algoritmos de ML mediante modelos CNN-LSTM se efectuó y analizó estructuras de algoritmos semejantes y efectivas lo que dio como resultado mayores aciertos en los pronósticos de predicción que la solución de línea de base. El informe citado fue uno de los primeros en involucrar CNN combinado con el modelo LSTM.

Capítulo 2

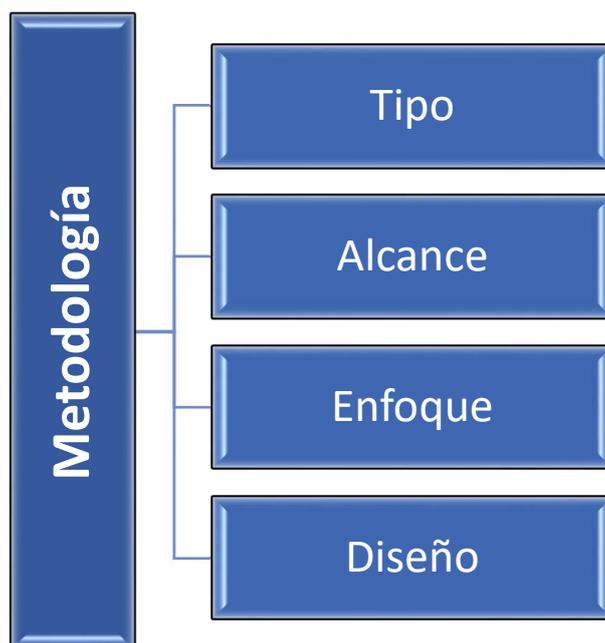
Materiales y métodos

Esta sección tiene como propósito describir el diseño y las técnicas que se utilizaron en el desarrollo del proceso investigativo, y que se muestra en la figura 10, se detalla los materiales que se emplearon, así como la tipología, enfoque, población y muestra que se ajustó al estudio, lo que convierte a la presente sección como una del epígrafe más importante del presente análisis. La propuesta metodológica reúne datos de venta de empresas que comercializan productos de primera necesidad como uno de los materiales más significativos a utilizar.

Para Escudero & Cortez los proyectos investigativos demandan del diseño metodológico, como instrumento vital para el desarrollo ordenado y estructurado dentro de los procesos de investigación y análisis de los problemas [29]. Esto significa el desarrollo de un análisis, exploración e información de la propuesta metodológica elaborada, cuyo propósito es darle validez metodológica, asignando los pasos determinados en el estudio, estableciendo mecanismos que se manejan para conseguir información necesaria y contrastar sus resultados.

Actualmente, los inventarios de los negocios que comercializan productos de primera necesidad, prevén en primer lugar la demanda **con base en** la temporada o fechas específicas, para luego calcular stocks necesarios que cumplan con dicha demanda [30], con el modelo predictivo CNN se prevé mejorar los pronósticos de una forma eficiente en el sector comercial. No obstante, para realizar este modelo predictivo es indispensable seguir métodos que conlleven qué tipo de investigación a seguir, los cuales se detallan a continuación:

Figura 10 Metodología de investigación aplicada al estudio



Fuente: Hernández et al (2019)
Elaboración: Charles Cali

2.1. Tipo de estudio

Muñoz Rocha expresa: La tipología de investigación se clasifica conforme la naturaleza o forma como se obtiene la información, esto es, por las referencias bibliográficas o fuentes de información [31]. El autor citado, hace mención a la forma como se obtuvieron los datos para el desarrollo del estudio. En este sentido, la procedencia de los datos de información corresponde a varias pymes y grandes empresas comercializadoras, por lo que se afirma que el tipo de estudio investigativo es de campo y descriptivo [32].

2.1.1. Estudio de campo

La data incorporada al presente estudio se ha recopilado de pequeñas, medianas y grandes empresas comercializadoras de productos de primera necesidad de diferentes cantones de la provincia del Guayas, dichos datos de ventas han sido seleccionados de los últimos 5 años en los puntos comerciales, lo que se ajusta a una investigación de campo.

Arias Gonzáles asegura al respecto, que la investigación de campo es el tipo de investigación, que según la fuente en la que se obtuvo los datos, se efectúa en el sitio que

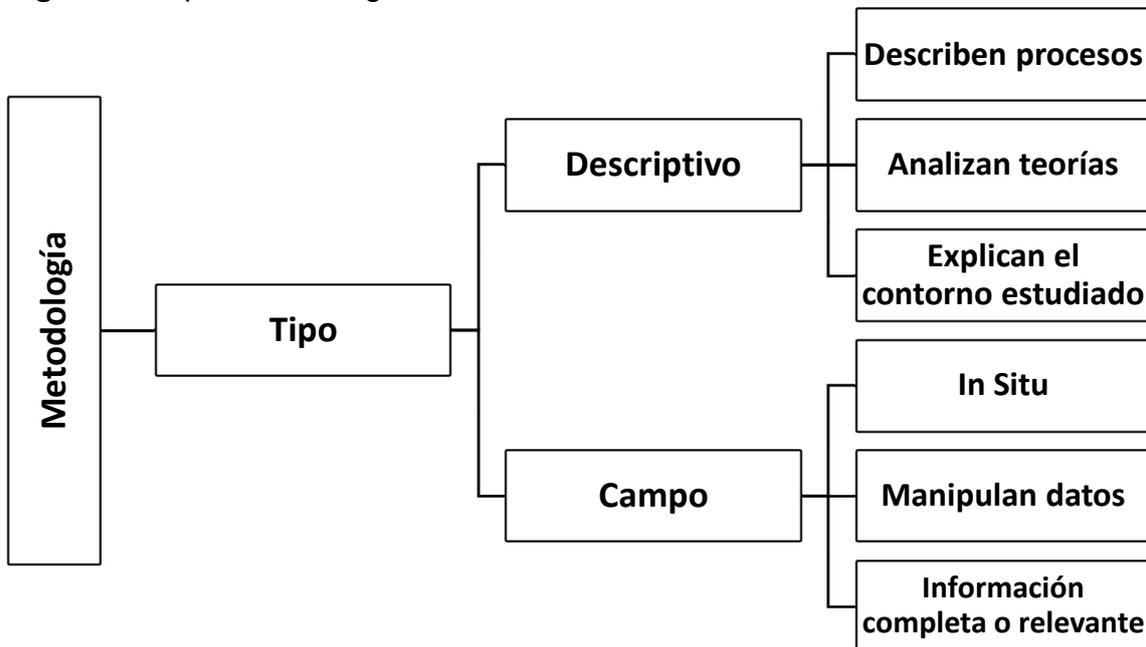
se suscitan los hechos investigados. Su finalidad es obtener los datos de forma ordenada, sistemática con respecto al tema de interés [33]. El presente análisis se ajusta a un trabajo de campo, dado el acceso a los datos de las propias fuentes de investigación, es decir al sector comercial de productos de primera necesidad.

2.1.2. Estudio descriptivo

El análisis de los diversos modelos predictivos basados en las técnicas de ML, específicamente en las CNN, las características y relación con el objeto de estudio, permite describir sus principales características, perfiles y componentes que se ajustan para desarrollar pronósticos eficientes.

La figura 11 muestra los estudios descriptivos perciben precisiones integrales y descripciones del contexto, de las pertenencias, de las partes o de la ejecución de un estudio o suceso, este tipo de estudio lleva a describir cómo se producen en el presente las particularidades más significativas del fenómeno analizado [34].

Figura 11 Tipo de investigación



Elaboración: Charles Cali

2.2. Alcance de estudio

2.2.1. Alcance explicativo

El alcance explicativo no involucra exclusivamente las características del objeto de estudio, es decir está relacionado a aclarar todo el proceso investigativo [8]. Este alcance se caracteriza por no limitarse a describir el problema que enfrenta el contexto estudiado, sino explicar de forma detallada sus posibles soluciones. Los modelos predictivos de las ventas de productos de primera necesidad en el sector comercial, enfrentan desafíos relacionados a maximizar la eficiencia predictiva, los mismos que se proponen con técnicas de ML.

Las técnicas de ML se utilizan desde hace varios años por empresas que buscan predecir el comportamiento de ciertos productos y hacer más efectivo los manejos del inventario. Para el presente análisis se estudian las CNN, cuya propuesta se ha manifestado con un rendimiento óptimo en trabajos de modelos predictivos, cuya tarea principal es aprender las características de la big data en el menor tiempo y con mayor precisión.

2.3. Enfoque

2.3.1. Enfoque cualitativo

Es un método de exploración que se relaciona más con las descripciones del objeto de estudio, sin mediciones numéricas. Los instrumentos cualitativos pretenden concretar la problemática de investigación. Se caracteriza por explicar las variables que se proponen en el desarrollo de la investigación y no tanto por medirlas [35].

Las redes neuronales correspondientes al ML, específicamente, la red convolucional procesa las capas del desarrollo de entrada, salida y destino, proporciona campos receptivos de información, semejantes a las neuronas del cerebro humano. En este sentido, el enfoque cualitativo se encarga de la descripción de todos los procesos que permitan clasificar datos.

2.3.2. Enfoque cuantitativo

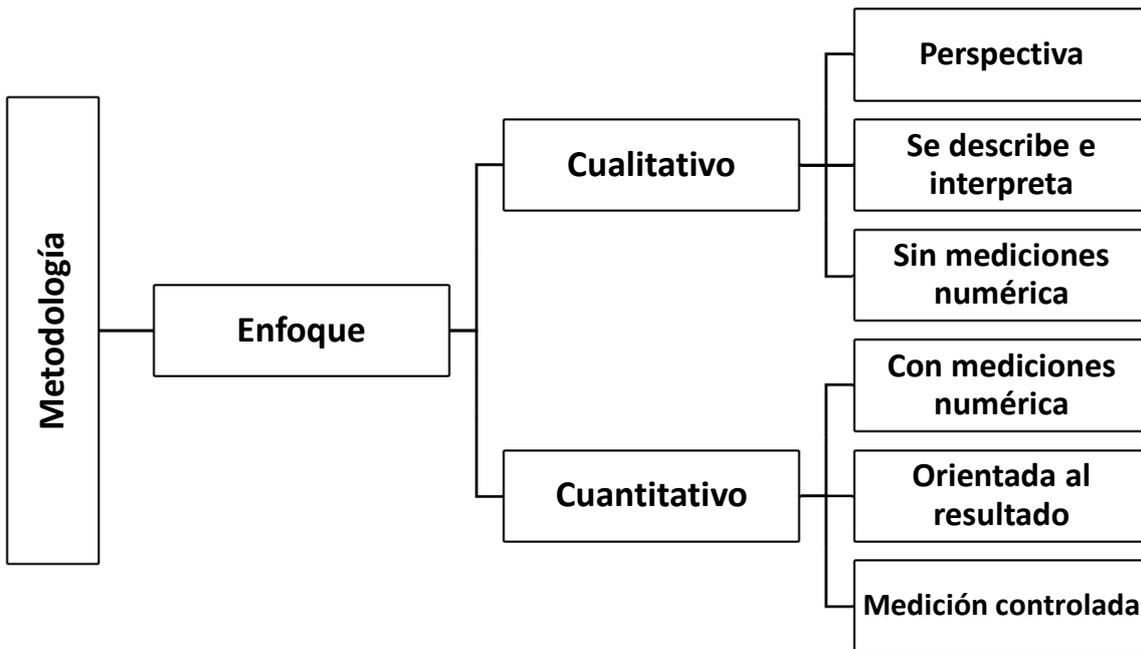
Las CNN es un método característico de algoritmos de aprendizaje profundo, que toma datos por medio de distintas capas neuronales [5]. En este sentido, el enfoque cuantitativo

se apoya en medición numérica, los procesos investigativos que se desarrollan bajo este enfoque manejan y recolectan información como la big data, confiando en la medición numérica y el conteo con la finalidad de determinar con mayor exactitud patrones de conducta de una población [8].

2.3.3. Enfoque mixto

Este método incorpora el estudio de enfoques cualitativos y cuantitativos y técnicas ordenadas, que involucran la recolección de información, como se aprecia en la figura 12, de igual forma su combinación y discusión vinculada, para efectuar deducciones fruto de la investigación obtenida y conseguir un mayor alcance del análisis realizado [36]. El análisis de modelos predictivos involucra mediciones controladas y análisis de big data.

Figura 12 Enfoque mixto



Elaboración: Charles Cali

2.4. Diseño

El diseño describe los procedimientos o técnica pensada para conseguir los datos que se necesita con la finalidad de responder a la formulación del problema [36]. El diseño

establece la estrategia que se requiere para analizar la formulación del problema, así como la hipótesis, se utilizará el diseño experimental.

2.4.1. Diseño experimental

El tipo de estrategia o diseño se ajusta de acuerdo a las características de la investigación, para el presente estudio se aplica el diseño experimental, la figura 13 señala que es debido a la existencia de pruebas o situaciones experimentales hacia las variables empleadas [33]. los objetos de estudio son analizados en su entorno regular y estuvieron sujetos a cambios y experimentos en la cantidad de: filtros, kernel, activación, optimizador y épocas

El término Manipular variables se refiere estrictamente a las pruebas que se ejercen en la variable independiente “Modelo predictivo” para que ejerza influencia en la variable dependiente “Ventas”. Y es precisamente la naturaleza del diseño experimental que realiza este tipo de tarea, es decir se realizan maniobras que permitan interpretar diferentes resultados.

Figura 13 Características de investigación experimental



Fuente: José Luis Arias
Elaboración: Charles Cali

La recolección de información se realiza en varias etapas, especialmente la información correspondiente a los años 2017 y 2018, luego se realiza una segunda recolección que pertenece a los años 2019, 2020 y 2021. Cabe señalar que la información del año 2022

no se encuentra aún disponible, sin embargo, en las próximas semanas estará listo, no obstante, esta información tampoco será considerada por ser datos recientes.

2.5. Cálculo de población y muestra

El análisis del modelo predictivo de las ventas en el sector comercial basado en técnicas de machine learning no amerita realizar cálculo del tamaño del universo o población, por tal razón no se realizó cálculo de muestra. Los elementos que se consideran para establecer el modelo predictivo basado en ML, son los que se extraen de la big data, que es el conjunto de datos o matriz que servirá para desarrollar las redes neuronales convolucionales. Esta matriz de datos, está compuesta de 800.000 registros.

2.6. Operacionalización de variables

La figura 14 muestra las variables del estudio y sus respectivas dimensiones, las mismas que serán determinantes al momento para el cumplimiento de los objetivos específicos

Figura 14 Operacionalización de variable

Variables	Tipo	Dimensión	Indicadores
Modelo predictivo	Independiente	Pedidos precisos	Stock promedio Rotación de stock
		Ventas más precisas	Mayor facturación Clientes nuevos
		Mejor stock	Tiempo de reemplazo Sin quiebre de stock
Ventas de productos	Dependiente	Cumplimiento de metas	Metas organizacionales Metas financieras
		Menor devolución	Tasa de retorno Pérdidas
Machine learning	Interviniente	Satisfacción del cliente	Fidelización de clientes Menor clientes perdidos Net Prometer Score

Elaboración: Charles Cali

Modelo predictivo de las ventas de productos de primera necesidad en el sector comercial basado en técnicas de machine learning

En el presente capítulo se desarrolla la metodología y materiales propuestos de 3 modelos basados en CNN, cada uno con su propia arquitectura, a estos modelos se los entrenó utilizando varias combinaciones de los hiper parámetros como: filtros, kernel, optimizadores y épocas. Generando 256 combinaciones pudiendo ser cada una de ellas una posible solución a la necesidad de un modelo predictivo como se muestra en el Anexo 1. Cada combinación será sometida a un entrenamiento utilizando el 80% del dataset como datos de entrada de la CNN y mediante métricas para evaluar siendo estos objetos de experimentación.

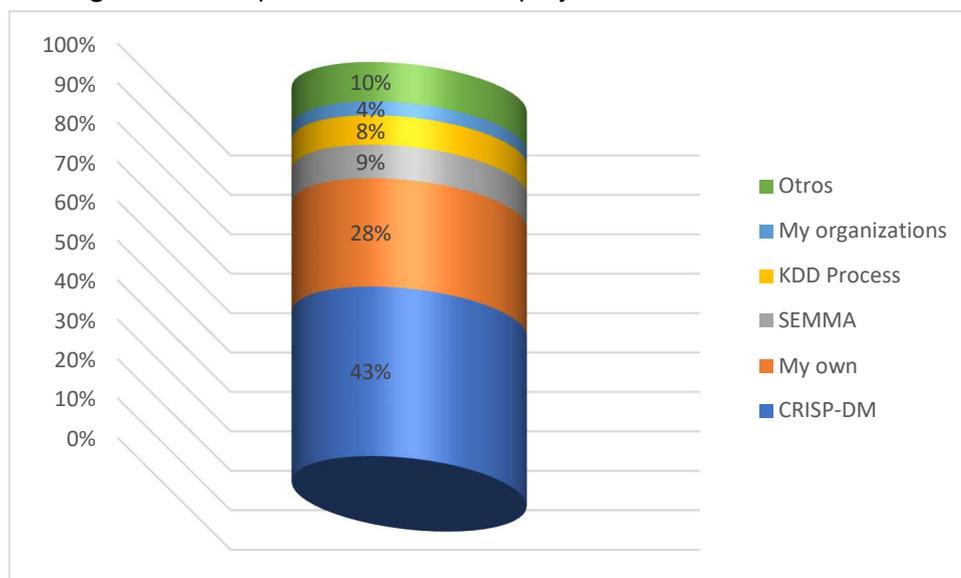
3.1. Selección de metodología

La metodología seleccionada para el desarrollo de esta tesis se basó en la propuesta de Piatetsky, quien hizo una comparación entre varias metodologías para proyectos de análisis o minería de datos, concluyendo que CRISP-DM es el método que más se utiliza en los proyectos de grandes volúmenes de datos [37], el autor citado afirma que al menos el 43% de los encuestados maneja esta metodología [38]. Los resultados de la encuesta efectuada se presentan en la figura 15 y 16 imagen a continuación.

Figura 15 Principales métodos en los proyectos de datos
Fuente: Piatetsky

CRISP-DM	86	43%
My own	55	28%
SEMMA	17	9%
KDD Process	15	8%
My organizations	7	4%
Otros	20	10%
Totales	200	100%

Figura 16 Principales métodos en los proyectos de minería de datos



Fuente: Piatetsky

3.1.1. Metodología CRISP-DM

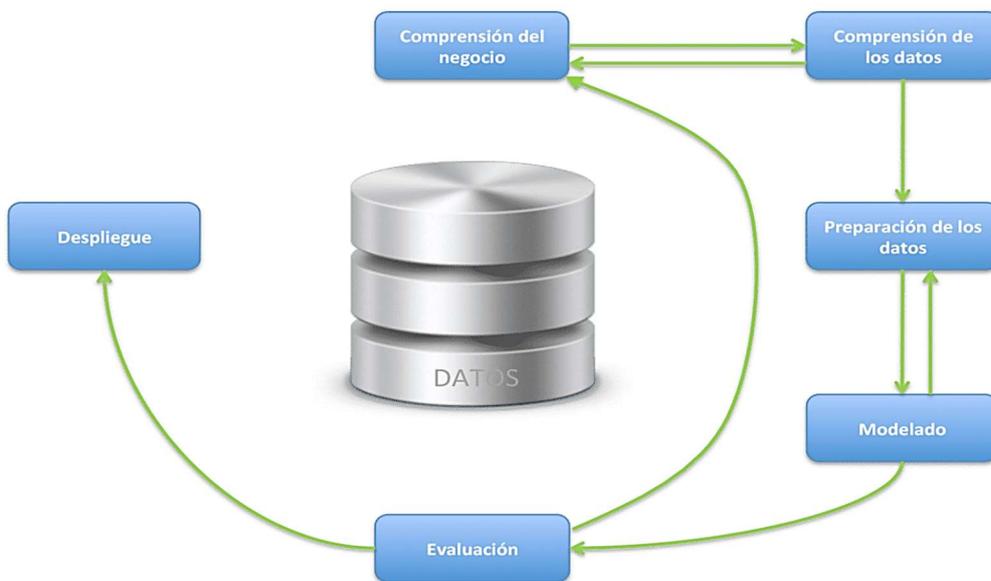
La metodología CRISP-DM (Cross Industry Standard Process for Data Mining), es una técnica fundamental adaptada al mundo empresarial, la misma que se desarrolla bajo métodos eficientes, que ponen de manifiesto la solidez y consistencia de sus procesos [39].

Otra característica importante, es que diseña bajo un tipo de metodología neutral en relación con el instrumento a trabajar, en este caso, minería de datos [40], cuya finalidad consiste en identificar las variables principales de las empresas comerciales, tales como: Comprensión del giro del negocio, análisis de los datos, preparación de datos, modelado, fase de prueba y despliegue. La figura 17 muestra el ciclo de vida de la metodología, cada etapa se detalla a continuación:

- **Comprensión del giro del negocio:** Identificar los objetivos, problemas y planes de acción
- **Análisis y comprensión de la información:** Se adquieren y estudian los datos.
- **Disposición de los datos:** Se recopilan y verifican los datos, se establecen las diferentes fases de los datos.
- **Modelado:** Se preparan los datos con el modelo establecido

- **Valoración de resultados:** Se evalúan los resultados considerando los criterios de éxitos preestablecidos
- **Ejecución del plan:** Se monitorea los procedimientos con la finalidad de detectar movimientos inusuales

Figura 17 Metodología CRISP-DM



Autor: Hernández Calderón.

- Comprensión del giro del negocio o problemática a solucionar:** Saber ¿qué hay que solucionar? Identificar ¿cuáles son los problemas de la organización? Esta etapa es la fase más significativa por establecer las insuficiencias más importantes a cubrir [41], si no se tiene clara la problemática, las soluciones no serán eficientes.

Por tal motivo, en esta fase del presente estudio se debe analizar de forma íntegra a la empresa, como lo presenta la figura 18, de esta manera se pudo identificar los problemas, para luego elaborar los objetivos de la minería de datos, para finalmente elaborar un plan de acción que permita orientar cada paso del proyecto [42].

Figura 18 Fase de comprensión del negocio



Autor: Espinoza Zúñiga (2020)

Fases de la comprensión del negocio

- Para efectuar esta etapa, se realizó el requerimiento debido al departamento de sistemas de la organización, quienes procedieron a dar acceso a la base de datos de producción. Con la finalidad de aplicar la metodología adecuada, se ejecutó un análisis general de la estructura, así como los datos de dicha base para determinar la importancia de los datos mencionados.
- De la base de datos se extrajo información de la facturación del negocio, correspondiente del 2 de enero del 2018 al 31 de diciembre del 2021, la estructura de la data presenta los campos: identificador del cliente, fecha, cantidad, valores unitarios, código de artículos, valor de descuentos, descripción del artículo, descripción del grupo al que pertenece el artículo y el grupo al que pertenece el artículo, como lo muestra la figura 19 y 20.
- Se delimitan los objetivos de la minería de datos, con la finalidad de identificar y entender los problemas en la organización, los mismos fueron definidos en conjunto con la gerencia del negocio, el área de sistemas y con quienes toman las decisiones en la empresa, a su vez, se definen objetivos específicos, los que se mencionan a continuación:
 - A-1. Definir variables comerciales que el modelo predictivo necesita identificar.
 - A-2. Sistematizar los objetivos del estudio, ejecutando preguntas relevantes.
 - A-3. Definir el equipo que ejecutará el proyecto, señalando alcance de cada partícipe

A-4. Elaborar un plan de acción que llevará a cabo el equipo de trabajo, especificando obligaciones y limitaciones

A-5. Definir métricas que permitan evaluar los modelos predictivos.

Figura 19 Variables comerciales

```
<class 'pandas.core.frame.DataFrame'>
Int64Index: 873247 entries, 0 to 873283
Data columns (total 12 columns):
#   Column          Non-Null Count  Dtype
---  -
0   id               873247 non-null  int64
1   fecha           873247 non-null  datetime64[ns]
2   cantidad        873247 non-null  float64
3   valor_u         873247 non-null  float64
4   id_articulos    873247 non-null  int64
5   descuento       873247 non-null  float64
6   articulos       873247 non-null  object
7   id_grupo        873247 non-null  int64
8   Grupo_Articulos 873247 non-null  object
9   venta           873247 non-null  float64
10  Años             873247 non-null  int64
11  Meses           873247 non-null  int64
dtypes: datetime64[ns](1), float64(4), int64(5), object(2)
memory usage: 118.9+ MB
```

Figura 20 Big data

	id	fecha	cantidad	valor_u	id_articulos	descuento	articulos	id_grupo	Grupo_Articulos	venta	Años	Meses
0	115017	2019-09-10 17:57:38	1.0	2.15	501	0.0	QUESO FLORES	4	Leches y Avenas	2.15	2019	9
1	115017	2019-09-10 17:57:38	1.0	0.95	416	0.0	MARGARINA GIRASOL*250G	5	Despensa	0.95	2019	9
2	174736	2020-02-11 10:28:53	1.0	0.50	606	0.0	TONI-GELATONI CHIQUI 120G	6	Snacks	0.50	2020	2
3	189992	2020-04-02 09:17:25	2.0	1.50	654	0.0	AC. ACEITE CRIOLLO 1LT	5	Despensa	3.00	2020	4
4	189992	2020-04-02 09:17:25	1.0	2.80	507	0.0	QUESO PICAFLOR	4	Leches y Avenas	2.80	2020	4

A-2. Sistematizar los objetivos del estudio:

1. Optimizar las ventas desarrollando mejores recomendaciones
2. Incrementar fidelización de los clientes con servicios postventa

A-3. Definir el equipo que ejecutará el proyecto:

Responsable de grupo: Es la persona encargada del proyecto, dirige todas las unidades y asigna responsables, se reúne con la gerencia del establecimiento a discutir todo lo relacionado al proyecto: alcance, objetivos, metas, fechas, etc.

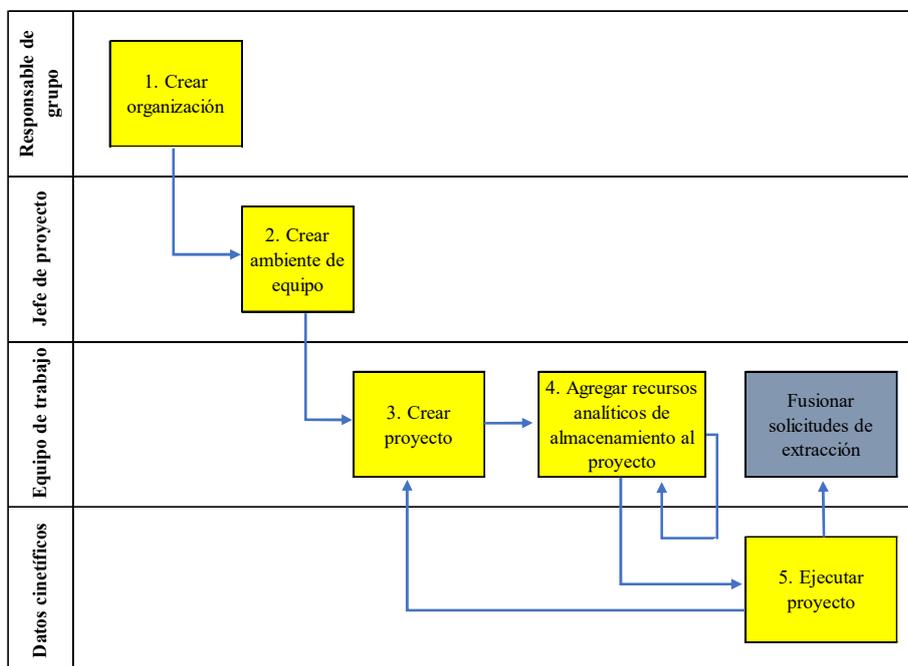
Jefe de proyecto: Dirige los avances semanales y diarios con los integrantes del proyecto, es el responsable de la calidad y del cumplimiento de los tiempos del proyecto.

Equipo de trabajo: Son colaboradores expertos en diferentes tipos de software y datos, tales como: Administradores de bases de datos, Arquitectos de datos, Desarrolladores, Ingeniero en datos, etc.

A-4. Elaborar un plan de acción que llevará a cabo el equipo de trabajo:

Todo el equipo de trabajo debe de tener claro sus funciones y los tiempos en los que estos deben ser realizados, las pruebas y los reportes que deben entregarse conforme a lo planificado, en la figura 21 se presenta detalle de un plan de trabajo

Figura 21 Plan de trabajo



A-5. Definir métricas que permitan evaluar los modelos predictivos

A continuación, se presentan las métricas que evaluaron los modelos predictivos:
`metrics=['mse','mae','mape']`

- b. **Comprensión de los datos:** Una vez interpretado perfectamente la línea del negocio y su funcionamiento, se recolecta la información necesaria, la misma que debe ser validada previo al cumplimiento de tareas tales como: recopilar datos, explorar datos y verificar si los datos cumplen los requerimientos necesarios, en este último proceso se utilizaron pruebas estadísticas mínimas, cuya finalidad fue conocer las especificaciones de los datos, dando como resultado un mejor entendimiento de los datos [41], como se presenta en la figura 22

Figura 22 Fases de la comprensión de datos



Autor: Espinoza Zúñiga (2020)

Recolección de datos: La recolección de información debe incluir parámetros que permitan identificar datos relevantes que permitan responder la sistematización en los objetivos del proyecto, esta fase se caracteriza por la necesidad de obtener los siguientes resultados:

- Se elaboró un conjunto de datos tabulados llamada también dataset, los mismos deben ser de alta calidad y deben guardar relación con los objetivos definidos.
- Se elaboró una arquitectura que permitió guiar los datos filtrados a una dataset de datos limpios.
- Se desarrolló el proceso de ruta a los datos, origen – destino en el cual se efectuó las operaciones de análisis.
- Se exploró los datos para establecer la calidad de los mismos
- Al estar aptos los datos, se continuó con el siguiente paso, que fue la comprensión de los datos correlacionados en patrones de comportamiento.
- Se configuró una canalización de información, que permite adquirir nuevos datos o actualizarlos de forma permanente.

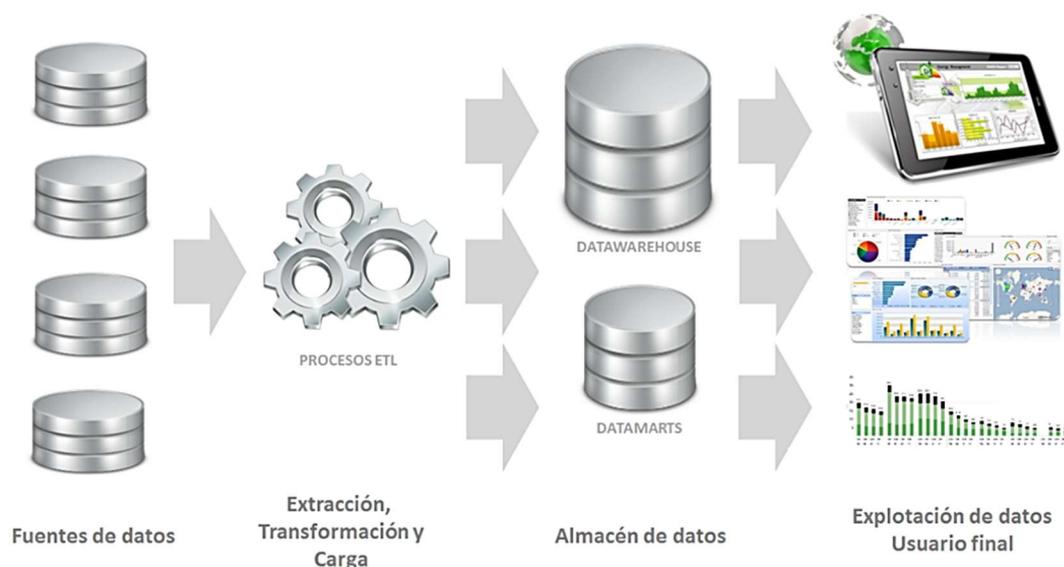
Los siguientes objetos se especifican en el presente análisis

Desarrollo de la arquitectura de sistema de información: Es el diseño de la estructura que permite guiar a través del modelo descriptivo, la manera que se ajustó la canalización de datos que estableció evaluaciones en nueva información de datos.

Ingesta de datos: En esta parte se ejecuta una consulta SQL en la base de datos de producción que fue migrada a un archivo CSV, la misma que se subió a la herramienta GoogleColab, donde realizamos el entorno para el análisis y desarrollar los modelos de CNN

Canalización de datos: Se definieron los pasos para construir de manera lógica un canal de datos que permita conseguir los datos de la base de producción y exportar dicha información a la ubicación de destino, donde se analizará la información, como se presenta en la figura 23

Figura 23 Canalización de datos



Calidad de datos: Se realizó la verificación respectiva de los datos obtenidos, en donde se encontró información con errores de codificación, lo que produjo se realice el estudio a la calidad de datos, los nodos de resultados permitieron detectar los siguientes conflictos:

- Datos con valores en cero (0, null, etc.)
- Errores de tipeo realizados al ingresar los datos
- La información que ha sido ingresada correctamente, sin embargo, las herramientas que se utilizaron fueron erradas
- Los datos ingresados sin criterios, como la asignación de diferentes atributos para un mismo campo.

Una vez realizada la exploración y verificación de datos se procede a realizar el respectivo informe que permitirá continuar a la siguiente fase

Elaboración de informe de calidad de datos: El desarrollo del informe considera resúmenes de la información, así como las relaciones existentes entre las propiedades o atributos.

- c. *Preparación de los datos:* Se trata de uno de los pasos más significativos y en el que se invirtió más tiempo dentro del proceso de minería de datos. La presente fase se relaciona con la etapa de modelado y en función a la misma las tareas que se efectuaron estas etapas se muestran en la figura 24.

Figura 24 Fases de preparación de datos



Autor: IBM (2021)

Selección de datos, donde se parametriza la inclusión o exclusión de los mismos, tales como datos repetidos. Limpieza de los datos, en el cual se emitió un nuevo reporte de calidad de los datos. Estructuración de datos, donde se generaron registros. Integración de datos, proceso que se unificó los datos obtenidos y finalmente el formateo de datos, en el cual se utilizó la técnica de reordenar campos [43].

- **Selección de elementos:** Se consideró los elementos como las cuentas, los artículos o principales clientes
- **Selección de atributos:** Considera las decisiones que se tomaron en función a las características de la actividad del negocio, como valores de las ventas, las unidades vendidas.

Se consideró de forma preliminar 800.000 ítems de la data, lo que llevó a configurar los filtros que excluyeron datos no informativos o relevantes

Limpieza de datos: La limpieza de datos involucró la revisión de los posibles problemas que se hayan filtrado al momento de seleccionarlos. Los principales problemas detectados son los errores en los datos y las incoherencias en los criterios de codificación. Para el primer caso se excluyó las características con un valor estimado y para el segundo caso se decidió una codificación simple que reemplace los datos incoherentes.

Estructuración de datos: Se estructuró nuevos datos, que se consideraron útiles por cada transacción, el campo artículos $DF = \text{articulosDF.drop}(['id','descuento'], \text{axis}=1)$ se generó manejando nodos

Integración de datos: Se utilizó dos métodos para gestionar la integración de datos, la fusión y la adición.

- **La fusión de datos:** Donde se unieron conjuntos de información que contenía registros similares con atributos diferentes, y;
- **La adición de dato:** Donde se unieron conjunto de datos con atributos semejantes cuyos registros son diferentes

Se ejecutó el proceso de limpieza de datos en esta fase para corregir los conflictos encontrados en el informe de calidad de datos que se realizó en la etapa anterior, tanto los errores de datos como los errores de medición. De igual forma, se realizó un registro de cada actividad de limpieza realizada con la finalidad de dejar constancia del detalle realizado

- d. **Modelado:** Los datos preparados se concentraron en un modelo o técnica de acuerdo al objetivo de la presente tesis, es decir, análisis apoyado en regresiones y redes neuronales, a continuación, se realizó un plan de ensayo o prueba cuyo propósito fue parametrizar los algoritmos fundamentado en el ML donde se estableció las métricas de valoración, como se ve en la figura 25.

Figura 25 Fases de modelado de datos



Autor: Espinoza Zúñiga (2020)

Posteriormente se desarrollaron los modelos sobre los datos preparados, es decir los que se construyeron en base a redes neuronales, para finalmente evaluar el resultado de dicho modelo, que no es otra cosa que descifrar los criterios de éxitos elaborados [41]. Para establecer el modelo se consideró el tipo y los objetivos de la minería de datos en función a la actividad del negocio.

Para efectuar la selección del modelo se muestra la conexión física abierta, esta conexión aprueba que el modelo seleccionado opere fácilmente desde herramientas de cálculos, sitios web y demás aplicaciones.

e. **Generación del modelo**

Se proponen 3 modelos de CNN con diferentes arquitecturas a nivel de capas convolucionales. Estos modelos emplean la clase Conv1D que es una capa de 1 dimensión, los hiper parámetros empleados por capa Conv1D son la cantidad de filtros, el tamaño del kernel y la función de activación

3.1.1.1. Modelo A

En la figura 26 se aprecia la arquitectura realizada para el modelo A, donde se utiliza una capa de inicio Conv1D seguida de 2 capas iguales, una capa de 1 dimensión MaxPooling1D con un pool_size de 2 minimiza el tamaño de la muestra de los datos que ingresan, también se incluye una capa Flatten que permite aplanar los datos de entrada para la siguiente capa Dense y finalmente otra capa de salida Dense, como se muestra en la figura 26.

Figura 26 Modelo A

```
f modelo_A(kernel, filtro):
    modeloA = Sequential()
    modeloA.add(Conv1D(filters=filtro, kernel_size=kernel, activation='relu', input_shape=(intervalo, 1)))
    modeloA.add(Conv1D(filters=filtro, kernel_size=kernel, activation='relu'))
    modeloA.add(Conv1D(filters=filtro, kernel_size=kernel, activation='relu'))
    modeloA.add(MaxPooling1D(pool_size=2))
    modeloA.add(Flatten())
    modeloA.add(Dense(100, activation='relu'))
    modeloA.add(Dense(1))
    return modeloA
```

3.1.1.2. Modelo B

En la figura 27 se aprecia la arquitectura realizada para el modelo B, donde se utiliza una capa de inicio Conv1D, una capa de 1 dimensión GlobalMaxPool1D la idea es minimizar el tamaño de la muestra de la misma forma que lo hace la MaxPooling1D, la siguiente capa Dense utiliza un activador 'linear' y finalmente otra capa de salida Dense, como se muestra en la figura 27.

Figura 27 Modelo B

```
def modelo_B(kernel, filtro):
    model = Sequential()
    model.add(Conv1D(filters=filtro, kernel_size=kernel, padding='same', activation='relu', input_shape=(intervalo, 1)))
    model.add(GlobalMaxPool1D())
    model.add(Dense(units=intervalo, activation='linear'))
    model.add(Dense(1))
    model.summary()
    return model
```

3.1.1.3. Modelo C

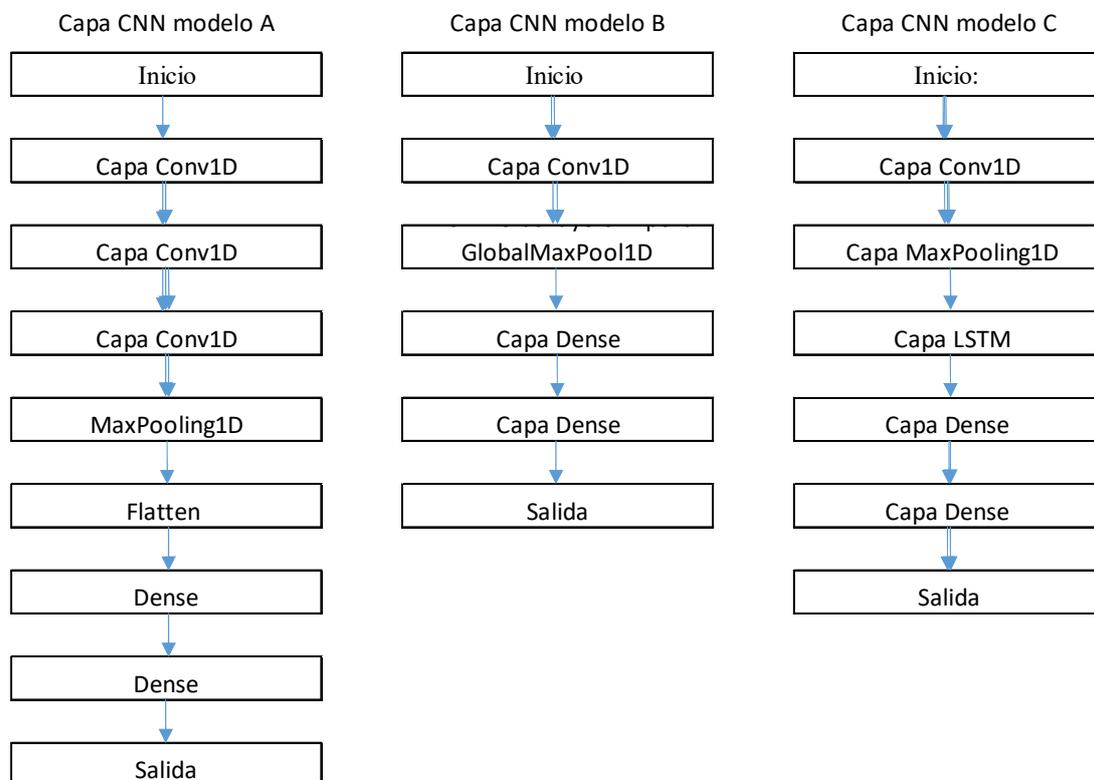
En la figura 28 se aprecia la arquitectura realizada para el modelo C, donde se utiliza una capa de inicio Conv1D igual que el modelo B, una capa de 1 dimensión MaxPooling1D con un pool_size de 2, una capa LSTM y finalmente 2 capas Dense, como se muestra en la figura 28

Figura 28 Modelo C

```
def modelo_C(kernel, filtro):  
    model = Sequential()  
    model.add(Conv1D(filters=filtro, kernel_size=kernel, padding='same', activation='relu', input_shape=(intervalo, 1)))  
    model.add(MaxPooling1D(pool_size=2))  
    model.add(LSTM(64))  
    model.add(Dense(units=filtro, activation='linear'))  
    model.add(Dense(1))  
    model.summary()  
    return model
```

Estos modelos conciernen a los datos del nodo central para el que se ejecuta la predicción en relación a nodos próximos. Por otro lado, la capa de salida crea un único valor que pertenece a la concentración de la minería de datos. De igual forma, las capas ocultas pertenecen a la capa Conv1D. Esta capa nivela la información de los datos de entrada. En la figura 29 se destacan los tres modelos de redes neuronales convolucionales en forma secuencial para visualizar a mayor detalle cada una de las capas que conforman los modelos.

Figura 29 Arquitectura CNN



- f. **Evaluación:** Una vez que se construyó el modelo de datos y que se determinó que el modelo es eficiente en relación a los criterios de rendimiento determinados, se evaluó los resultados considerando los criterios de éxitos preestablecidos, como se presenta en la figura 30. En esta fase se consideró los parámetros de fiabilidad calculada, luego se realizó una reingeniería de revisión a todo el proceso de evaluación, cuya finalidad fue localizar errores o mejorar elementos en el modelo construido. En esta fase se calificó de exitoso el modelo elaborado

Figura 30 Fases de evaluación de datos



Se desarrolló una bitácora de evaluación, manifestando los resultados obtenidos en la generación del modelo, siguiendo procesos básicos de indicadores comerciales, para lo cual se consideró una presentación amigable, haciendo énfasis en la información significativa y cotejando que los resultados encontrados se adapten a los objetivos comerciales del negocio.

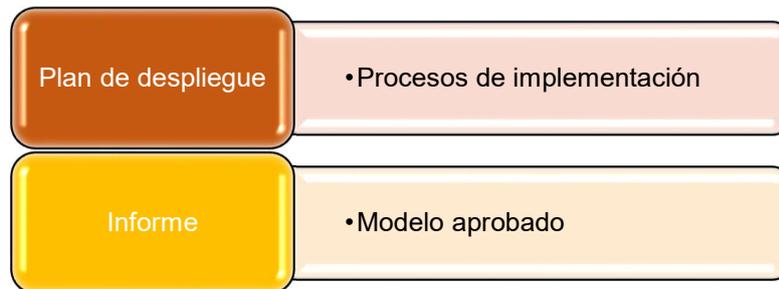
Los resultados del modelo A, en conjunto con el modelo B y el modelo C, permiten establecer los valores y los hiper parámetros estimados para cada modelo propuesto, en el cual se prueba la información obtenida, con la finalidad de analizar la capacidad de los modelos. El comportamiento de cada modelo se pone de manifiesto

Una característica importante de CRISP-DM es que permite instruirse con la información de minería de datos, lo que hace más eficiente sus resultados. Una de los procesos de revisión incluyó las interrelaciones entre la preparación de datos y los problemas y objetivos comerciales. Dentro de los procesos de revisión se mantuvo enfocado la comprensión comercial y la aplicación de los resultados derivados en la presente minería de datos

g. Despliegue

Se ejecutó un plan de despliegue al cliente que incluía el proceso de mantenimiento y monitoreo, lo que sirvió para detectar comportamientos irregulares que fueron subsanados. Se hace especial énfasis en el respaldo de lo actuado, así como se documentó cada proceso de la Metodología CRISP-DM, en la presente etapa debe continuar documentando los resultados obtenidos, cuya finalidad es aprender lecciones en el proceso de la implementación de la metodología Crisp-DM, donde finalmente se elevó un informe a la gerencia de la empresa, tal como se muestra en la figura 31

Figura 31 Fases de despliegue de datos



Se realizó un resumen general de los resultados y de los modelos, de igual forma se realizó una planificación para la ejecución del despliegue de datos. Toda la información debe llegar a los usuarios más importantes, como Gerente de la empresa, Junta General Y Administradores de Bases de Datos. Este informe, consideró las soluciones a los diversos problemas y objetivos empresariales, así como los elementos que incidieron en su selección.

3.2. Modelo propuesto

Se propone al modelo A como el modelo predictivo para este estudio. Su estructura se visualiza en la figura 32 el mismo que trabaja con los hiper parámetros de la propuesta como el activador, kernel, épocas, etc. La codificación de la arquitectura se muestra en la figura 34. Además, el modelo es elegido por los resultados de las 256 combinaciones. El código de la entrada o carga del dataset lo vemos en la figura 33 y para la visualización de la predicción en la figura 36.

Figura 32 Modelo propuesto

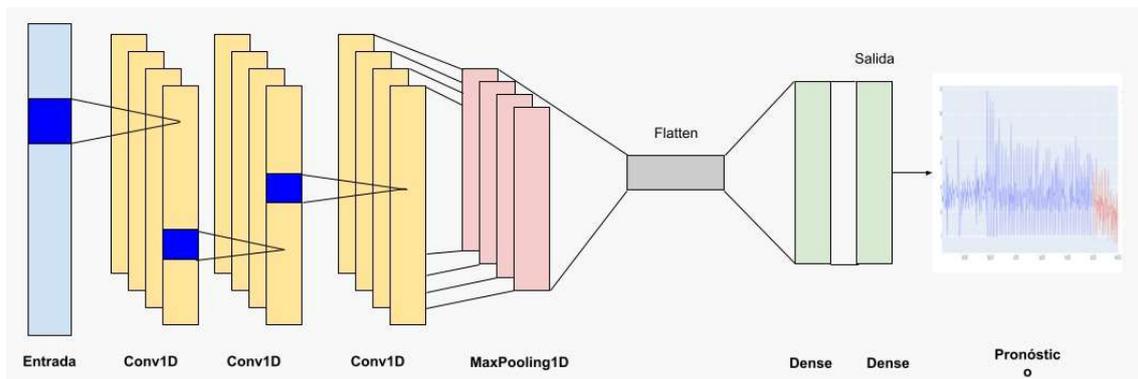


Figura 33 Función modelo A

```
filtroInt = 64; kernelInt=5; optimizadorStr='adam'; epocasInt=1000;
modelo1 = modelo A(kernelInt,filtroInt)
modelo1.compile(loss=lossStr,optimizer=optimizadorStr,metrics=metricsArr)
modelo1.summary()
historial = modelo1.fit(datosDeEntrada, datosDeSalida, epochs=epocasInt, batch_size=len(datosDeEntrada), verbose=2)
score1 = modelo1.evaluate(datosDeEntrada, datosDeSalida,batch_size=128)
```

Figura 34 Carga del dataset

```
#!/ls /content/gdrive/  
#carga el archivo cvs donde cada campo esta separado por un (;)  
data = pandas.read_csv('/content/gdrive/SharedDrives/CharlesCali/MegaSuCasa.csv', sep=';')  
#Se calcula el valor de venta segun la cantidad y el valor unitario  
data['ventas'] = round(data.cantidad * data.valor_u,2)  
#La columna fecha no tiene el tipo de dato fecha por lo se ajusta  
data['fecha'] = pandas.to_datetime(data['fecha'])  
#Declaro las nueva columnas AÑO y Meses partiendo de la fecha  
data['años'] = data['fecha'].dt.year  
data['meses'] = data['fecha'].dt.month  
#Solo vamos a trabajar con años del 2018 en adelante  
young_df_idx = data[data['años']<=2017].index  
data = data.drop(young_df_idx)  
data['años'] = pandas.to_numeric(data['años'])  
#Renombramos las columnas Articulos y grupos de articulos  
data.rename(columns = {'descripcion': 'Articulos', 'descripcion.1': 'Grupo_Articulos'})  
data.set_index(['fecha'], inplace=True) ##Se agrupan las ventas por la fecha  
dataSet = data['ventas'].resample('D').sum() #Realiza una sumatoria de ventas por dia  
dataFrame = pandas.DataFrame(dataSet)  
dataFrame.head()
```

Figura 35 Código para graficar la predicción

```
pred_list = []  
n_input = intervalo; n_features = 1;  
batch = dataSinProcesar[-n_input:].reshape((1, n_input, n_features))  
  
for i in range(n_input):  
    pred_list.append(modelo1.predict(batch)[0])  
    batch = numpy.append(batch[:,1:,:], [[pred_list[i]]], axis=1)  
  
add_dates = [dataFrame.index[-1] + DateOffset(days=x) for x in range(0,61) ]  
future_dates = pandas.DataFrame(index= add_dates[1:], columns=dataFrame.columns)  
df_predict = pandas.DataFrame(scaler.inverse_transform(pred_list), index=future_dates[-n_input:].index, columns=['Prediccion'])  
  
df_proj = pandas.concat([dataFrame, df_predict], axis=1)  
plot_data = [  
    go.Scatter(x=df_proj.index, y=df_proj['ventas'], name='actual'),  
    go.Scatter(x=df_proj.index, y=df_proj['Prediccion'], name='prediction')  
]  
  
plot_layout = go.Layout( title='Prediccion de ventas Modelo 1' )  
fig = go.Figure(data=plot_data, layout=plot_layout)  
pyoff.iplot(fig)
```

Capítulo 3

Presentación de resultados

En este capítulo se exponen los resultados obtenidos después de la ejecución de los modelos y sus variantes descritas previamente. En esta sección se detalla la presentación y discusión de los diferentes modelos y sus variantes, los mismos que fueron descritos en los capítulos precedentes, los resultados son analizados e interpretados con base en los modelos de predicción planteados con la finalidad de establecer y proponer el que generó mejores resultados.

Los presentes resultados se elaboran a fin de dar cumplimiento con el objetivo general del proyecto, esto es, desarrollar un modelo predictivo en las ventas de productos de primera necesidad en el sector comercial mediante la construcción de las redes neuronales convolucionales que permita la optimización de inventario, las que fueron objeto de pruebas que permitieron establecer en primera instancia datos exactos de las ventas las mismas que se describen a continuación.

Se determinó que el resultado de la hipótesis es afirmativo, al plantear la suposición, si se desarrolla un modelo predictivo de ventas de productos de primera necesidad basados en CNN se obtendrán resultados más precisos. Dicha validez se efectuó a través de 256 pruebas, del cual el segundo experimento se obtuvo los mejores resultados con 64 filtros y 5 kernels

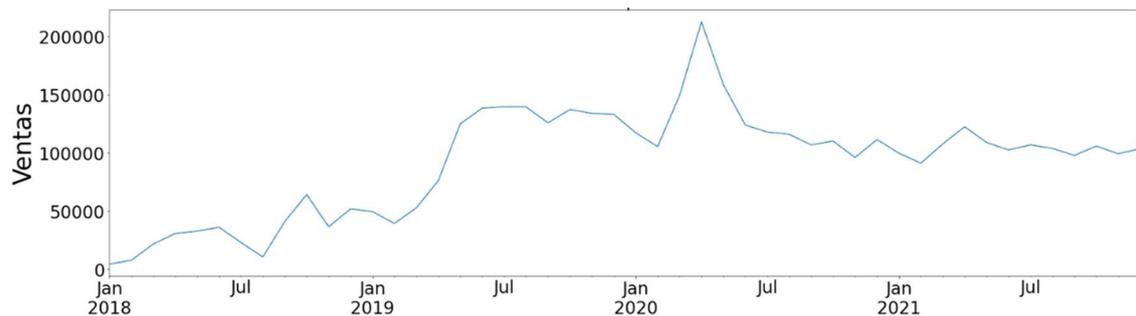
La figura 36 representa las ventas efectuadas desde el mes de enero del 2018 hasta el mes de diciembre del año 2021 en la empresa objeto de estudio, la cual representa los niveles de fluctuación en cada mes. La representación muestra regularidad en cada periodo, a excepción de algunos picos en el nivel de las ventas, presentando aumento o caída inusuales en las demandas de productos de primera necesidad, especialmente en el primer semestre del año 2020, año en que todos los indicadores o predicciones de ventas fallaron, debido a la llegada del COVID-19, virus desconocidos para todos hasta ese entonces.

Figura 36 Ventas mensuales en el periodo de 2018 a 2021



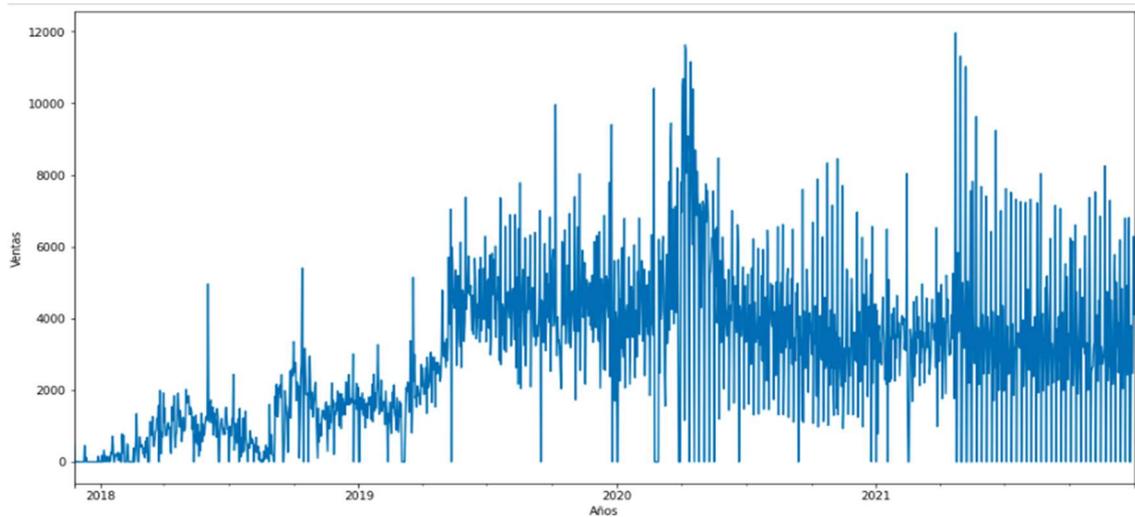
A continuación, se muestra una figura estadística en la figura 37, el cual representa las ventas mensuales en el periodo antes mencionado, dicha figura se diseñó con la herramienta google colab, la misma permite identificar los mismos niveles de fluctuación mencionados en la figura anterior

Figura 37 Ventas mensuales en el periodo de 2018 a 2021



De igual forma, se presentan las ventas en los periodos mencionados, con la salvedad, que la presentación es diaria, lo que manifiesta la sensibilidad en las fluctuaciones generadas y que se evidencian en la figura 38.

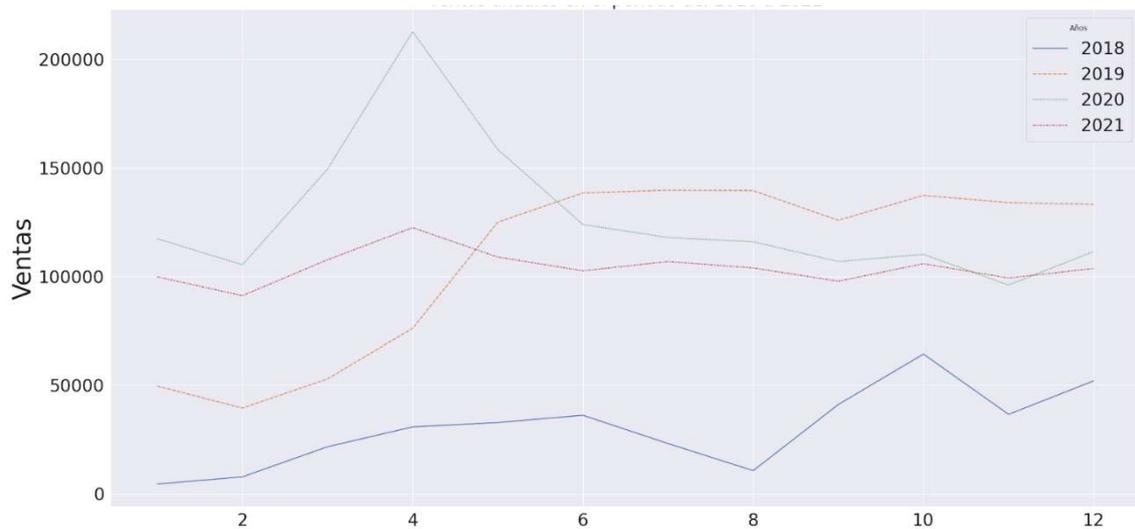
Figura 38 Ventas diarias en el periodo de 2018 a 2021



4.1. Estadística descriptiva de los datos

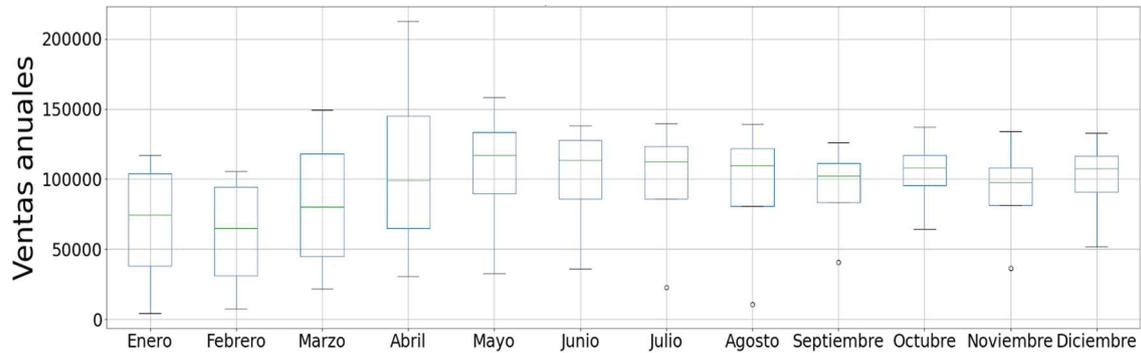
En la figura 39 se presenta las ventas efectuadas por cada mes de los años analizados, en el cual, se muestra las variaciones por mes de los diferentes años, como es el caso del mes de abril, el mismo establece un repunte de ventas en todos los años estudiados, siendo el año 2020 el que demuestra un incremento significativo en las ventas correspondiente en comparación a los años 2018, 2019 y 2021.

Figura 39 Ventas por años periodo de 2018 a 2021



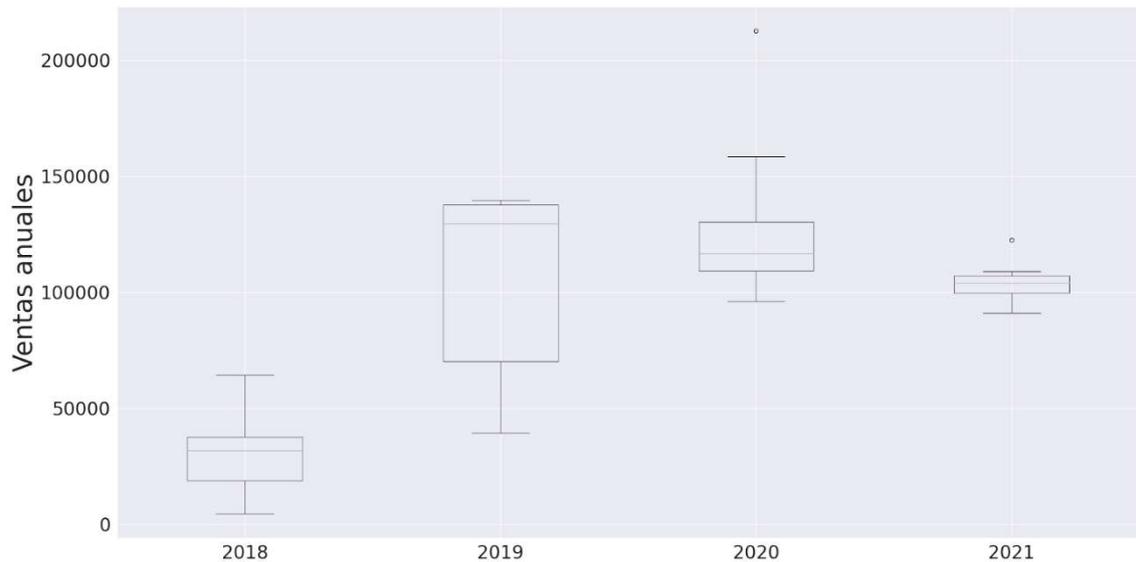
Por otro lado, se presentan los promedios de las ventas por cada mes de los años revisados, para lo cual se utilizó la herramienta desviación estándar, la figura 40 representa el valor máximo, mínimo y el promedio efectuado de cada mes por los años 2018-2021.

Figura 40 Promedios por cada mes del 2018 al 2021



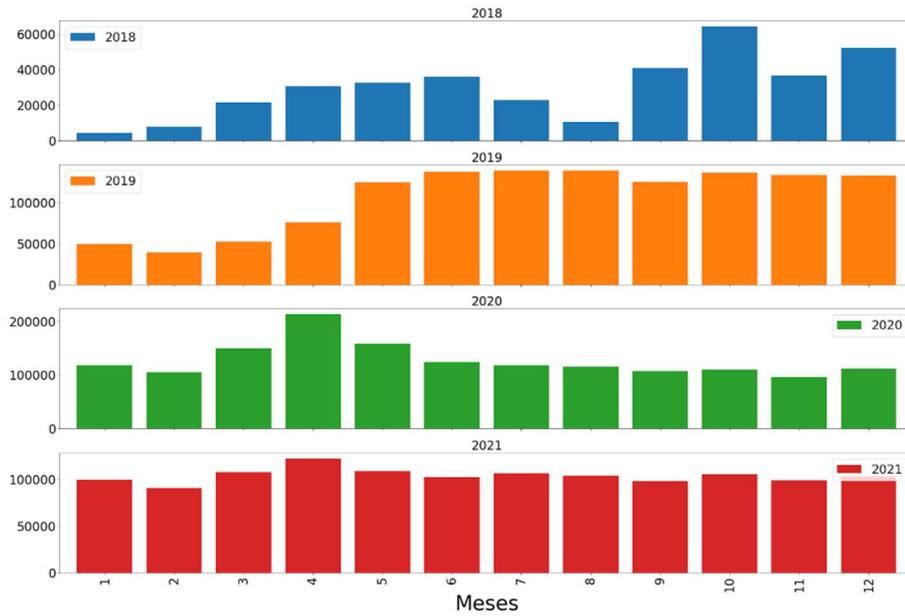
Así mismo, en la figura 41 representa el promedio de las ventas en cada año, evidenciando, que el año 2020 presentó un incremento por parte de los usuarios en las ventas del periodo comprendido entre 2018 y 2021.

Figura 41 Periodo del 2018 al 2021



Como parte del análisis al reporte de la big data, se presentan en figura de barra las fluctuaciones por cada mes y por cada año analizado, como se presenta en la figura 42.

Figura 42 Imagen de barras de las ventas periodo 2018 2021



Finalmente, se presentan las ventas realizadas de los diez artículos de primera necesidad más vendidos por la empresa, dichos productos son los más representativos para considerar al momento de ejecutar el pronóstico de ventas propuesto, ver figura 43.

Figura 43 Ventas top 10 en periodo 2018 - 2021

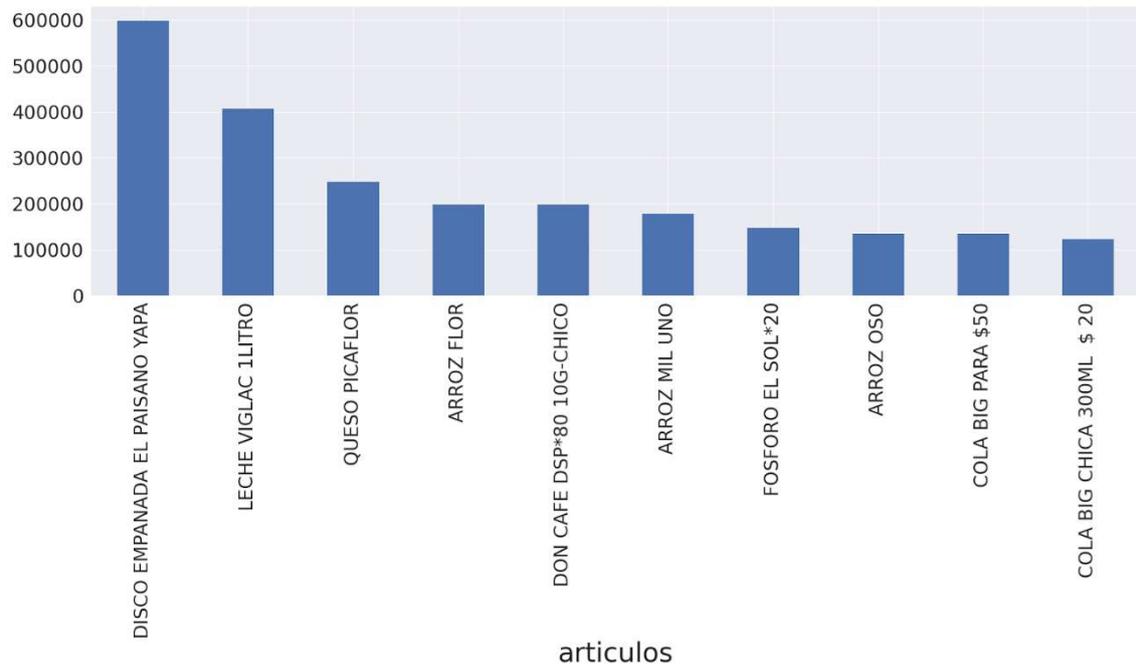
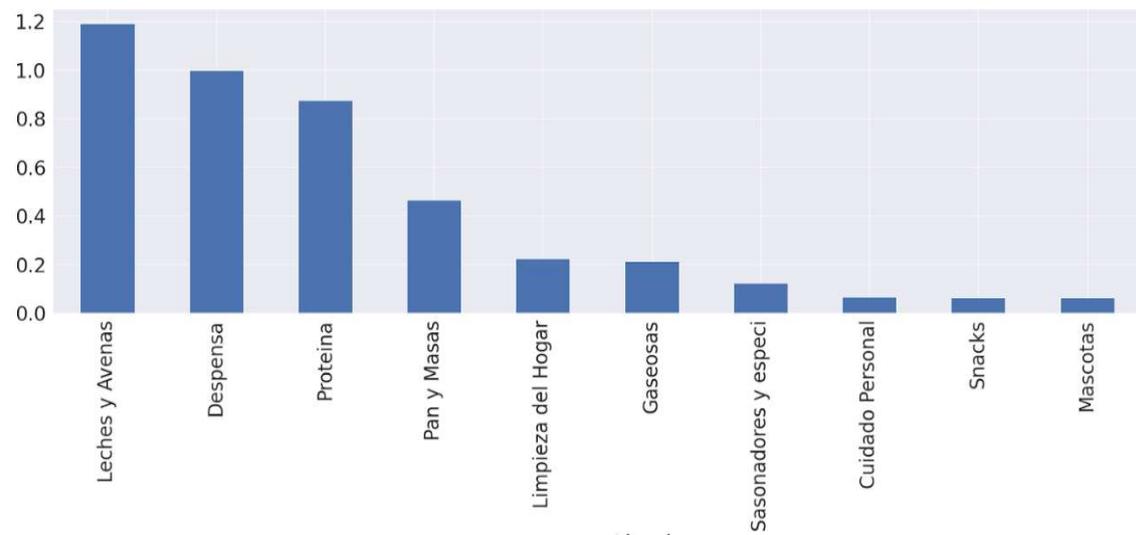


Figura 44 grupo de artículos



De igual forma, la figura precedente, señala las ventas por grupos de artículos más vendidos, este tipo de filtro se considera importante si se necesita determinar los ítems que más demanda tiene la empresa, como se visualiza en la figura 44.

Capítulo 4

Discusión de resultados

4.2. Diseño experimental

Se entrenaron 256 pruebas experimentales generadas a partir de los tres modelos basados en CNN, así como los hiper parámetros para la predicción de las ventas de productos de primera necesidad. Utilizando el lenguaje programación Python, y el uso de bibliotecas de código como Pandas para el tratamiento de los datos, Matplotlib para visualización de datos, Keras y TensorFlow para la implementación de modelos de DL. Dentro del desarrollo de la implementación, porciones de código fueron probados empleando Jupyter Notebooks⁷.

Los parámetros utilizados corresponden a la información descrita en el capítulo 3, dichos parámetros permitieron obtener los resultados generados por los modelos desarrollados. Los modelos se evaluaron según las métricas MSE, MAE y MAPE siendo estas métricas las más utilizadas en problemas de regresiones de ML [44]. El conjunto del dataset para el presente experimento contiene en total más de 800.000 registros los cuales se dividieron en un 80% para el entrenamiento y en 20% para realizar las evaluaciones.

4.2.1. Experimentación de los modelos de CNN

Utilizando los modelos A, B, C cada uno con su propia arquitectura, se procedió a entrenar cada modelo, cambiando los hiper parámetros y generando 256 combinaciones de evaluaciones, como se muestra en el anexo 1, donde se detalla los resultados de los experimentos científicos.

Para el experimento, se consideró los valores iniciales y los siguientes hiper parámetros:

- Filtros: 16 - 32 - 64 - 128
- Kernel: 2 - 3 - 5
- Activación: Relu
- Optimizador: Adam - RMSprop
- Épocas: 10 – 20 – 80 – 160 – 320 – 500 – 600 – 640 – 700 – 800 – 1.000

Se preparó el primer modelo CNN, el cual se compone de 3 capas convolucionales de 1 dimensión espacial (o temporal), 1 capa MaxPooling1D que reduce la muestra de la representación de entrada tomando el valor máximo sobre una ventana espacial, 1 capa Flatten para aplanar y no alterar el lote de los registros

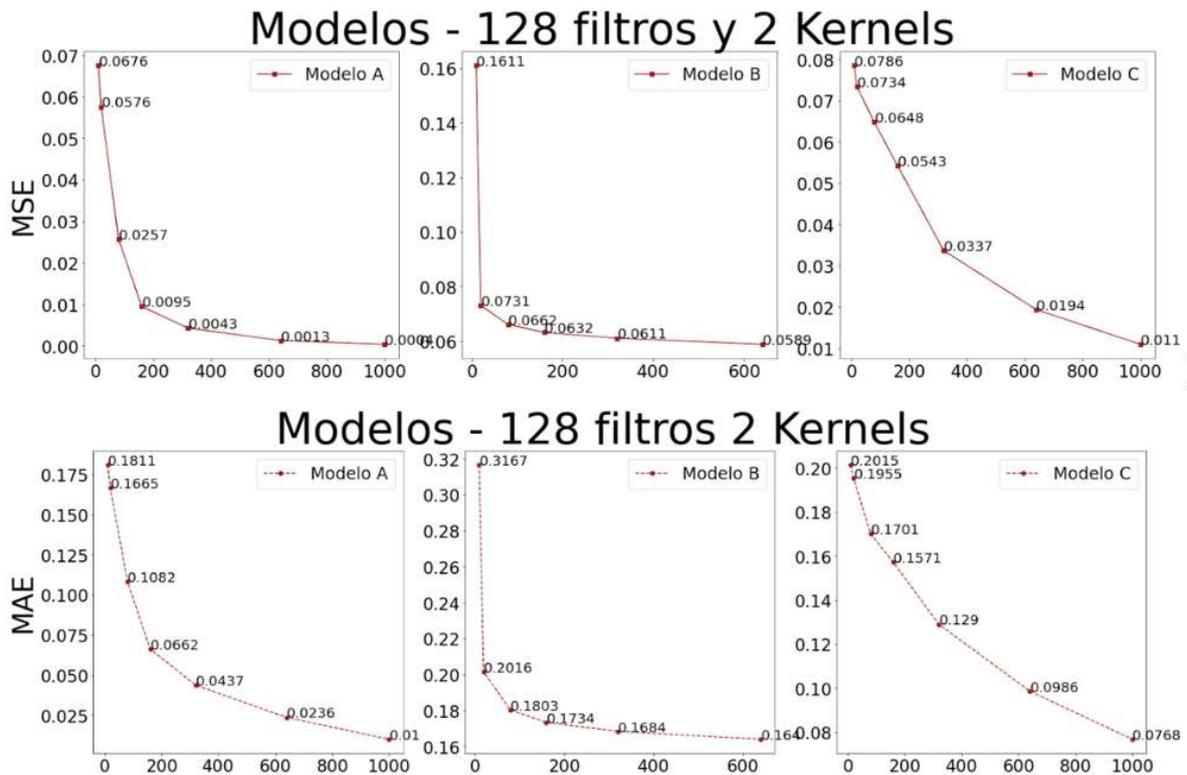
Filtros

Para evaluar el rendimiento respecto a la cantidad de filtros por capa, se realizaron pruebas con 16, 32, 64 y 128 filtros. Los resultados para las métricas MAE y MSE están disponibles en la Figura 45.

Tamaño del kernel

El segundo experimento corresponde a la evaluación del rendimiento respecto al tamaño del kernel, los resultados se presentan en la figura 45 Se prueban kernels de tamaño 2, 3 y 5 empleando 64 y 128 filtros. En las métricas MSE y MAE se obtienen mejores resultados con 64 filtros y 5 kernels.

Figura 45 Resultados de pruebas



Pruebas de pronóstico

En la Figura 46 se detalla los 6 mejores resultados dados por las métricas de MSE, MAE y el tiempo de ejecución, donde se visualiza que el modelo A, con 64 filtros, 5 Kernel, optimizador Adam y 1.000 épocas.

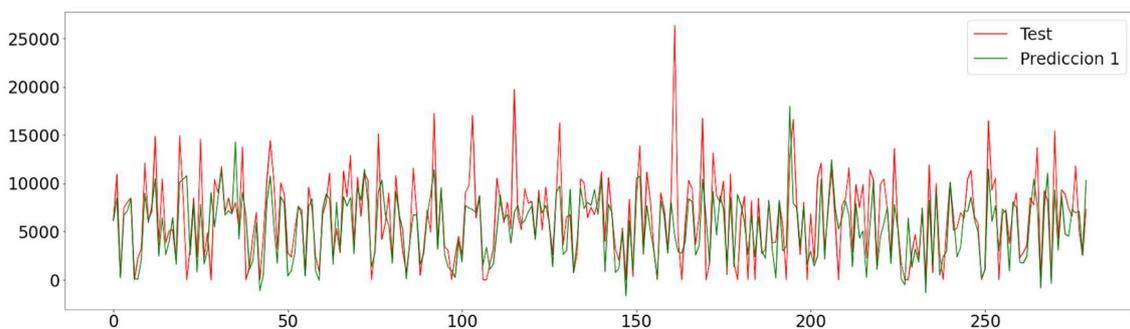
En el siguiente experimento evaluamos el rendimiento de los tres pronósticos versus los datos de test o de prueba. En la figura posterior, se puede visualizar que la predicción se ajusta en gran medida con la curva de pruebas de color verde.

Figura 46 Mejores resultados

Modelo	FILTRO	KERNEL	OPTIMIZADOR	EPOCAS	MSE	MAE	TIEMPO
A	64	5	adam	1000	0.000300	0.008900	443.403467
A	128	2	adam	1000	0.000400	0.010000	713.896828
A	128	3	adam	1000	0.000400	0.009100	922.723596
A	16	5	adam	800	0.002125	0.030015	0.069956
A	16	5	adam	700	0.002239	0.029565	0.066261
A	16	3	adam	600	0.003630	0.042776	0.069377

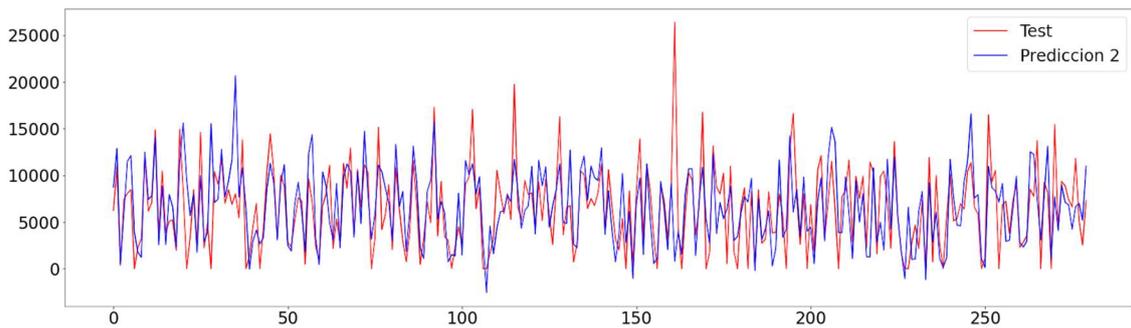
La predicción al utilizar un modelo con menos filtros y menos kernels podemos evidenciar visualmente que no se aleja de los resultados obtenidos en el primer experimento, como lo refleja la figura 47. El test arranca en la época 0 con valores de ventas de 10.000 dólares, mientras la predicción determina ventas de 8.000 aproximadamente en la misma época. Mientras que la época 250, el test presenta valores de ventas por 800 dólares, mientras que la primera predicción muestra ventas por 850 dólares.

Figura 47 Pruebas del primer pronóstico



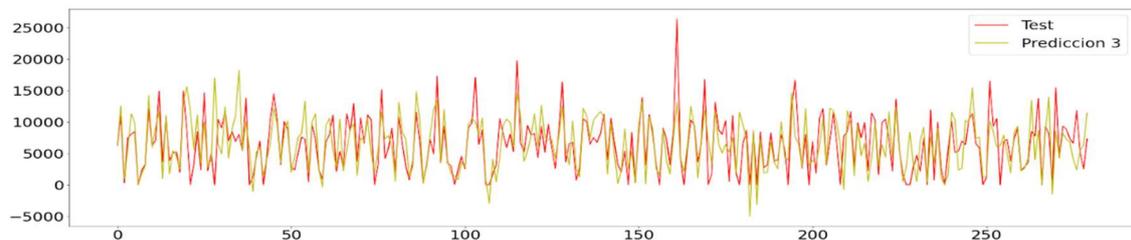
En la figura 48 se evidencia visualmente que no se aleja de los resultados obtenidos en el segundo experimento, El test empieza en la época 0 con valores de ventas de 11.000 dólares, mientras la predicción determina ventas de 12.500 aproximadamente. De igual forma, en la época 250, el test presenta un presenta valores de ventas por 11.000 dólares, mientras que la segunda predicción muestra ventas por 10.500 dólares.

Figura 48 Pruebas del segundo pronóstico



La figura 49 representa de forma visual que en la tercera ocasión se mostró una desviación significativa con relación a los 2 modelos anteriores. El test inicia en la época 0 con valores de ventas de 10.000 dólares, mientras la predicción determina ventas de 11.000 aproximadamente en la misma época. Mientras que la época 250, el test presenta un presenta valores de ventas por 4.000 dólares, mientras que la primera predicción muestra ventas por 5.000 dólares.

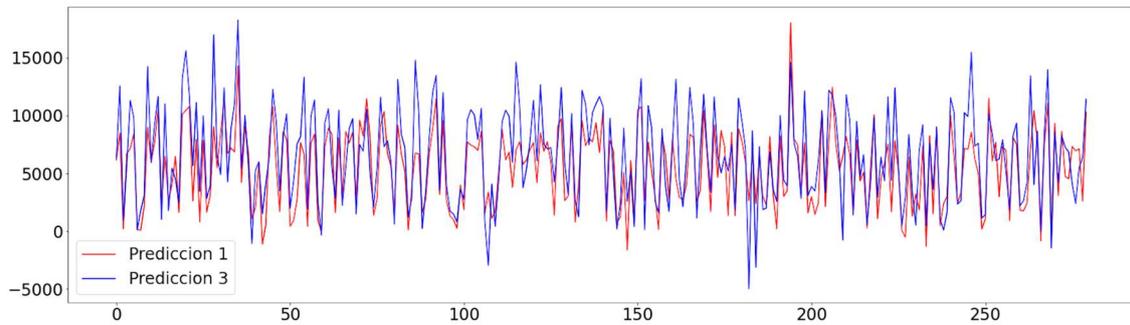
Figura 49 Pruebas del tercer pronóstico



En la figura 50 se compara las dos predicciones, la primera vs la tercera y visualmente la primera predicción se ajusta significativamente y se aleja de la tercera predicción de forma evidente. La comparativa arranca en la época 0 con valores de ventas de 7.000 dólares, mientras que el tercer resultado determina ventas de 11.000 aproximadamente en

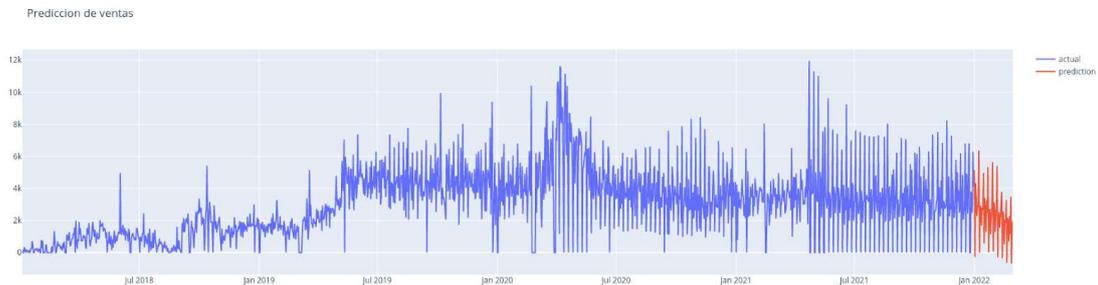
la misma época. Mientras que la época 250, el test presenta un presenta valores de ventas por 800 dólares, mientras que la primera predicción muestra ventas por 850 dólares.

Figura 50 Comparativa del primer y tercer resultado



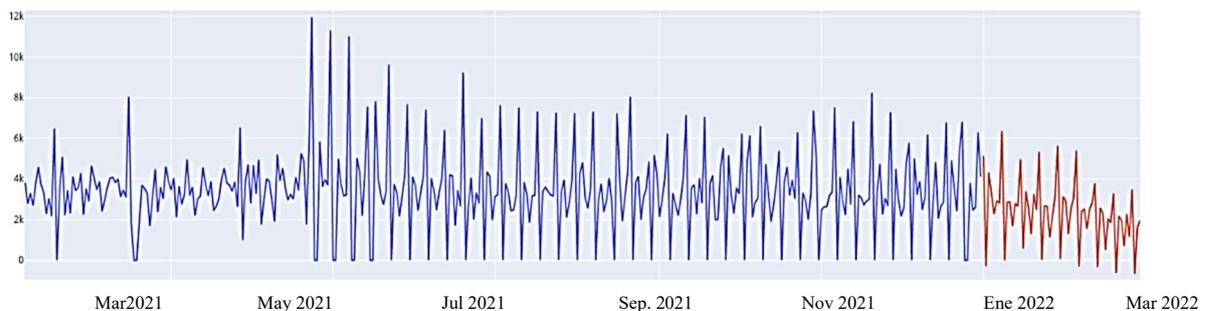
En la figura 51 se puede observar en color azul la data de ventas muestra que en la color rojo se aprecia la predicción en 2 meses adelantados. Es decir, el modelo predictivo, pronostica una tendencia a la baja en las ventas de los dos siguientes meses.

Figura 51 Predicción de ventas a 60 días



Mientras que la figura 52 se puede observar en color azul la data trimestral de ventas muestra que en la de color rojo se aprecia la predicción en 2 meses adelantados.

Figura 52 Predicción de ventas a 60 días maximizadas



CONCLUSIONES

De acuerdo al análisis realizado en el presente trabajo y una vez obtenido los resultados predictivos CNN, se detalla el cumplimiento o no de los objetivos específicos establecidos:

- Se investigó la técnica que permite construir modelos predictivos, para lo cual se utilizó las redes neuronales convolucionales, la cual fue descrita en el marco teórico con diferentes autores de artículos científicos de revistas indexadas y autorizadas por la universidad.
- Se recolectó datos históricos de ventas para identificar los indicadores claves y definir el grupo de datos que servirán para entrenamiento y testeo de la Red Neuronal Convolucional, estos datos corresponden a los movimientos operacionales compra y venta de los años 2018 a 2021
- Se implementó tres modelos de entrenamiento de la Red Neuronal Convolucional para la predicción de ventas, que sirvieron para determinar el modelo más preciso y eficiente para la organización. Dichos modelos se encuentran identificados en el presente proyecto como modelo A, B y modelo C
- Se evaluó el desempeño y propiedad de los modelos de predicción utilizados, dicha evaluación consistió en la verificación del error MAE y MSE.
- Se determinó que el resultado de la hipótesis es afirmativo, al plantear la suposición, si se desarrolla un modelo predictivo de ventas de productos de primera necesidad basados en CNN se obtendrán resultados más precisos.
- Para obtener el mejor modelo predictivo de las ventas, la red neuronal convolucional está construida utilizando 3 modelos, de los cuales se generaron 256 combinaciones, compuesto por 3 capas convolucionales, cuyas métricas MSE y MAE obtuvieron los mejores resultados con 64 filtros y 5 kernels, optimizador Adam y 1.000 épocas

Recomendación

Como parte final del presente estudio, se realizan recomendaciones que servirán como futuras líneas de investigación, a fin de perfeccionar los modelos experimentados a la luz de los resultados encontrados:

- Una manera adicional de mejorar los pronósticos, es añadiendo nuevos modelos, o los hiper parámetros como o robustez que permite tomar una mejor decisión en cuanto a los resultados proporcionados.
- En relación a los resultados, se recomienda establecer modelos predictivos de ventas que sirvan de manera general al sector comercial en productos de primera necesidad.
- La combinación de modelos de CNN con LSTM, XGBoost, etc. Proporciona opciones a contemplarse en la búsqueda de mejorar los resultados del presente trabajo.

Anexo 1 Resultados de los experimentos científicos

Modelo	FILTRO	KERNEL	OPTIMIZADOR	EPOCAS	MSE	MAE	TIEMPO
A	64	5	adam	1000	0.000300	0.008900	443.403467
A	128	2	adam	1000	0.000400	0.010000	713.896828
A	128	3	adam	1000	0.000400	0.009100	922.723596
A	16	3	adam	700	0.00235	0.026382	0.070003
A	128	3	adam	700	0.00094	0.015203	0.070524
A	128	5	adam	800	0.00074	0.022488	0.071183
A	64	3	adam	500	0.00225	0.025043	0.071276
A	64	5	adam	600	0.00143	0.022629	0.074090
A	16	5	adam	500	0.00350	0.041535	0.074228
B	64	3	adam	500	0.05857	0.165827	0.077531
A	16	5	adam	600	0.00298	0.032507	0.078086
B	128	3	adam	800	0.05399	0.160968	0.078469
B	16	3	adam	700	0.05802	0.16586	0.079758
B	16	5	adam	800	0.05939	0.165076	0.079820
B	64	3	adam	600	0.05795	0.165277	0.082268
B	16	5	adam	500	0.05554	0.16124	0.083472
A	64	5	adam	500	0.00211	0.026995	0.083745
B	16	5	adam	700	0.05799	0.164131	0.084905
B	128	3	adam	600	0.05774	0.165878	0.085054
B	64	5	adam	700	0.03849	0.13752	0.085419
B	128	5	adam	800	0.03821	0.137155	0.085557
B	64	5	adam	600	0.04978	0.152342	0.086014
B	128	5	adam	500	0.04051	0.138968	0.087581
A	128	5	adam	500	0.00231	0.02475	0.087794
A	64	5	adam	800	0.00086	0.01448	0.088028
A	16	3	adam	800	0.00201	0.025692	0.088412
A	128	5	adam	600	0.00203	0.03523	0.089107

B	64	5	adam	800	0.04019	0.139263	0.089440
A	64	5	adam	700	0.00149	0.031116	0.090336
B	64	5	adam	500	0.05020	0.153187	0.093400
A	128	3	adam	800	0.00061	0.01368	0.094189
A	128	5	adam	700	0.00049	0.01064	0.094324
B	128	5	adam	600	0.04217	0.141829	0.094695
A	64	3	adam	800	0.00073	0.01459	0.097742
A	64	3	adam	600	0.00160	0.022614	0.098494
B	128	5	adam	700	0.04440	0.143888	0.098838
A	128	3	adam	600	0.00122	0.020672	0.099806
B	16	5	adam	600	0.05736	0.16498	0.100521
A	64	3	adam	700	0.00131	0.01996	0.101123
A	128	3	adam	500	0.00131	0.022909	0.102726
B	128	3	adam	700	0.05474	0.161777	0.107076
B	128	3	adam	500	0.05702	0.164213	0.110525
B	64	3	adam	800	0.05403	0.160847	0.121104
B	64	3	adam	700	0.05845	0.166061	0.124335
A	16	3	adam	500	0.00324	0.038317	0.171781
B	16	3	adam	500	0.06152	0.16886	0.172168
B	16	3	adam	800	0.06034	0.166967	0.245248
B	16	3	adam	600	0.06240	0.168659	0.265312
C	16	5	adam	700	0.02675	0.115922	0.331869
C	64	5	adam	800	0.01598	0.090812	0.345886
C	128	3	adam	500	0.02193	0.107677	0.352015
C	128	5	adam	500	0.01970	0.102087	0.352195
C	64	3	adam	600	0.01883	0.098464	0.357005
C	128	3	adam	600	0.01729	0.096415	0.360973
C	16	5	adam	500	0.03884	0.139624	0.362928
C	16	5	adam	800	0.01992	0.101093	0.362980
C	64	5	adam	700	0.01705	0.094058	0.369383
C	16	3	adam	600	0.03695	0.136627	0.371649
C	128	5	adam	700	0.01481	0.089489	0.373710
C	64	5	adam	600	0.02145	0.106294	0.377707
C	64	3	adam	800	0.01449	0.089807	0.378110

C	128	5	adam	600	0.01568	0.090775	0.383287
C	16	3	adam	700	0.02979	0.124435	0.392026
C	16	5	adam	600	0.03161	0.127267	0.393048
C	64	3	adam	500	0.02620	0.117714	0.393827
C	128	3	adam	800	0.01576	0.091083	0.398725
C	16	3	adam	800	0.02456	0.112797	0.399298
C	128	3	adam	700	0.02449	0.120212	0.400365
C	64	5	adam	500	0.02631	0.120076	0.408677
C	128	5	adam	800	0.01172	0.080207	0.436503
C	16	3	adam	500	0.03323	0.13114	0.450103
C	64	3	adam	700	0.01873	0.10041	0.853951
B	16	5	adam	10	0.15010	0.3107	1.518351
B	16	2	RMSprop	10	0.17170	0.341	1.519848
B	32	3	adam	10	0.16110	0.3199	1.545317
B	32	2	adam	10	0.09140	0.2284	1.561838
B	32	5	adam	10	0.10660	0.2535	1.572996
B	16	3	RMSprop	10	0.07790	0.2129	1.580516
B	16	5	RMSprop	10	0.11550	0.2697	1.642745
B	64	2	adam	10	0.14170	0.2946	1.690322
B	32	3	RMSprop	10	0.10540	0.2553	1.702113
B	64	3	adam	10	0.12600	0.2792	1.735932
B	32	5	RMSprop	10	0.07610	0.206	1.755970
B	64	2	RMSprop	10	0.09190	0.2402	1.811007
B	64	3	RMSprop	10	0.07330	0.2049	1.835212
B	16	2	RMSprop	20	0.08300	0.2258	1.843243
B	64	5	adam	10	0.13740	0.2922	1.847597
B	16	3	adam	20	0.12160	0.2888	1.885860
B	16	5	adam	20	0.11750	0.2649	1.915231
B	16	3	RMSprop	20	0.07500	0.2033	1.975540
B	32	3	adam	20	0.08820	0.2336	2.025182
B	128	3	adam	10	0.09400	0.2411	2.037136
B	128	2	adam	10	0.16110	0.3167	2.043008
B	32	2	adam	20	0.08730	0.2318	2.052711
B	16	5	RMSprop	20	0.07650	0.2068	2.074529

A	16	3	adam	10	0.07330	0.202	2.135873
B	32	5	adam	20	0.07680	0.2068	2.163446
B	32	2	RMSprop	10	0.08680	0.2293	2.177266
B	128	5	RMSprop	10	0.07170	0.1991	2.190392
B	32	2	RMSprop	20	0.07110	0.196	2.197704
B	128	2	RMSprop	10	0.07460	0.2055	2.220977
B	32	5	RMSprop	20	0.07270	0.2027	2.227497
B	32	3	RMSprop	20	0.10700	0.2639	2.229053
A	16	5	adam	10	0.06500	0.1771	2.232986
B	128	3	RMSprop	10	0.07180	0.1992	2.265447
A	16	2	RMSprop	10	0.05760	0.1672	2.280968
B	64	2	adam	20	0.08470	0.2281	2.298332
B	64	5	adam	20	0.08680	0.2288	2.357020
A	16	3	RMSprop	10	0.06580	0.182	2.360811
A	16	5	RMSprop	10	0.06760	0.1832	2.412355
B	64	5	RMSprop	10	0.07840	0.2138	2.425275
B	64	3	adam	20	0.08240	0.2229	2.438695
B	64	2	RMSprop	20	0.06880	0.1908	2.484386
B	64	5	RMSprop	20	0.06880	0.1901	2.522389
B	16	3	adam	10	0.12160	0.2758	2.551446
B	64	3	RMSprop	20	0.08780	0.2247	2.573577
A	32	2	adam	10	0.07060	0.1949	2.589778
B	128	5	adam	10	0.06970	0.1862	2.591929
A	32	3	adam	10	0.07110	0.1987	2.690292
B	16	2	adam	20	0.10030	0.2526	2.882576
B	16	2	adam	10	0.09000	0.2366	2.896776
A	32	3	RMSprop	10	0.06790	0.1879	2.910334
A	16	2	adam	10	0.09020	0.2209	2.944357
B	128	3	adam	20	0.08620	0.2251	3.012088
A	16	3	adam	20	0.06650	0.1799	3.022008
B	128	2	adam	20	0.07310	0.2016	3.054398
A	32	5	adam	10	0.07350	0.2025	3.056476
A	32	2	RMSprop	10	0.07200	0.2042	3.103518
A	16	5	adam	20	0.07170	0.1999	3.179087

B	128	2	RMSprop	20	0.07050	0.1916	3.192541
B	128	3	RMSprop	20	0.08730	0.2234	3.210601
B	128	5	adam	20	0.07670	0.2004	3.218689
B	128	5	RMSprop	20	0.06850	0.1881	3.222156
A	16	3	RMSprop	20	0.05630	0.1749	3.316527
A	16	5	RMSprop	20	0.04650	0.1497	3.340232
A	32	5	RMSprop	10	0.06860	0.1939	3.346305
A	32	2	adam	20	0.06010	0.1698	3.918082
B	16	2	RMSprop	80	0.07040	0.1885	3.927009
A	64	2	adam	10	0.07850	0.2137	3.956708
C	16	3	adam	10	0.10550	0.252	4.110784
A	32	2	RMSprop	20	0.05790	0.1744	4.157691
A	64	2	RMSprop	10	0.06200	0.1721	4.227688
C	16	3	RMSprop	10	0.06960	0.1831	4.291681
B	16	3	adam	80	0.07050	0.1967	4.304817
C	32	3	adam	10	0.11510	0.273	4.320411
B	16	3	RMSprop	80	0.06380	0.1756	4.354641
C	16	2	RMSprop	10	0.07150	0.1863	4.357898
C	16	5	RMSprop	10	0.07310	0.2	4.382136
B	16	5	adam	80	0.06420	0.1751	4.386789
C	32	5	adam	10	0.09950	0.2386	4.412621
A	16	2	RMSprop	20	0.05880	0.1756	4.420761
A	32	3	RMSprop	20	0.06220	0.1912	4.483619
A	64	3	adam	10	0.07250	0.2009	4.572157
C	32	5	RMSprop	10	0.08030	0.203	4.579225
A	32	3	adam	20	0.06690	0.1787	4.654012
C	16	5	adam	10	0.10470	0.2419	4.693556
C	32	2	adam	10	0.10190	0.2452	4.703481
C	64	2	adam	10	0.11350	0.2555	4.778981
B	32	2	adam	80	0.07100	0.1954	4.844118
C	32	3	RMSprop	10	0.07060	0.1857	4.864837
A	32	5	adam	20	0.06330	0.1766	4.867300
A	64	3	RMSprop	10	0.06130	0.1736	4.881505
C	32	2	RMSprop	10	0.07800	0.2109	4.964591

B	32	3	RMSprop	80	0.06390	0.1749	5.002823
C	64	3	adam	10	0.08570	0.2106	5.009920
B	16	5	RMSprop	80	0.06520	0.1781	5.013776
B	32	2	RMSprop	80	0.06650	0.1799	5.092600
A	16	2	adam	20	0.08190	0.2208	5.096660
B	32	3	adam	80	0.06780	0.188	5.097174
A	32	5	RMSprop	20	0.05480	0.171	5.115240
B	32	5	RMSprop	80	0.06670	0.1818	5.123788
C	64	3	RMSprop	10	0.07040	0.1841	5.278283
C	16	2	adam	10	0.11280	0.2567	5.293291
C	64	2	RMSprop	10	0.07300	0.1908	5.336987
C	64	5	RMSprop	10	0.07190	0.1868	5.356398
C	64	5	adam	10	0.08590	0.2121	5.470006
B	32	5	adam	80	0.06770	0.1842	5.528737
B	16	2	adam	80	0.06820	0.1861	5.588526
C	16	3	adam	20	0.07110	0.1928	5.761566
C	16	5	adam	20	0.08410	0.2239	5.781741
A	64	5	adam	10	0.06660	0.1789	5.782876
C	16	2	RMSprop	20	0.06690	0.181	5.846786
A	64	5	RMSprop	10	0.06070	0.1709	6.016337
B	64	2	adam	80	0.06780	0.1823	6.098396
C	32	2	adam	20	0.08280	0.2218	6.136243
C	16	5	RMSprop	20	0.06440	0.1709	6.144366
C	16	3	RMSprop	20	0.07050	0.1864	6.164692
B	64	2	RMSprop	80	0.06690	0.1802	6.204426
B	64	3	adam	80	0.06710	0.1854	6.241457
C	32	5	adam	20	0.07330	0.1998	6.305734
C	32	3	RMSprop	20	0.06930	0.1832	6.309086
B	64	5	adam	80	0.06330	0.173	6.364034
C	32	2	RMSprop	20	0.07160	0.1942	6.419615
C	128	5	RMSprop	10	0.06530	0.1757	6.446311
C	32	3	adam	20	0.07410	0.2028	6.534310
B	64	5	RMSprop	80	0.06440	0.1777	6.600880
A	64	2	adam	20	0.06210	0.1757	6.641632

C	128	3	RMSprop	10	0.06690	0.1784	6.714511
C	128	3	adam	10	0.07660	0.1992	6.716533
C	128	5	adam	10	0.07770	0.2106	6.732341
B	64	3	RMSprop	80	0.06650	0.1826	6.761451
C	128	2	adam	10	0.07860	0.2015	6.785899
C	32	5	RMSprop	20	0.06950	0.1846	6.848349
A	64	2	RMSprop	20	0.05190	0.1563	6.923884
B	16	2	RMSprop	160	0.06480	0.1755	7.046603
C	64	2	RMSprop	20	0.07650	0.2054	7.063911
C	64	2	adam	20	0.07570	0.206	7.164088
C	64	5	adam	20	0.06820	0.1839	7.243675
C	128	2	RMSprop	10	0.07850	0.2102	7.292986
B	16	3	adam	160	0.06690	0.1832	7.468268
C	64	3	adam	20	0.07180	0.1961	7.495921
B	16	3	RMSprop	160	0.06430	0.1739	7.658064
B	16	5	adam	160	0.05940	0.1638	7.698925
C	64	5	RMSprop	20	0.06940	0.1833	7.835938
B	16	5	RMSprop	160	0.06150	0.1692	7.934615
A	64	3	adam	20	0.05580	0.1654	7.973728
A	16	2	RMSprop	80	0.03660	0.1313	8.004788
A	16	3	adam	80	0.03370	0.1221	8.338926
C	64	3	RMSprop	20	0.06830	0.1807	8.369642
A	64	3	RMSprop	20	0.05890	0.174	8.376671
B	32	2	adam	160	0.06480	0.1768	8.686715
A	16	3	RMSprop	80	0.03730	0.1453	8.718160
B	128	2	adam	80	0.06620	0.1803	8.737211
A	128	2	RMSprop	10	0.07070	0.1966	8.754203
B	32	2	RMSprop	160	0.06300	0.174	8.773120
B	32	3	adam	160	0.06320	0.1727	8.791450
B	128	2	RMSprop	80	0.06930	0.1846	8.808564
A	128	2	adam	10	0.06760	0.1811	8.913349
B	32	3	RMSprop	160	0.06240	0.1738	8.968752
B	32	5	adam	160	0.05850	0.1633	8.994781
B	128	3	RMSprop	80	0.06730	0.1823	9.041183

B	32	5	RMSprop	160	0.06050	0.1667	9.089342
B	128	5	RMSprop	80	0.06580	0.1812	9.200530
B	128	5	adam	80	0.06400	0.175	9.232793
C	16	2	adam	20	0.08330	0.2224	9.234730
B	128	3	adam	80	0.06440	0.1768	9.275815
C	128	5	RMSprop	20	0.07040	0.1914	9.356934
A	16	5	adam	80	0.03340	0.121	9.370924
C	128	5	adam	20	0.07100	0.1858	9.548800
A	16	5	RMSprop	80	0.04010	0.1405	9.576179
C	128	3	RMSprop	20	0.07050	0.1864	9.608596
A	64	5	adam	20	0.05520	0.1627	10.122167
C	128	2	adam	20	0.07340	0.1955	10.204129
C	128	2	RMSprop	20	0.10930	0.2647	10.530553
C	128	3	adam	20	0.06910	0.1878	10.729245
A	64	5	RMSprop	20	0.06170	0.1794	10.842529
A	128	3	adam	10	0.07310	0.1948	10.853647
A	128	3	RMSprop	10	0.07010	0.1934	10.988836
B	64	2	adam	160	0.06270	0.1719	11.020276
B	64	3	adam	160	0.06180	0.1694	11.225178
B	64	2	RMSprop	160	0.06400	0.1737	11.430703
B	64	3	RMSprop	160	0.06400	0.1775	11.558129
B	64	5	adam	160	0.05980	0.1661	11.761281
B	64	5	RMSprop	160	0.05990	0.1676	11.774237
A	32	2	adam	80	0.03350	0.1204	11.898997
A	32	2	RMSprop	80	0.03800	0.1376	12.252916
B	16	2	adam	160	0.07060	0.1927	12.531638
A	32	3	adam	80	0.02750	0.1119	13.345587
B	16	3	adam	320	0.06210	0.1694	13.883884
A	32	3	RMSprop	80	0.03520	0.1329	14.016733
B	16	3	RMSprop	320	0.06070	0.1681	14.263318
B	16	5	adam	320	0.05930	0.164	14.336687
B	16	5	RMSprop	320	0.05760	0.1642	14.485920
A	16	2	adam	80	0.03510	0.1244	14.573579
A	128	5	adam	10	0.06160	0.1698	14.695660

A	128	5	RMSprop	10	0.06760	0.1838	14.869489
C	16	3	RMSprop	80	0.06540	0.1764	14.919553
A	16	2	RMSprop	160	0.02910	0.1279	15.009021
B	16	2	adam	320	0.06450	0.1764	15.529407
C	16	3	adam	80	0.06370	0.1676	15.610363
A	16	3	adam	160	0.01610	0.0881	15.746489
C	16	5	RMSprop	80	0.06480	0.1753	15.827695
C	16	2	RMSprop	80	0.06680	0.1775	15.926852
A	16	3	RMSprop	160	0.02960	0.1289	15.927667
A	128	2	adam	20	0.05760	0.1665	16.017752
A	128	2	RMSprop	20	0.06000	0.1714	16.134957
A	32	5	adam	80	0.03190	0.1149	16.196146
C	16	5	adam	80	0.06310	0.1681	16.218149
B	128	2	RMSprop	160	0.06610	0.1777	16.297424
A	32	5	RMSprop	80	0.03820	0.1414	16.313069
B	32	2	RMSprop	320	0.06290	0.171	16.335839
B	128	2	adam	160	0.06320	0.1734	16.379741
B	128	3	adam	160	0.06100	0.168	16.407702
B	32	2	adam	320	0.06140	0.1687	16.457479
B	32	3	adam	320	0.06030	0.1658	16.676014
B	128	3	RMSprop	160	0.06420	0.1754	16.718246
C	32	2	adam	80	0.06560	0.1712	16.894047
B	128	5	RMSprop	160	0.06070	0.1707	16.932466
B	32	3	RMSprop	320	0.06100	0.1694	16.977976
C	32	3	adam	80	0.06460	0.1691	17.009946
B	32	5	adam	320	0.05650	0.1604	17.088508
C	32	3	RMSprop	80	0.06530	0.1748	17.132480
C	32	2	RMSprop	80	0.06670	0.1813	17.215615
B	128	5	adam	160	0.05620	0.1595	17.314305
C	32	5	RMSprop	80	0.06320	0.1737	17.334380
A	16	5	adam	160	0.01670	0.0881	17.406459
B	32	5	RMSprop	320	0.05790	0.1643	17.424188
A	16	5	RMSprop	160	0.02530	0.1195	17.647481
C	32	5	adam	80	0.06280	0.1673	18.321285

C	64	2	adam	80	0.06500	0.1704	19.601732
A	16	2	adam	160	0.01900	0.0939	19.663622
C	64	2	RMSprop	80	0.06390	0.1779	19.798378
B	16	5	adam	500	0.05554	0.16124	19.972510
A	128	3	adam	20	0.05610	0.1645	20.154315
A	128	3	RMSprop	20	0.06680	0.198	20.366983
C	64	3	adam	80	0.06390	0.1678	20.946378
C	64	3	RMSprop	80	0.06400	0.1752	20.998238
B	64	2	adam	320	0.06060	0.1665	21.130677
B	64	3	adam	320	0.05770	0.1627	21.402079
C	16	2	adam	80	0.06470	0.17	21.480070
C	64	5	RMSprop	80	0.06250	0.1716	21.573564
B	16	2	RMSprop	320	0.06690	0.1819	21.683730
B	64	3	RMSprop	320	0.06070	0.1689	21.705186
B	64	2	RMSprop	320	0.06300	0.1745	21.989636
B	64	5	adam	320	0.05130	0.1545	22.225590
B	64	5	RMSprop	320	0.05360	0.1584	22.537922
B	16	2	adam	640	0.06120	0.1689	22.669218
A	32	2	adam	160	0.01480	0.0831	22.739672
A	64	2	adam	80	0.03230	0.1181	22.932045
C	64	5	adam	80	0.06270	0.1665	22.956214
A	32	2	RMSprop	160	0.02700	0.1168	23.044769
A	64	2	RMSprop	80	0.03670	0.1482	23.318625
B	16	3	adam	700	0.05802	0.165857	24.183855
B	16	2	RMSprop	640	0.06190	0.1681	25.349841
A	32	3	adam	160	0.01500	0.0853	25.684425
A	32	3	RMSprop	160	0.02310	0.1125	25.889781
A	16	2	adam	320	0.00590	0.054	26.144706
B	16	3	adam	640	0.05890	0.1649	26.518859
C	16	2	adam	160	0.06370	0.169	27.026265
A	64	3	adam	80	0.02520	0.1053	27.639342
A	128	5	adam	20	0.05450	0.167	27.700533
A	16	2	RMSprop	320	0.01990	0.1045	27.730091
B	16	5	adam	640	0.05900	0.1638	27.863182

A	128	5	RMSprop	20	0.07860	0.2132	27.920136
B	16	5	RMSprop	640	0.05590	0.1613	27.957094
B	16	3	RMSprop	640	0.06040	0.1668	27.990200
C	16	2	RMSprop	160	0.05940	0.172	28.130161
C	128	5	adam	80	0.06310	0.1669	28.220779
A	64	3	RMSprop	80	0.03480	0.1454	28.250567
C	128	3	RMSprop	80	0.06440	0.1781	28.475943
C	16	5	adam	160	0.06250	0.1665	28.752713
C	128	5	RMSprop	80	0.06650	0.1847	28.983194
C	16	3	adam	160	0.06050	0.1635	29.158017
C	16	3	RMSprop	160	0.05890	0.1638	30.030194
A	16	3	adam	320	0.00630	0.0548	30.555280
A	32	5	adam	160	0.01430	0.0831	30.692178
C	16	5	RMSprop	160	0.06000	0.1666	30.699261
C	32	2	RMSprop	160	0.06460	0.1775	30.702537
A	16	3	RMSprop	320	0.01790	0.1007	31.148402
B	32	2	adam	640	0.06070	0.1671	31.152616
B	32	2	RMSprop	640	0.06070	0.1691	31.396031
C	32	5	adam	160	0.05750	0.16	31.447122
C	32	3	RMSprop	160	0.05590	0.1598	31.496521
A	32	5	RMSprop	160	0.02130	0.1079	31.504012
B	32	3	adam	640	0.05390	0.1594	31.645031
C	32	5	RMSprop	160	0.05620	0.1629	31.683963
B	128	2	RMSprop	320	0.06380	0.1731	31.703727
B	128	3	adam	320	0.05690	0.1619	31.755561
B	128	3	RMSprop	320	0.06180	0.1709	31.823002
C	32	3	adam	160	0.06010	0.1636	31.961118
B	128	2	adam	320	0.06110	0.1684	32.079540
C	32	2	adam	160	0.06110	0.1663	32.123183
B	32	3	RMSprop	640	0.05940	0.1697	32.273449
B	32	5	adam	640	0.04160	0.1414	32.603273
B	128	5	RMSprop	320	0.05500	0.162	32.715296
C	128	3	adam	80	0.06300	0.1662	33.068640
B	32	5	RMSprop	640	0.05020	0.1544	33.103794

B	128	5	adam	320	0.04210	0.1417	33.196515
C	128	2	adam	80	0.06480	0.1701	33.427009
C	128	2	RMSprop	80	0.06310	0.1756	33.535493
A	16	5	adam	320	0.00580	0.0518	33.591216
A	16	5	RMSprop	320	0.01470	0.092	33.777320
A	64	5	adam	80	0.02180	0.1001	36.389107
A	64	5	RMSprop	80	0.03740	0.1531	36.898508
C	64	2	adam	160	0.06040	0.1647	37.220668
C	64	2	RMSprop	160	0.05420	0.1575	37.374622
C	64	3	adam	160	0.05920	0.1613	38.773612
C	64	5	adam	160	0.05100	0.1531	39.233966
C	64	5	RMSprop	160	0.05570	0.1628	39.821763
B	64	2	adam	640	0.05820	0.1627	40.915817
C	64	3	RMSprop	160	0.05260	0.1627	40.969666
B	64	3	adam	640	0.05610	0.1621	41.624228
B	64	2	RMSprop	640	0.06080	0.1672	41.639703
B	64	3	RMSprop	640	0.05930	0.1668	41.791217
B	64	5	adam	640	0.04470	0.1438	43.017838
B	64	5	RMSprop	640	0.05400	0.1604	43.316700
A	32	2	adam	320	0.00420	0.0457	44.586321
A	32	2	RMSprop	320	0.01300	0.0888	44.587978
A	64	2	RMSprop	160	0.02360	0.1128	45.166732
A	32	3	adam	320	0.00560	0.0531	49.665866
A	32	3	RMSprop	320	0.01110	0.0811	50.106544
C	16	2	adam	320	0.04840	0.1496	51.635009
A	16	2	adam	640	0.00430	0.0524	52.488548
C	16	2	RMSprop	320	0.05110	0.1552	52.499831
A	64	3	adam	160	0.00820	0.0657	53.969005
C	128	5	RMSprop	160	0.04960	0.159	53.987722
A	16	2	RMSprop	640	0.00750	0.0674	54.213060
C	128	3	RMSprop	160	0.05320	0.1573	54.214958
C	16	3	RMSprop	320	0.04910	0.156	54.344662
A	64	3	RMSprop	160	0.02690	0.1311	55.288719
C	128	5	adam	160	0.05210	0.1533	55.977113

C	16	5	RMSprop	320	0.04520	0.1481	56.175435
C	16	3	adam	320	0.04780	0.1482	58.085226
C	128	2	RMSprop	160	0.05200	0.1546	58.141716
C	16	5	adam	320	0.05090	0.1527	58.446192
A	128	2	RMSprop	80	0.03810	0.1425	58.999092
C	32	2	adam	320	0.05280	0.1552	59.045166
A	16	3	RMSprop	640	0.00800	0.0701	59.122465
C	32	2	RMSprop	320	0.04380	0.1489	59.176832
A	128	2	adam	80	0.02570	0.1082	59.194534
A	16	3	adam	640	0.00300	0.0424	59.505939
A	32	5	adam	320	0.00490	0.0468	59.630704
C	32	3	RMSprop	320	0.03890	0.1343	59.836054
A	32	5	RMSprop	320	0.01270	0.0904	60.304006
C	32	5	adam	320	0.03940	0.1377	60.597913
C	32	5	RMSprop	320	0.03750	0.1337	61.433552
B	128	2	adam	640	0.05890	0.164	61.841449
B	128	2	RMSprop	640	0.06160	0.1717	62.247658
C	32	3	adam	320	0.05370	0.1559	62.316532
C	128	3	adam	160	0.05560	0.1568	62.398266
B	128	3	adam	640	0.05360	0.1584	62.472387
B	128	3	RMSprop	640	0.05910	0.1667	62.790440
B	128	5	RMSprop	640	0.04970	0.1551	62.984826
C	128	2	adam	160	0.05430	0.1571	64.374741
B	128	5	adam	640	0.03920	0.1367	64.582912
A	16	5	RMSprop	640	0.00730	0.0677	66.116085
A	16	5	adam	640	0.00280	0.0325	66.310886
A	16	5	adam	700	0.00224	0.029565	66.765940
C	64	2	adam	320	0.03870	0.1368	70.812264
C	64	2	RMSprop	320	0.04710	0.1466	71.173599
A	64	5	adam	160	0.00900	0.0652	71.786527
A	64	5	RMSprop	160	0.02460	0.123	72.052120
C	64	3	RMSprop	320	0.03840	0.1391	74.910336
A	128	3	adam	80	0.02110	0.0995	75.173947
C	64	5	adam	320	0.04010	0.1412	75.834457

A	128	3	RMSprop	80	0.03760	0.1435	76.345248
C	64	3	adam	320	0.04380	0.1449	77.781021
C	64	5	RMSprop	320	0.03270	0.1299	78.222732
A	64	2	adam	160	0.01230	0.0757	83.225216
A	16	2	adam	1000	0.00160	0.0219	83.259941
A	16	2	RMSprop	1000	0.00530	0.0581	84.557143
A	32	2	adam	640	0.00360	0.0437	86.687810
A	32	2	RMSprop	640	0.00590	0.062	86.788788
A	64	2	adam	320	0.00530	0.0537	89.102105
A	64	2	RMSprop	320	0.01260	0.0878	89.239877
A	16	3	adam	1000	0.00190	0.0226	91.237929
C	16	2	adam	640	0.03630	0.1296	97.714033
A	32	3	adam	640	0.00280	0.0374	98.834336
A	32	3	RMSprop	640	0.00510	0.059	99.286532
C	16	5	RMSprop	640	0.03320	0.1282	101.628484
C	16	3	adam	640	0.03090	0.1236	102.671919
A	16	5	adam	1000	0.00230	0.0299	103.109527
A	16	5	RMSprop	1000	0.00530	0.0582	103.191330
C	16	2	RMSprop	640	0.03450	0.1325	104.736123
C	128	5	adam	320	0.03030	0.1263	105.003361
A	128	5	adam	80	0.02170	0.1008	105.793854
A	128	5	RMSprop	80	0.03690	0.1397	106.155833
A	64	3	adam	320	0.00300	0.0346	106.659552
C	128	5	RMSprop	320	0.03250	0.129	106.758967
C	128	3	RMSprop	320	0.03920	0.1405	107.213813
A	64	3	RMSprop	320	0.01250	0.0905	108.310869
C	16	5	adam	640	0.02830	0.1174	110.029020
C	16	3	RMSprop	640	0.03390	0.131	112.082756
A	128	2	adam	160	0.00950	0.0662	115.218014
C	32	2	RMSprop	640	0.03040	0.1211	115.303922
C	32	3	adam	640	0.02620	0.12	116.724436
A	128	2	RMSprop	160	0.02200	0.1084	117.114332
C	128	2	RMSprop	320	0.04200	0.1443	117.842437
A	32	5	adam	640	0.00250	0.0311	117.876554

C	128	3	adam	320	0.03800	0.1368	117.963958
C	32	5	RMSprop	640	0.02820	0.1236	117.970935
C	32	2	adam	640	0.02560	0.1113	118.234854
C	32	3	RMSprop	640	0.02940	0.1215	118.272899
A	32	5	RMSprop	640	0.00490	0.0545	118.347116
C	128	2	adam	320	0.03370	0.129	118.801973
C	32	5	adam	640	0.02460	0.1112	121.451301
A	32	2	RMSprop	1000	0.00330	0.0466	135.912158
A	32	2	adam	1000	0.00150	0.019	135.948191
C	64	2	adam	640	0.02180	0.1039	139.069059
A	64	5	adam	320	0.00420	0.0475	141.821150
C	64	2	RMSprop	640	0.03190	0.1277	142.057319
A	64	5	RMSprop	320	0.00940	0.0771	142.181962
A	16	3	RMSprop	1000	0.00400	0.0501	143.398741
C	64	3	adam	640	0.02630	0.1135	145.452198
C	64	3	RMSprop	640	0.02620	0.1157	146.729144
C	64	5	RMSprop	640	0.03220	0.1373	147.771038
A	128	3	adam	160	0.00840	0.0646	149.664018
A	128	3	RMSprop	160	0.02090	0.1086	150.557481
A	32	3	adam	1000	0.00120	0.0245	154.499515
A	32	3	RMSprop	1000	0.00280	0.043	154.592790
C	16	2	adam	1000	0.01860	0.0981	157.492666
C	16	5	adam	1000	0.02160	0.1048	159.512097
C	16	2	RMSprop	1000	0.02880	0.1202	160.677951
C	64	5	adam	640	0.02030	0.0999	163.685142
C	16	5	RMSprop	1000	0.02190	0.1093	167.607507
C	16	3	RMSprop	1000	0.02710	0.1181	169.448025
C	16	3	adam	1000	0.01970	0.1004	172.982259
A	64	2	RMSprop	640	0.00690	0.0644	174.735308
A	64	2	adam	640	0.00190	0.0299	175.181567
C	32	2	RMSprop	1000	0.02410	0.1087	180.150197
C	32	3	RMSprop	1000	0.02330	0.1132	180.334322
C	32	3	adam	1000	0.02110	0.1026	181.479741
C	32	5	adam	1000	0.02000	0.0982	182.600628

A	32	5	RMSprop	1000	0.00190	0.0333	183.144737
A	32	5	adam	1000	0.00140	0.0189	183.382815
C	32	2	adam	1000	0.02130	0.1062	184.468198
C	32	5	RMSprop	1000	0.02150	0.1078	184.545128
C	128	3	adam	640	0.01680	0.0918	205.320485
C	128	5	adam	640	0.01910	0.1066	206.897770
C	128	3	RMSprop	640	0.02480	0.1143	208.475207
A	128	5	RMSprop	160	0.02550	0.1274	210.117673
A	128	5	adam	160	0.01010	0.0716	210.548195
A	64	3	RMSprop	640	0.00410	0.0507	215.183976
A	64	3	adam	640	0.00120	0.018	215.874795
C	64	2	adam	1000	0.01770	0.095	217.666086
C	128	5	RMSprop	640	0.01910	0.0995	220.475544
C	128	2	RMSprop	640	0.02800	0.1222	221.334013
C	64	3	adam	1000	0.01510	0.0873	222.771930
C	64	2	RMSprop	1000	0.02020	0.1014	224.957195
A	128	2	adam	320	0.00430	0.0437	228.939008
C	64	5	RMSprop	1000	0.01640	0.093	229.265299
A	128	2	RMSprop	320	0.00940	0.0762	229.987265
C	64	5	adam	1000	0.01470	0.0882	231.675866
C	128	2	adam	640	0.01940	0.0986	236.981629
C	64	3	RMSprop	1000	0.02230	0.107	248.564520
A	64	2	RMSprop	1000	0.00140	0.0308	271.086003
A	64	2	adam	1000	0.00080	0.0141	273.628440
A	64	5	RMSprop	640	0.00470	0.0546	281.548681
A	64	5	adam	640	0.00140	0.0203	283.440292
A	128	3	adam	320	0.00290	0.0357	298.640086
A	128	3	RMSprop	320	0.00980	0.0796	302.799932
C	128	3	adam	1000	0.01240	0.0819	316.971091
C	128	3	RMSprop	1000	0.01830	0.0974	320.286995
C	128	5	adam	1000	0.01560	0.0888	330.231303
C	128	5	RMSprop	1000	0.01530	0.0888	331.393289
A	64	3	RMSprop	1000	0.00310	0.0415	335.807636
A	64	3	adam	1000	0.00090	0.0144	337.045380

C	128	2	RMSprop	1000	0.02330	0.1183	370.343806
C	128	2	adam	1000	0.01100	0.0768	381.149600
A	128	5	RMSprop	320	0.00790	0.0687	416.233242
A	128	5	adam	320	0.00210	0.03	418.321927
A	64	5	RMSprop	1000	0.00130	0.0262	438.740692
A	16	5	adam	800	0.002125	0.030015	0.069956
A	128	2	adam	640	0.00130	0.0236	455.127037
A	128	2	RMSprop	640	0.00280	0.0409	458.823991
A	128	3	adam	640	0.00130	0.0234	592.043189
A	128	3	RMSprop	640	0.00260	0.0401	601.251720
A	128	2	RMSprop	1000	0.00250	0.0395	713.051874
A	16	5	adam	700	0.002239	0.029565	0.066261
A	128	5	adam	700	0.00049	0.010643	791.170118
A	128	5	RMSprop	640	0.00360	0.0423	829.828749
A	128	5	adam	640	0.00050	0.0115	836.573298
A	16	3	adam	600	0.003630	0.042776	0.069377
A	128	3	RMSprop	1000	0.00290	0.0433	932.806970
A	128	5	RMSprop	1000	0.00170	0.032	1296.613487
A	128	5	adam	1000	0.00200	0.0422	1298.036296