



UNIVERSIDAD CÉSAR VALLEJO

**FACULTAD DE INGENIERÍA Y ARQUITECTURA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS**

**Machine learning para la predicción en la gestión de inventario
dirigida a PYMES de venta de productos tecnológicos.**

TESIS PARA OBTENER EL TÍTULO PROFESIONAL DE:

Ingeniero de sistemas

AUTORES:

Flores Taquiri, Giuseppe Anthony (orcid.org/0009-0003-4911-2572)

Montalvo Celis, James Stiven (orcid.org/0000-0002-1250-9117)

ASESOR(A)(ES):

Mg. Quinteros Navarro, Dino Michael (orcid.org/0000-0001-8174-8771)

LÍNEA DE INVESTIGACIÓN:

Sistemas de Información y Comunicaciones

LÍNEA DE RESPONSABILIDAD SOCIAL UNIVERSITARIA:

Desarrollo económico, empleo y emprendimiento

LIMA – PERU

2024



Declaratoria de Autenticidad del Asesor

Yo, QUINTEROS NAVARRO DINO MICHAEL, docente de la FACULTAD DE INGENIERÍA Y ARQUITECTURA de la escuela profesional de INGENIERÍA DE SISTEMAS de la UNIVERSIDAD CÉSAR VALLEJO SAC - LIMA NORTE, asesor de Tesis titulada: "Machine learning para la predicción en la gestión de inventario dirigida a PYMES de venta de productos tecnológicos", cuyos autores son MONTALVO CELIS JAMES STIVEN, FLORES TAQUIRI GIUSSEPH ANTHONY, constato que la investigación tiene un índice de similitud de 17%, verificable en el reporte de originalidad del programa Turnitin, el cual ha sido realizado sin filtros, ni exclusiones.

He revisado dicho reporte y concluyo que cada una de las coincidencias detectadas no constituyen plagio. A mi leal saber y entender la Tesis cumple con todas las normas para el uso de citas y referencias establecidas por la Universidad César Vallejo.

En tal sentido, asumo la responsabilidad que corresponda ante cualquier falsedad, ocultamiento u omisión tanto de los documentos como de información aportada, por lo cual me someto a lo dispuesto en las normas académicas vigentes de la Universidad César Vallejo.

LIMA, 12 de Julio del 2024

Apellidos y Nombres del Asesor:	Firma
QUINTEROS NAVARRO DINO MICHAEL DNI: 41567782 ORCID: 0000-0001-8174-8771	Firmado electrónicamente por: DQUINTEROS el 12- 07-2024 15:22:29

Código documento Trilce: TRI - 0812197



UNIVERSIDAD CÉSAR VALLEJO

**FACULTAD DE INGENIERÍA Y ARQUITECTURA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS**

Declaratoria de Originalidad de los Autores

Nosotros, MONTALVO CELIS JAMES STIVEN, FLORES TAQUIRI GIUSSEPH ANTHONY estudiantes de la FACULTAD DE INGENIERÍA Y ARQUITECTURA de la escuela profesional de INGENIERÍA DE SISTEMAS de la UNIVERSIDAD CÉSAR VALLEJO SAC - LIMA NORTE, declaramos bajo juramento que todos los datos e información que acompañan la Tesis titulada: "Machine learning para la predicción en la gestión de inventario dirigida a PYMES de venta de productos tecnológicos", es de nuestra autoría, por lo tanto, declaramos que la Tesis:

1. No ha sido plagiada ni total, ni parcialmente.
2. Hemos mencionado todas las fuentes empleadas, identificando correctamente toda cita textual o de paráfrasis proveniente de otras fuentes.
3. No ha sido publicada, ni presentada anteriormente para la obtención de otro grado académico o título profesional.
4. Los datos presentados en los resultados no han sido falseados, ni duplicados, ni copiados.

En tal sentido asumimos la responsabilidad que corresponda ante cualquier falsedad, ocultamiento u omisión tanto de los documentos como de la información aportada, por lo cual nos sometemos a lo dispuesto en las normas académicas vigentes de la Universidad César Vallejo.

Nombres y Apellidos	Firma
GIUSSEPH ANTHONY FLORES TAQUIRI DNI: 48039011 ORCID: 0009-0003-4911-2572	Firmado electrónicamente por: GFLORESTA el 12-07- 2024 15:45:25
JAMES STIVEN MONTALVO CELIS DNI: 45509704 ORCID: 0000-0002-1250-9117	Firmado electrónicamente por: JMONTALVOCE el 12- 07-2024 20:11:32

Código documento Trilce: TRI - 0812198



Dedicatoria

A mis abuelitos, Candelaria, Carmen y Augusto por brindarme su amor, sabiduría y apoyo incondicional desde siempre.

A mis padres, Abdon y Esther, por ser motivación de superación para cumplir con todas mis metas

Ustedes son los más valioso que tengo y son mi inspiración para seguir adelante.

Anthony

A mis padres Flor de María y James por sus consejos, apoyo incondicional y su anhelo de verme triunfar.

A mi abuelita Vilma, por su paciencia y comprensión para seguir creciendo profesionalmente.

James

Agradecimiento

A mi asesor Mg. Quinteros Navarro Dino Michael por su orientación y comprensión durante todas las asesorías.

A mi jefe Garcia Alvarado Cesar por ser darme su apoyo incondicional.

Anthony

Al MG. Quinteros Navarro Dino Michael por su loable tarea de inculcarnos y darnos la asesoría necesaria para cumplir nuestros objetivos.

A mi tía Jenny por sus consejos e inspiración.

James

Índice de contenidos

Carátula.....	i
Declaratoria de autenticidad del asesor	ii
Declaratoria de originalidad del/os autor/es	iii
Dedicatoria	iv
Agradecimiento	v
Índice de contenidos	vi
Índice de Tablas.....	vii
Índice de figuras.....	viii
Resumen.....	ix
Abstract	x
I. INTRODUCCIÓN	1
I. METODOLOGÍA	10
III. RESULTADOS.....	20
IV. DISCUSIÓN	32
V. CONCLUSIONES.....	36
VI. RECOMENDACIONES	37
REFERENCIAS.....	38
ANEXOS	43

Índice de Tablas

Tabla 1 Relación entre variables.....	11
Tabla 2 Recolección de datos.....	15
Tabla 3 Niveles de confiabilidad.....	15
Tabla 4 Prueba de normalidad del primer indicador.....	16
Tabla 5 Prueba de normalidad del segundo indicador.....	16
Tabla 6 Correlación de Spearman del primer indicador.....	17
Tabla 7 Correlación de Spearman del segundo indicador.....	17
Tabla 8 Resultados descriptivos del índice de rotación antes y después.....	20
Tabla 9 Resultados descriptivos del índice de duración antes y después.....	21
Tabla 10 Prueba de normalidad del índice de rotación pretest y posttest.....	22
Tabla 11 La prueba de normalidad del índice de duración pre-test y post-test.....	23
Tabla 12 Rangos de la prueba de Wilcoxon para el índice de rotación.....	26
Tabla 13 Resultado de la prueba de Wilcoxon para el índice de rotación.....	27
Tabla 14 Rangos de prueba de Wilcoxon para el índice de duración.....	30
Tabla 15 Resultado de la prueba de Wilcoxon para el índice de duración.....	30
Tabla 16 Matriz de Operacionalización de Variables.....	43
Tabla 17 Operacionalización de variables.....	45
Tabla 18 Plan del Proyecto.....	73
Tabla 19 Data del Mes de Julio.....	77

Índice de figuras

Figura 1 Procedimientos del proyecto	18
Figura 2 Nivel de rotación de inventario antes y después	20
Figura 3 Nivel de rotación de inventario antes y después	21
Figura 4 Prueba de normalidad del índice de rotación en el antes	22
Figura 5 Prueba de normalidad del índice de rotación en el después.....	23
Figura 6 Prueba de normalidad de índice de duración de inventario antes.....	24
Figura 7 Prueba de normalidad de índice de duración de inventario	24
Figura 8 Índice de rotación de inventario (Pre-Test)	25
Figura 9 Índice de rotación de inventario (Post-Test).....	26
Figura 10 Prueba de Wilcoxon del índice de rotación	27
Figura 11 Índice de duración de inventario (PreTest)	29
Figura 12 Índice de duración (PostTest)	29
Figura 13 Prueba de Wilcoxon del índice de duración	31
Figura 14 Esquema de la base de datos.....	76
Figura 15 Importación de librerías.....	81
Figura 16 Acceso a la data.....	81
Figura 17 Obtención de información para la predicción	82
Figura 18 Aplicación del modelamiento de regresión lineal	82
Figura 19 Aplicación del modelamiento de random forest.....	83
Figura 20 Aplicación del modelamiento de gradient boosting	83
Figura 21 Lógica para impresión.....	84
Figura 22 Impresión para los gráficos	84
Figura 23 Resultados de correlación de tiempo con IRI e IDI	85
Figura 24 Todas las variables vs columna secuencial del tiempo	86
Figura 25 Dashboard del IRI - Histórico	89
Figura 26 Dashboard del IDI - Histórico	90
Figura 27 Dashboard del IRI - Proyectado	90
Figura 28 Lista del IRI proyectado de mayor y baja probabilidad.....	91
Figura 29 Dashboard del IDI - Proyectado	91
Figura 30 Lista del IDI proyectado de mayor y baja duración	92

Resumen

El estudio ha permitido conocer resultados sobre la influencia que tiene un sistema basado en machine learning en la predicción de gestión de inventarios, los cuales son dirigidas a las PYMES de venta de productos tecnológicos. Asimismo, se tiene la contribución para impulsar la innovación, mejorar métricas de eficiencia para la gestión y apoyar el desarrollo de las pequeñas empresas. La investigación fue de tipo aplicada y como población se tomaron los 64 productos que tenía inventariado la empresa del caso de estudio. Para el desarrollo del sistema se realizó mediante CRISP-DM, cuya metodología es idónea para el contexto específico de las empresas. Adicionalmente a ello, se realizó la comparación de tres algoritmos que tuvieron mayor precisión en el entrenamiento de modelos de predicción basados en las investigaciones previas halladas, en este caso se compararon los algoritmos de regresión lineal, árbol aleatorio y mejora gradual, estos fueron evaluados utilizando los datos requeridos de duración y rotación de los inventarios. El algoritmo de mejora gradual fue el que obtuvo mejores resultados con el coeficiente de determinación (R^2) y menores errores cuadráticos medios (MSE). Al aplicar el sistema de predicción con el modelo de mejora gradual la empresa pudo tomar mejores decisiones en el manejo del inventario la cual se vio reflejada con la mejora de la rotación y la disminución de la duración del inventario. Finalmente, se precisa que machine learning influyó positivamente en la mejora de la gestión del inventario.

Palabras Clave: Inteligencia artificial, gestión, inventario, algoritmo, Sistema informático.

Abstract

The study has provided results on the influence that a system based on machine learning has on inventory management prediction, which are aimed at SMEs that sell technological products. Likewise, there is a contribution to promoting innovation, improving efficiency metrics for management and supporting the development of small businesses. The research was of an applied type and the 64 products that the case study company had inventoried were taken as the population. The development of the system was carried out using CRISP-DM, whose methodology is suitable for the specific context of companies. In addition to this, a comparison was made of three algorithms that had greater precision in training prediction models based on previous research found, in this case the linear regression, random tree and gradual improvement algorithms were compared, these were evaluated using the required inventory duration and rotation data. The gradual improvement algorithm was the one that obtained the best results with the coefficient of determination (R^2) and lower mean squared errors (MSE). By applying the prediction system with the gradual improvement model, the company was able to make better decisions in inventory management, which was reflected in the improvement of turnover and the decrease in inventory duration. Finally, it is specified that machine learning had a positive influence on the improvement of inventory management.

Keywords: Artificial intelligence, management, inventory, algorithm, computer system

I. INTRODUCCIÓN

Los sistemas de gestión de inventario conforman una forma determinante de las estrategias y operaciones de una PYME, llevando a cabo los registros de las actividades productivas y comerciales; permitiendo supervisar tanto las entradas como las salidas de un almacén. Por ello, debe de mantenerse en un estado de control que impida el sobreabastecimiento de productos tecnológicos y de no quedarse con productos obsoletos, ocasionando pérdidas económicas para las mismas.

Al respecto Farlkner et al. (2022) precisan que el aprendizaje automático es una herramienta con importancia para la automatización empresarial, permitiendo el aprendizaje en base a los datos para la toma de decisión, los cuales se traducen desde patrones y algoritmos. Asimismo, permite el procesamiento rápido y preciso de datos considerables, facilitando el análisis, identificación de patrones y tendencias. Reduciendo los errores humanos, garantizando una mayor precisión y por ende una mejor toma de decisión.

Con ello, a nivel internacional, el sector Industrial ha registrado un crecimiento exponencial durante la actual década, fundamentalmente en los ámbitos de producción, logística, servicios y productos. El machine learning puede contribuir en las áreas de la educación, los bienes y el sistema de distribución. Además, se espera un aumento significativo en las soluciones basadas en dicha tecnología, con una tasa de incremento del 44,1%, lo que representa un aumento de 7.400 millones de dólares entre 2019 y 2024. (Gardas y Narwane, 2024, p. 3)

En relación con lo mencionado, las compañías que adoptan estrategias guiadas por las necesidades pueden disminuir sus costos de almacenamiento entre un 15% y un 30% y mejorar la puntualidad en la existencia de productos en el mismo rango porcentual.” (Wang, Chien y Trappey, 2021, p. 1)

En América latina, los autores Dini et al. (2021) indican que 14 de 33 países de América Latina y el Caribe tienen niveles ínfimos de uso con ML. En el sector empresarial las gestiones de inventario se ven afectadas por la acumulación y estancamiento de algunos materiales en inventario por la falta de rotación de algunos productos (Hamed y Jawad, 2023).

A nivel local, la empresa Group Alcántara, ubicada en la Av. Tacna N°572, Cercado de Lima, departamento de Lima, está dedicada a la comercialización de artículos tecnológicos, por lo que en su almacén central se guardan todos los productos, para luego distribuirlo a otras ubicaciones y/o ser enviados directamente a los clientes. En la reunión agendada con la gerente general Nathaly (Anexo 01), indica ha observado que una parte significativa de su inventario consiste en productos que no se están vendiendo bien, resultando en un exceso de stock de ciertos productos. Inicialmente, la empresa tenía 1643 unidades de productos en su almacén, pero recientemente ha identificado que, de estas, solo 439 unidades corresponden a productos de alta rotación. Esta situación está causando varios problemas, como: Incremento en los costos de almacenamiento debido al exceso de stock, ineficiencia en el uso del espacio de almacén, problemas de liquidez, ya que el capital está atrapado en productos no vendibles y pérdida de ventas.

El problema identificado fue que la gestión inventario es ineficiente lo que dificulta prever la demanda futura y gestionar el flujo de productos en su almacén, lo que ha resultado en la pérdida de dinero debido a productos que están perdiendo continuidad que no se podrán vender fácilmente.

La justificación teórica de este estudio radicó en su contribución a la comprensión de las futuras investigaciones para el control de inventario, al establecer los cimientos de las variables y al emprender una búsqueda de innovación científica a través del ML. Este trabajo impulsa un avance significativo en la innovación, por lo tanto, se vuelve crucial llevar a cabo un análisis completo del panorama actual del problema bajo investigación y comparar los resultados con investigaciones previas para ampliar el marco teórico. (Ñaupas, Mejía, Trujillo, Romero, Medina y Novoa, 2023). Del mismo modo, la justificación práctica radica en que la implementación de un algoritmo de ML generará información indispensable que beneficiará a las organizaciones reflejándose en mejoras económicas y ayudando a evitar pérdidas en las operaciones. Permitiéndoles procesos sistematizados, reales y óptimos, conllevando a que el almacén registre de forma precisa, oportuna los artículos tecnológicos de la organización. La razón central de esta justificación es demostrar la utilidad, posibilidad y viabilidad de poner en práctica la información adquirida recientemente con el propósito de solucionar o anticipar dificultades, (Ñaupas et al., 2023). Asimismo, la

justificación económica, es minimizar los costos operativos en la empresa Group Alcantara, la cual tiene como finalidad obtener un mayor control del inventario aplicando Machine Learning. Hay varias justificaciones académicas fundamentales para realizar este proyecto. En primer lugar, se alinea estrechamente con mis intereses académicos y metas profesionales, por lo que he desarrollado un profundo interés en Machine Learning. En segundo lugar, esta investigación representa una oportunidad para contribuir al cuerpo del conocimiento en mi campo de estudio. Además, me permitirá adquirir y desarrollar habilidades prácticas que considero esenciales para mi crecimiento como estudiante y futuro profesional.

Se logró formular como problema general, ¿Cómo influye un sistema basado en Machine learning para la predicción en la gestión de inventario dirigida a PYMES de venta de productos tecnológicos? Asimismo, se desglosan específicamente lo siguiente:

¿Cómo influye un sistema basado en Machine learning para la predicción en la rotación de inventario en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos? y ¿Cómo influye un sistema basado en Machine learning para la predicción en la duración de inventario en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos?

La investigación precisó el objetivo general: Determinar cómo influye un sistema basado en Machine learning para la predicción en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos. Por ello, se tiene los siguientes objetivos específicos: determinar cómo influye un sistema basado en Machine learning para la predicción en el índice de rotación de inventario en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos y determinar cómo influye un sistema basado en Machine learning para la predicción en el índice de duración del inventario en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos.

Repasando investigaciones previas a nivel internacional, encontramos a Demizu, Fukazawa, Morita (2023) los cuales realizaron un artículo científico del cual el problema principal a tratar fue el desabastecimiento de nuevos productos en las tiendas retail, la cual una de las causas fue la ineficiencia al calcular el número de stock a adquirir, en otros casos a tener una tasa de desabastecimiento alta y una

rotación de inventario baja, el objetivo del estudio es optimizar la gestión del inventario a través de los métodos de aprendizaje por refuerzo propuestos, se propuso para el estudio dos modelos BNN (redes neuronales binarias) y NAML (redes neuronales de aprendizaje atento de múltiple vistas), el estudio fue de naturaleza experimental, en la cual se estudió 10 tiendas como población y muestra 4 productos durante 200 días, resultando en que el modelo propuesto NAML obtuvo la mayor rotación de inventario de 14.367% lo que representa una mejora 5% contra los métodos convencionales y redujo la tasa de desabastecimiento al 0.5% dando un porcentaje similar al método convencional, el modelo BNN mostró la misma tendencia y obtuvo un 14.003 siendo un 3% mayor al convencional, como conclusión estos resultados demuestran que los algoritmos propuestos logran un mejor control de inventario al determinar los pedidos y al mismo tiempo satisfacer la demanda de ventas. Del mismo modo los autores Park, Choi y Min (2023) estudiaron la problemática de una tienda retail dedicada al rubro de salud y belleza en Corea del Sur que tenía inconvenientes con el reabastecimiento de inventario con demanda desconocida y no estacionaria la cual generaba costos altos. El objetivo del estudio es diseñar un algoritmo estructurado de aprendizaje por refuerzo que se adapta eficientemente a la política de reabastecimiento por demanda cambiante sin ningún conocimiento previo, los métodos propuestos son el uso de FSA (aproximación estocástica completa) y PSA (aproximación estocástica parcial). La investigación fue de naturaleza cuantitativa. La población y muestra fueron los 2 artículos (bloqueador solar y desodorante) la cual se estudiaron las ventas realizadas durante 865 y 1000 días respectivamente, el resultado fue que los modelos SRL_FSA y SRL_PSA reducían los costos de inventario en más de un 10% y un 30% en comparación con las prácticas actuales de reposición. Por otra parte, Osorio (2022) en sus tesis, la problemática encontrada fue el inadecuado proceso en la gestión de inventarios productos perecederos encontrada en la Corporación Favorita, esto debido a que no se cuenta con un modelo predictivo que controle la cantidad de productos a adquirir ya que un exceso de stock deriva en productos desperdiciados por caducidad o deterioro por otro lado la escasez de estas producirán una rotura del stock. Por lo tanto, con el fin de ejercer un control administrativo efectivo sobre el inventario, se implementó un sistema combinado con modelos de aprendizaje automático y profundo. La investigación fue de naturaleza cuantitativa. Como población y muestra se tomaron 10 productos perecederos. Los resultados revelaron que para los productos con caducidad de valor 1, la acumulación

de residuos era de 14.5% y las roturas los cortes de stock del 13.6% con respecto a la caducidad de valor 3 son 2.9% y 2.7% respectivamente. Asimismo, Correa (2023) en su trabajo de especialización encontró que la problemática era la falta de productos disponibles en el almacén por la cual no se llegaban a concretar las ventas. El objetivo del estudio fue examinar el modelo tradicional versus un modelo para la predicción propuesto, se propusieron los modelos ARIMA, redes neuronales, regresión lineal y random forest. La investigación fue de naturaleza cuantitativa, como población y muestra se usaron tres productos relevantes de la empresa para la evaluación de los modelos se empleó la métrica MAE (error medio absoluto) que puede implementarse con scikit-learn. Los resultados de la comparativa entre los diversos modelos arrojaron que cada uno tenía sus complicaciones y eran adecuadas en ciertos tipos de eventos. Por otra parte, los autores Sridhar, Vishnu y Sridharan (2021) en su artículo, el problema que se encontró fue que el método convencional para solicitar productos se basa en la intuición personal, lo cual resulta ineficiente. Paradójicamente, la tienda mantiene un inventario elevado, pero todavía experimenta escasez de productos y pérdida de ventas con regularidad. Se priorizó como objetivo garantizar que la inversión en inventario se mantenga en el nivel óptimo necesario para respaldar las operaciones y las ventas, evitando tanto el exceso como la escasez de inventario para ello se usa el software arena. El estudio es de tipo aplicada, como población se preseleccionaron 200 artículos para luego tomar como muestra el producto más valorado, como resultados se obtuvieron que el método propuesto reduce el nivel de inventario en un 40% y la pérdida de consumidores en 87%, la calidad del servicio se elevó de 0.63 a 0.94 y se produjo una disminución en el gasto total del inventario en 6%.

En los trabajos previos nacionales encontramos a Bernaola y Varillas (2022) en su trabajo de investigación encontraron que, en la empresa estudiada, la administración de productos y ventas del almacén se realizan de manera manual, esto conduce a discrepancias entre la cantidad física y la cantidad registrada de artículos. Como resultado, existe un control ineficaz de los distintos niveles que rige en la gestión de inventario de las diferentes mercancías que maneja la empresa. Es por eso que, como objetivo general el control del mismo fue prioridad. La investigación fue aplicada con diseño experimental, para esto se tomó como población 190 registros de facturación, resultando como muestra 128 registros. De ello, se precisa el aumento

en rotación de los inventarios ya que en el pretest se logró el resultado de 0.87%, luego de implementarse el sistema fue de 0.94%. Asimismo, Silva (2019) quien desarrolló su investigación la cual tenía como problemática el mal manejo del inventario, donde se compraban materiales que tenían de sobra. El objetivo fue la implementación de una solución informática que posibilite una mejora en la administración y fácil para los materiales disponibles. Usó la investigación aplicada y el diseño experimental, se tomó como población y muestra 20 artículos que tienen mayor uso por parte de producción. De acuerdo con los datos observados en el pretest para la medición del indicador de rotación se logró un promedio de 0.85 y el posttest se logró 1.6 de promedio. Además, la rotación más baja en las comparativas fue de 0.3 antes y 1 después, en la cual se ve una mejora significativa. Por otro lado, los autores Aguirre et al. (2023), en su estudio proponen un modelo de ML para predecir las ventas que permitan la prevención del sobre stock en el rubro de calzados. Asimismo, se utilizó el Orange como herramienta para el análisis de datos. Con ello, se tiene identificado a la regresión logística y al árbol de decisión como algoritmos utilizados. En base a ese contexto, se precisa que los resultados obtenidos lograron la precisión de 97%, respecto al árbol de decisión se obtuvo la precisión de 85%, que significa un nivel alto de predicción. De igual manera, Jiménez (2022) en su investigación identificó la problemática de pronóstico para las ventas, donde precisó sucesos significativos. Por esta razón, el objetivo fue de implementar datamart en un sistema web, que utiliza ML para obtener métodos de control para el inventario y predecir las ventas. Respecto a la metodología fue aplicada con datos cuantitativos. Asimismo, se utilizó la técnica de fichas de registro para 50 productos, donde se aplicó el cuestionario para el vendedor y administrador. Como resultado, se logró una optimización en el control de los inventarios y en la predicción, disminuyendo la pérdida de productos del 23.40% al 8.26%, la duración del inventario de 17.04 días a 9.28 días. Del mismo modo, para Atoche (2021) en su investigación la problemática hallada fue la falta de la tecnología en los procesos de planeación de los cuales sobrepasan sus costos en relación con los tiempos estimados que se demoran en planificar las órdenes de producción semanales. El objetivo fue identificar la influencia del sistema web con ML para predecir con diferentes modelos como RL, LSTM y MLP. La investigación fue aplicada con diseño experimental. Asimismo, con una población de 50 órdenes de producción y como muestra 47, como resultado se comprobó que de entre los 5 modelos estudiados la red neuronal (MLP) tuvo una mejor precisión con

un 96% al momento de pronosticar los requerimientos de producción al igual que disminuyó el tiempo promedio de cálculo de 76,68 minutos a 0,31 minutos.

De la variable independiente machine learning se describe como una parte de la inteligencia artificial para entrenar un modelo mediante la adquisición de conocimiento y con ello, tomar decisiones precisas. En ese mismo orden los autores Valdemar, et al. (2021) sostienen que “el campo del machine learning se puede desglosar en dos áreas esenciales: los conceptos relacionados con los datos, que proporcionan terminología para describir los datos y sus conjuntos, y los conceptos relacionados con el aprendizaje, que describen cómo se obtiene el conocimiento a partir de los datos y [...]” (p. 5).

Los algoritmos de ML consideran a los modelos lineales como uno de los principales. Según el autor Kurpicz-Briki (2023) precisa que se usa la regresión lineal y logística pero no presentan resultados ideales según el contexto de la empresa en base a mayor número de variables. Asimismo, los modelos de árbol permiten identificar reglas de decisión y presentar resultados; sin embargo, según Kurpicz-Briki (2023) indica que los algoritmos de árbol de decisión y los random forest son los más precisos no tienen buen rendimiento. Los de redes neuronales consideran el entrenamiento para generar mayores procesos. Según el autor Aggarwal (2023) indica que el modelo idóneo para reconocer de imágenes o vídeos, pero tienen lentitud y requieren potencia para tener resultados más favorables.

Para la creación del módulo en el cual se aplicó machine learning, se emplearon diversas herramientas tecnológicas que brindaron el respaldo necesario a la aplicación. El desarrollo se realizó en el framework django, para Fuior (2021) “es el framework más popular de Python que existe. También sigue la arquitectura model-view-controller (MVC), django brilla en su arquitectura no modular [...] puede ayudar al fácil para desarrollar sitios a nivel web que utilizaron bases de datos.” (p. 1). También se usó el lenguaje de programación python, según Fuior (2021) permite obtener resultados robustos y tienen una solidez muy clara para el procesamiento de la data. Asimismo, se usó el motor de base de datos SQLite que son útiles para trabajar en diferentes plataformas y dispositivos.

Por otra parte, están los inventarios que son todos los bienes, productos y

materiales que una empresa posee para su posterior venta, producción o uso en sus operaciones comerciales, por ello, Zapata (como se citó en Torres, 2022, p. 15) “El inventario es la cantidad de material disponible en un almacén, que incluye insumos, productos semielaborados y culminados. Asimismo, en algunos casos la demanda se incrementa sobre la cantidad disponible donde el periodo de reposición cubre el déficit generado, entonces se considera que el agotamiento del inventario. Por otro lado, la situación opuesta sería un inventario excesivo o sobre stock”. Es importante destacar que, aunque "stock" e "inventario" se utilizan a menudo de manera intercambiable, algunos pueden considerar que "stock" se refiere específicamente a los productos disponibles para la venta, mientras que "inventario" incluiría todos los activos almacenados, incluyendo materias primas y otros elementos.

Metodología CRISP-DM Según Schröer, Kruse y Gómez (2021) indican que es el modelo idóneo aplicado para minería de datos es CRISP-DM, que descompone el proceso de capacitación en extracción de datos en seis etapas bien definidas. También establece las actividades que deben llevarse a cabo en cada etapa, así como los resultados estimados. Las fases son iterativas lo que permite la posibilidad de volver atrás en el proceso, y es menos rígido que el enfoque en cascada tradicional utilizado en el desarrollo de aplicaciones.

Para este estudio, se estableció como variable dependiente el concepto de gestión de inventario. Para ello Zapata (como se citó en Torres, 2022, p. 15) “la gestión de inventarios asegura productos que son necesarios tanto en la compañía como para los clientes estén disponibles, lo que conlleva la sincronización de las áreas de adquisiciones, producción y distribución.”. Las dimensiones representan una faceta de una variable que puede ser complicada de evaluar y surge a raíz del proceso de desglose y análisis. En esta investigación, una de las dimensiones clave es la gestión, que abarca varios indicadores, El primer indicador que se abordó es el índice de rotación de inventario. Para Montoya (como se citó en Llasaca (2020) El objetivo de este indicador es cuantificar la frecuencia con la que los productos ingresan y salen de la organización, lo que se denomina 'rotación del inventario', y se expresa como la frecuencia donde se recupera el dinero invertido a través de las ventas. Se tiene la fórmula:

$$IRI = \frac{US}{IP}$$

IRI = índice de rotación de inventario

US = unidades salidas

IP = Inventario Promedio = (inventario inicial - inventario final) / 2

Fuente: Torres (2022)

El otro indicador que se tomó para la investigación es la duración del inventario. Para Zapata (como se citó en Torres, 2022, p. 15) Este indicador tiene como finalidad calcular el período durante el cual los productos permanecen en el inventario, lo que permite evaluar el nivel de inventario en peligro de volverse obsoleto o de ser extraviado. Se tiene la fórmula:

$$IDI = \frac{IF}{SP} \times 30$$

IDI = índice de duración de inventario

IF = inventario final

SP = salidas promedio

Fuente: Torres (2022)

Asimismo, el estudio tuvo como hipótesis general es: Un sistema basado en machine learning para la predicción mejora la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos. Asimismo, tiene como hipótesis específicas: Un sistema basado en machine learning para la predicción mejora el índice de rotación de inventario en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos y Un sistema basado en machine learning para la predicción mejora el índice de duración de inventario en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos.

II. METODOLOGÍA

La investigación realizada es de tipo aplicada, Hadi et al. (2023), al respecto indican que: “Es aplicada ya explica el problema que permitan tomar una decisión práctica” (p.120). Por lo que se elegirá un grupo en el experimento y dos medidas distintas. La primera medida, se tomó una muestra al grupo en un periodo determinado excluyendo el machine learning. Por otro lado, en la segunda medición se evaluó al mismo grupo, pero haciendo uso de machine learning. Asimismo, se realizó mediante el enfoque cuantitativo, al considerar que se adapta mejor a las características y necesidades de la investigación. Para Ñaupas (2019) el estudio es cuantitativo porque utiliza medios para recopilar datos para que luego puedan ser analizados, de este modo se logre generar resultados que permitan responder preguntas de investigación y comprobar cada hipótesis. Por otro lado, Hadi et al. (2023) sostienen que “La investigación es cuantitativa ya que Sus procedimientos permiten la medición precisa de diferentes aspectos específicos de la realidad. Utiliza técnicas estadísticas para analizar la información, lo que simplifica la comparación de datos y los resultados.”

El diseño es de tipo pre-experimental, dado que el objetivo de esta investigación fue Implementar ML para proceso de administración de artículos tecnológicos en la empresa Group Alcántara. Los autores Maldonado et al. (2023) mencionan que el núcleo de la cuestión se encuentra en la realización premeditada de la acción con un objetivo para examinar posibles causas y consecuencias que pueda tener.

El desarrollo experimental [...] Incluye proyectos organizados que hacen uso de los conocimientos ya obtenidos a través de la investigación experimental y se centra en la generación de nuevos materiales. (Maldonado et. al., 2023, p.45)

Por otra parte, Hernández y Mendoza (2018) afirman que, a un conjunto se le somete a una evaluación inicial previa a la introducción de un tratamiento, posteriormente se realiza el tratamiento y después se realiza la evaluación adicional.

Diagrama de diseño de investigación

$$G \rightarrow O_1 \rightarrow X \rightarrow O_2$$

Fuente: Hernández y Mendoza (2018)

Donde:

G: Grupo de sujetos

O1: Pre-Test, es antes de implementar machine learning

X: Es la aplicación usando machine learning

O2: Post-Test, es después de aplicar el estímulo (machine learning)

Respecto a las variables, Maldonado et. al. (2023) son las características o cualidades individuales que se estudiarán, deben ser identificadas y definidas después de un análisis exhaustivo de la bibliografía relevante al tema seleccionado. Es crucial evaluar la factibilidad, viabilidad y utilidad de estas características para el estudio científico y se pueden clasificar como independientes, dependientes e intervinientes.

Tabla 1

Relación entre variables

Variables investigadas	
Tipos	Variables de investigación
Variable independiente	Machine learning
Variable Dependiente	Gestión de inventario

La variable independiente, en este caso el machine learning, se definió conceptualmente como un factor que tiene la capacidad de influir, incidir, condicionar o causar el comportamiento de otras variables de salida. Según Rodríguez, Breña y Esenarro (2021), la variable independiente puede afectar significativamente los resultados de un estudio o experimento. De igual manera para Xu, Zhou, Sekula y ding (2021) “El Machine Learning consiste en la ciencia que capacita a las computadoras para aprender, del mismo modo este aprendizaje implica la integración de técnicas, datos, comprensión del análisis de datos y algoritmos con el propósito de

generar nuevos patrones y resolver desafíos adicionales.” (p. 2). Se define de forma operacional como un campo en base a los modelos que requieren datos consistentes que se generan a partir de las actividades como: recopilación de Datos, reprocesamiento de Datos y la selección del Modelo.

La variable dependiente es gestión de inventarios se definió conceptualmente como el resultado del comportamiento del objeto bajo análisis, que ha sido influenciado o estimulado, y sus valores dependen de la variable independiente (Rodríguez et al., 2021, p. 62). Por consiguiente, para Richards y Hamilton (2022) es importante la planeación, coordinación y el control mediante actividades específicas. Se define de manera operacional a través del estudio de las dimensiones del inventario donde se precisan que los indicadores considerados son: índice de rotación y duración.

Para el estudio se seleccionó la población que se basa en documentos y registros relacionados con el proceso de inventario, abarcando toda la información que describe los productos tecnológicos que la empresa maneja, esta población consta de un total de 64 productos. Asimismo, se define que la población es el conjunto completo de las unidades de estudio y que poseen las cualidades para ser consideradas. Estas unidades pueden abarcar individuos, objetos agrupados, eventos o fenómenos, siempre que cumplan con las características necesarias para la investigación” (Ñaupas et. al., 2023, p. 334).

Como criterios de inclusión se tomaron los 495 registros de salida y entrada de artículos correspondientes a la muestra desde el mes de enero a setiembre del 2023 y como criterios de exclusión se tomaron los registros de salida y entrada fuera de los meses de enero a setiembre correspondientes a la muestra del año 2023.

Una muestra consiste en una porción de una población que comparte las características de la totalidad, lo que posibilita la extrapolación de los resultados, “cuando la población es extensa, suele optarse por seleccionar una muestra de esta. Por esta razón, generalmente se establece que, si la población supera los 200 elementos, se considera grande y se requiere el uso de una fórmula” (Rodríguez et al., 2021, p. 58).

Posee entonces, como muestra 55 registros en la administración de inventario

en la organización Group Alcántara.

El tamaño de muestra consideró los registros de entrada y salida que cumplieran con los criterios de inclusión. Luego, se aplicó una fórmula de población finita, considerando nivel de confianza: 95%, el margen de error será del :5%.

Cálculo de la muestra

$$n = \frac{N \cdot Z\alpha^2 \cdot p \cdot q}{d^2 \cdot (N - 1) + Z\alpha^2 \cdot p \cdot q}$$

Fuente: Hernández y Mendoza (2018)

Donde:

N= total de artículos de la empresa Group Alcántara

n =Tamaño de la muestra

Z = 1.96 / 95% de nivel de confiabilidad

P = proporción esperada del 0.5

q =1-p (1-0.5= 0.5)

e = error de estimación 5%

Al reemplazar en la formula, obtendremos:

Al reemplazar en la formula, obtendremos:

$$n = \frac{64 * (1.96)^2 * (0.5) * (0.5)}{(0.05)^2 * (64 - 1) + (1.96)^2 * (0.5) * (0.5)}$$

El resultado de la muestra obtenido es de 55 artículos de los registros.

Los autores Hadi et al. (2023) precisan que la recopilación de datos de variables de medición se llevó a cabo a través de métodos que incluyeron entrevistas, observaciones, encuestas, etc. Todo ello, facilitó el acceso de los investigadores a los datos necesarios para sus investigaciones.

En la investigación se utilizó el fichaje como método para la obtención de los datos. Asimismo, los autores Ñaupás et. al. (2023) aseguran que el instrumento es aquel que facilita la documentación de los datos de manera precisa, representando de manera adecuada la serie de conceptos para la evaluación del investigador.

Se hizo uso de la ficha de registro la cual consiste en una hoja que resume la investigación, recopilando datos de diversas fuentes consultadas, lo que simplifica la tarea de registrar la información y su posterior análisis. “La ficha de registro consiste en recopilar datos a medida que se obtienen, utilizando fichas preconfiguradas que contienen la mayor parte de la información recopilada. Esto se describe como un método para registrar datos en fichas” (Hadi et al., 2023).

La validez de un instrumento se evalúa través de la eficacia, método o instrumento utilizado para la medición, “se pueden validar por contenido, la cual refiere al grado en la que demuestra competencia en el área de conocimiento que se pretende evaluar, se puede validar por constructo, que es la habilidad de una medida para representar de manera precisa el constructo o concepto que se busca y se puede evaluar por expertos, se pretende confirmar la precisión de los evaluadores que determinan la eficacia de un instrumento para llevar a cabo mediciones de una variable, apoyándose en el juicio de especialistas en el campo” (Ñaupas et al., 2023, p.124).

La confiabilidad es referida a la medida de precisión para un instrumento. Por lo tanto, existen varias formas de evaluar la confiabilidad, como el ejemplo de un test inicial y un segundo test posterior, conocido como "retest", que se realiza utilizando la misma escala que el test original. Este enfoque busca garantizar una mayor precisión en los resultados (Maldonado et al., 2023, p.102). Así mismo Hernández y Mendoza (2018) indican que existen múltiples enfoques para medir la precisión de un instrumento de medición. Todos estos métodos utilizan cálculos y técnicas que generan parámetros de fiabilidad, los cuales se expresan en una escala que va de 0 a 1. Un valor de 0 indica que la fiabilidad es nula, mientras que un valor de 1 representa la máxima fiabilidad posible. Cuanto más se acerque el coeficiente a 0, mayor será la posibilidad de error en la medición.

De igual manera se aplicaron los métodos test – retest, el método de pretest implica la aplicación del instrumento de medición dos veces o más al mismo individuo. Luego, se recopilarán los registros y se calculará la confiabilidad utilizando el coeficiente de Pearson. Además, el método de pretest podrá ser evaluado mediante los siguientes enfoques: el coeficiente de Pearson y las pruebas de Spearman-Brown.

Para Hernández y Mendoza (2018) el proceso se itera dos veces o más en el mismo entorno de medición, en el mismo conjunto de sujetos o escenarios, después de un intervalo de tiempo determinado. La herramienta es considerada confiable, si se demuestra la existencia de una concordancia práctica entre los resultados obtenidos en las diferentes aplicaciones.

Tabla 2

Recolección de datos

Indicadores	Técnica	Instrumento
ROTACIÓN DE INVENTARIO	Fichaje	Ficha de registro
DURACIÓN DE INVENTARIO	Fichaje	Ficha de Registro

El coeficiente de confiabilidad se precisa para distribución normal (Pearson) y para distribución no normal (Spearman).

Se dispuso de una tabla de correlación que establece que cuando el coeficiente de correlación supera 0.7, el instrumento se considera fiable; en caso contrario, se considera no fiable.

Tabla 3

Niveles de confiabilidad

Nivel	Escala
Nula	0.00 - 0.24
Bajo	0.25 - 0.35
Mediana	0.50 - 0.60
Elevado	0.70 – 0.89
Muy alto	0.90 – 0.95

Fuente: Hernández [et. al]. (2018)

En la Tabla 3 se observa que la escala para el coeficiente de confiabilidad con el que se puede evaluar nuestro instrumento; por lo que se puede afirmar, si el resultado es próximo a uno, la confiabilidad del instrumento es aceptable. Por otro parte, si está más cerca a cero, el instrumento por ende no es confiable para hacer uso.

Para poder realizar la confiabilidad del instrumento de los indicadores rotación y duración; Debemos disponer de la información recolectada en dos períodos distintos. Se dio uso del programa estadístico IBM SPSS.

Si $P < 0.05$; se rechaza la hipótesis nula y acepta la hipótesis alterna. Distribución no normal. $p \geq 0.05$; Acepta hipótesis nula y rechaza alterna. Distribución normal

Tabla 4

Prueba de normalidad del primer indicador

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
Índice de rotación de inventario - Test1	,143	55	,007	,890	55	,000
Índice de rotación de inventario – Re Test 2	,184	55	,001	,856	55	,000

El sig. Test: 0.007 y el sig. Retest: 0.001; valores menores a 0.05. Rechaza H_0 y acepta H_a , no tienen distribución normal, por lo tanto, se aplicó estadística no paramétrica.

Tabla 5

Prueba de normalidad del segundo indicador

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
Índice de duración de inventario – Test 1	,271	55	,001	,692	55	,000
Índice de duración de inventario – Re Test 2	,268	55	,001	,724	55	,000

El sig. test 0.001 y el sig. Retest 0.001; valores menores a 0.05, rechaza H_0 y acepta H_a , distribución normal, se aplicó estadística no paramétrica (Spearman).

Tabla 6

Correlación de Spearman del primer indicador

			Índice de rotación de inventario – test 1	Índice de rotación de inventario – Re Test 2
Rho de Spearman	Índice de rotación de inventario - test1	Coeficiente de correlación	1,000	,920**
		Sig. (bilateral)	.	,000
		N	55	55
Índice de rotación de inventario – Re Test 2	Índice de rotación de inventario – Re Test 2	Coeficiente de correlación	,920**	1,000
		Sig. (bilateral)	,000	.
		N	55	55

Rho Spearman es 0.920 por lo cual, la confiabilidad del instrumento es probada conforme a la tabla tres.

Tabla 7

Correlación de Spearman del segundo indicador

			Índice de duración de inventario - test1	Índice de duración de inventario – Re Test 2
Rho de Spearman	Índice de duración de inventario – Test 1	Coeficiente de correlación	1,000	,929**
		Sig. (bilateral)	.	,000
		N	55	55
Índice de duración de inventario – Re Test 2	Índice de duración de inventario – Re Test 2	Coeficiente de correlación	,929**	1,000
		Sig. (bilateral)	,000	.
		N	55	55

** La correlación es significativa en el nivel 0,01 (bilateral).

Rho de Spearman: 0.929, lo que lleva a la conclusión la fiabilidad del instrumento de acuerdo con la Tabla 3.

Los procedimientos en la investigación desde una perspectiva conceptual, un procedimiento se puede definir como “El camino a seguir con el fin de alcanzar un propósito. Constituye una progresión lógica con la cual se adquiere conocimiento sobre las cosas o cómo crearlas.” (Sánchez & Mejía, 2018, p. 89). En función de esta definición, se han delineado una serie de pasos secuenciales.

Figura 1
Procedimientos del proyecto



En esta investigación, se identificó un desafío en la empresa Group Alcántara, que se relaciona con el control de los productos suministrados por los proveedores. Este desafío se ha establecido como la variable dependiente. Luego, se realizó la exploración de disposiciones similares en otras organizaciones tecnológicas a nivel nacional e internacional. Se han examinado las soluciones que estas organizaciones están implementando en la actualidad y se ha evaluado la estructura de la gestión de inventario en cada caso. A través de este proceso, se ha facilitado la comunicación entre los departamentos pertinentes de la empresa actual.

Como resultado de estas investigaciones, se ha decidido desarrollar un sistema web con capacidades de aprendizaje automático (machine learning) para mejorar el manejo del inventario. Este sistema se establece como la variable independiente y se prevé que tenga un impacto en la variable dependiente de la investigación.

Esta investigación fue enfocada en un análisis cuantitativo, para López (2021) el análisis cuantitativo es un enfoque que utiliza conocimientos de matemáticas y

estadísticas para validar o predecir diversas variables. Por lo que se aplicara conocimiento de estadísticas, matemáticas con la finalidad de mostrar los resultados alcanzados, con la información adquirida a través de los instrumentos, se aplicó estadística descriptiva e inferencial los indicadores. Se utilizó el programa SPSS Statistics versión 29.0.1.0 y se estudiaron las variables.

La estadística descriptiva se desarrolló en cuatro etapas que son: obtención de los datos, carga de datos al programa estadístico, análisis estadísticos de los datos (media, moda, mediana, histogramas) y resultados descriptivos (gráficos de barras como lineales). Con respecto a la estadística inferencial se eligió un nivel de significancia del 0.05. Asimismo, la muestra fue de 55. En ese sentido, se realizó el análisis de normalidad con los datos para conocer si son paramétricas o no.

De acuerdo al aspecto ético de la investigación, este trabajo se comprometió a cumplir con las normativas internacionales para asegurar la ética del investigador. Además, se esmeró en honrar la creación de las fuentes referenciadas, acreditando correctamente a los autores de libros, tesis, artículos científicos, entre otros. Estas fuentes se citaron conforme al manual de la norma APA 7. Asimismo, el desarrollo del trabajo siguió la Resolución de Consejo Universitario N° 0470-2022/UCV, Así se asegura un trabajo de alta calidad, con integridad ética y respeto por la propiedad intelectual.

III. RESULTADOS

La investigación precisó el uso de un sistema basado en machine learning para obtener resultados óptimos en la rotación y duración de inventario. En ese sentido, se desarrolló el Pre-Test para identificar resultados previos; posterior a ello se aplicó el Post-Test con el software desarrollado. Se precisan resultados:

Tabla 8

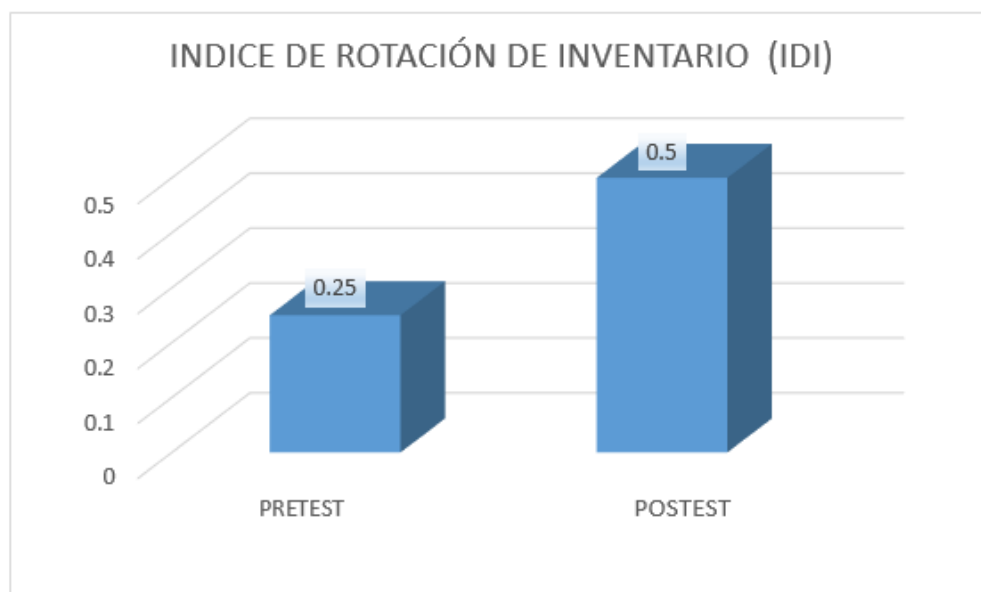
Resultados descriptivos del índice de rotación antes y después

	N	Mínimo	Máximo	Media	Desviación estándar	Varianza
Pre_Indice_Rotacion_Inv entario	55	,02	,95	,2580	,24806	,062
Post_Indice_Rotacion_Inv entario	55	,16	1,06	,5015	,25278	,064
N válido (por lista)	55					

Se tiene como media: pre-test:0.25% / post-test:0.5%, entonces se identifica diferencias antes y después de la implementación de ML; de igual manera se obtuvo como mínimo: pre-test:0.02% y post-test:0.16%.

Figura 2

Nivel de rotación de inventario antes y después



Se precisan los resultados descriptivos en la siguiente tabla:

Tabla 9


Resultados descriptivos del índice de duración antes y después

	N	Mínimo	Máximo	Media	Desviación estándar	Varianza
Pre_Indice_Duracion_Inv entario	55	16,50	1830,00	443,2440	567,29405	321822,542
Post_Indice_Duracion_Inv entario	55	13,33	168,75	62,7889	40,83322	1667,352
N válido (por lista)	55					

Se ve como media en pre-test:443.24 / post-test:62.78. Esto revela una variación entre el periodo anterior y el posterior a la implementación efectuada en el estudio. Asimismo, los resultados mínimos fueron: pre-test:16.50 / post-test:13.33.

Figura 3

Nivel de rotación de inventario antes y después



Dentro del análisis inferencial se realizó la prueba de normalización para los indicadores por medio del método de Kolmogorov Smirnov (muestra > 50), según lo indican los autores Ñaupas et. al., 2023. Asimismo, la herramienta utilizada fue IBM SPSS Statistics, nivel de confiabilidad 95%:

Sig. < 0.05 (distribución no normal / No paramétrica)

Sig. >= 0.05 (distribución normal / paramétrica)

Sig.: P-valor o nivel crítico de contraste.

Los resultados fueron los siguientes.

Para el índice de rotación de inventario, si los datos siguen una distribución normal, se procederá a examinar la distribución de dichos datos para seleccionar las pruebas de hipótesis adecuadas.

Tabla 10

Prueba de normalidad con respecto al índice de rotación pretest y posttest

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
Pre_Indice_Rotacion_Inv entario	,184	55	,001	,856	55	,000
Post_Indice_Rotacion_Inv entario	,157	55	,002	,919	55	,001

Sig. Pretest: 0.001, menor 0.05; distribución no normal.

Figura 4

Prueba de normalidad del índice de rotación en el antes




Figura 5

Prueba de normalidad del índice de rotación en el después

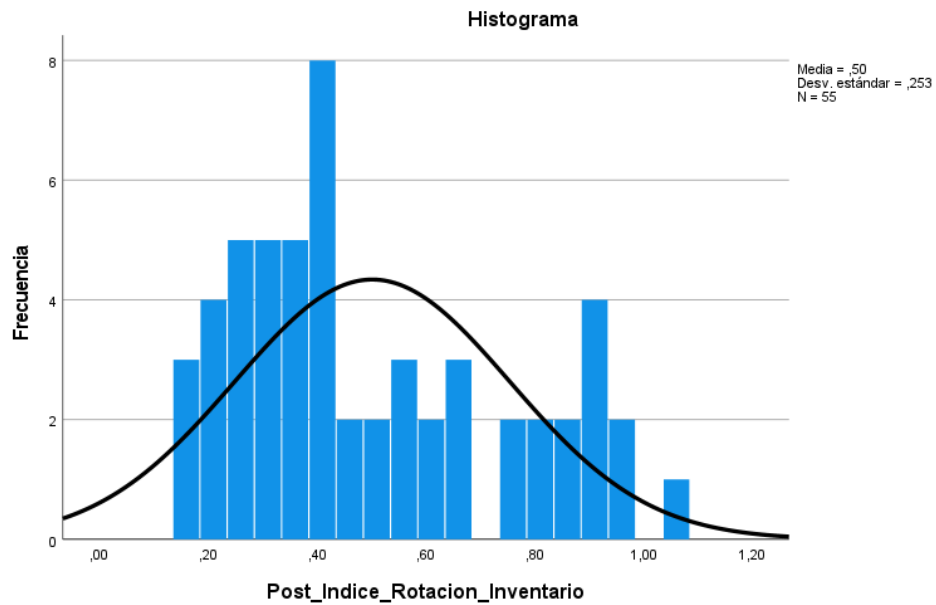


Tabla 11

La prueba de normalidad del índice de duración pre-test y post-test

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	Gl	Sig.
Pre_Indice_Duracion_Inventario	,268	55	,001	,724	55	,000
Post_Indice_Duracion_Inventario	,127	55	,027	,911	55	,001

Sig. Pre-test:0.001; menor a 0.05, distribución no normal. Post-Test:0.027; menor a 0.05; distribución no normal. Esto se puede observar en la siguiente figura.

Figura 6

Prueba de normalidad de índice de duración de inventario antes

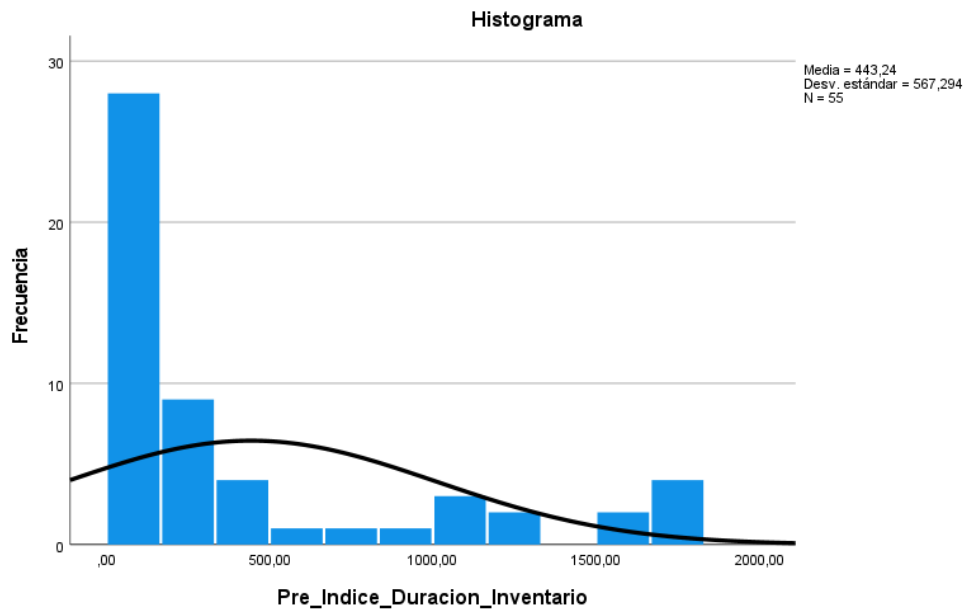
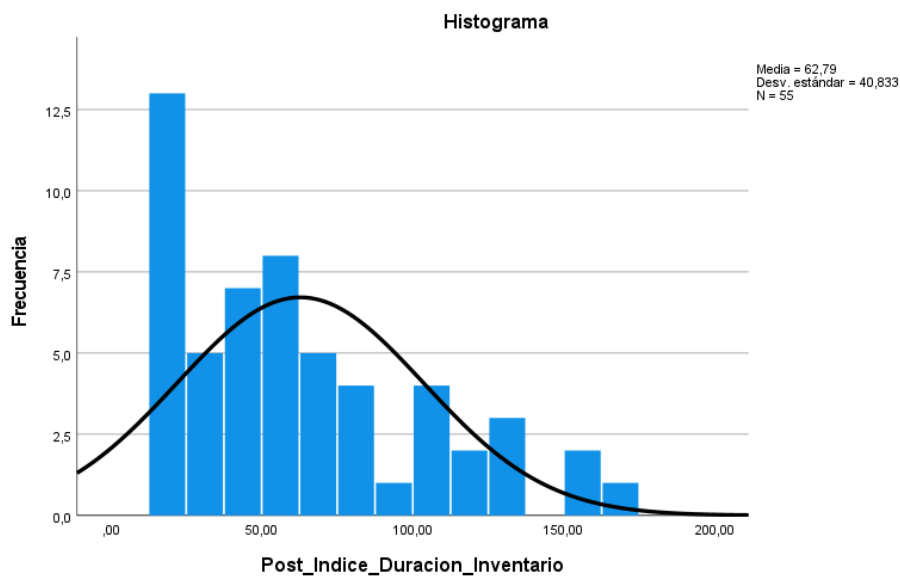


Figura 7

Prueba de normalidad de índice de duración de inventario



A continuación, se precisa el desarrollo de las pruebas de hipótesis. Del Indicador de rotación de la hipótesis (H1) es: Un sistema basado en machine learning para la predicción mejora el índice de rotación de inventario en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos, de la cual se realizó la definición de variables:

IRIa: Índice de rotación antes de utilizar el software predictivo de ML.

IRId: Índice de duración después de utilizar el software predictivo de ML.

La hipótesis nula fue la siguiente: Un sistema basado en machine learning para la predicción no mejora el índice de rotación de inventario en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos. De la cual se derivó la siguiente ecuación:

$$H_0 = \text{IRId} - \text{IRIa} \leq 0$$

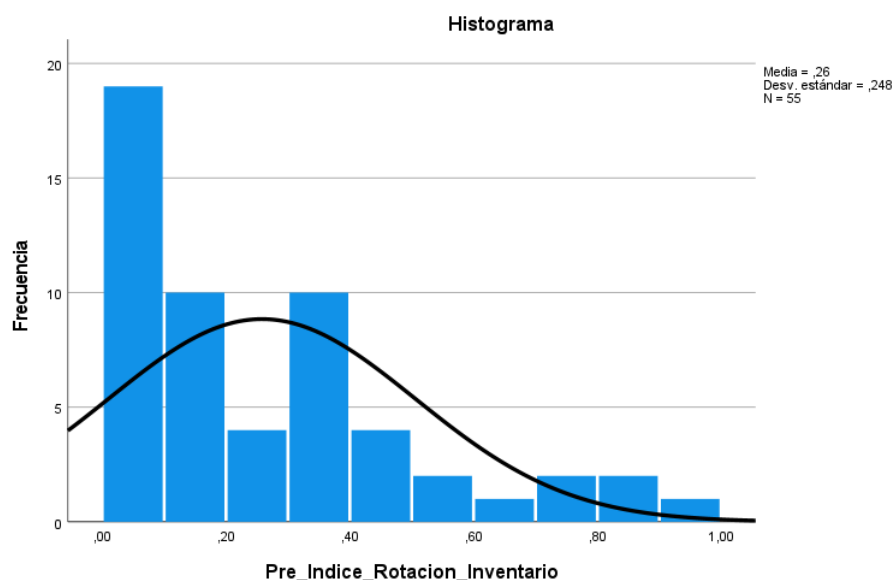
La hipótesis alterna fue la siguiente: Un sistema basado en machine learning para la predicción mejora el índice de rotación de inventario en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos. De la cual se derivó la siguiente ecuación:

$$H_a = \text{IRId} - \text{IRIa} > 0$$

En la figura 10, se obtuvo índice de rotación para pre-test: 0.26%

Figura 8


Índice de rotación de inventario (Pre-Test)



En la figura 11, se precisa un aumento en la rotación de 0.26% al valor de 0.50%.

Figura 9

Índice de rotación de inventario (Post-Test)



Por lo tanto, se evidencia un incremento de 0.24%.

Tabla 12

Rangos de la prueba de Wilcoxon para el índice de rotación

		N	Rango promedio	Suma de rangos
Post_Indice_Rotacion_Inv entario -	Rangos negativos	1 ^a	11,00	11,00
	Rangos positivos	54 ^b	28,31	1529,00
Pre_Indice_Rotacion_Inv entario	Empates	0 ^c		
	Total	55		

a. Post_Indice_Rotacion_Inventario < Pre_Indice_Rotacion_Inventario

b. Post_Indice_Rotacion_Inventario > Pre_Indice_Rotacion_Inventario

c. Post_Indice_Rotacion_Inventario = Pre_Indice_Rotacion_Inventario

Tabla 13

Resultado de la prueba de Wilcoxon para el índice de rotación

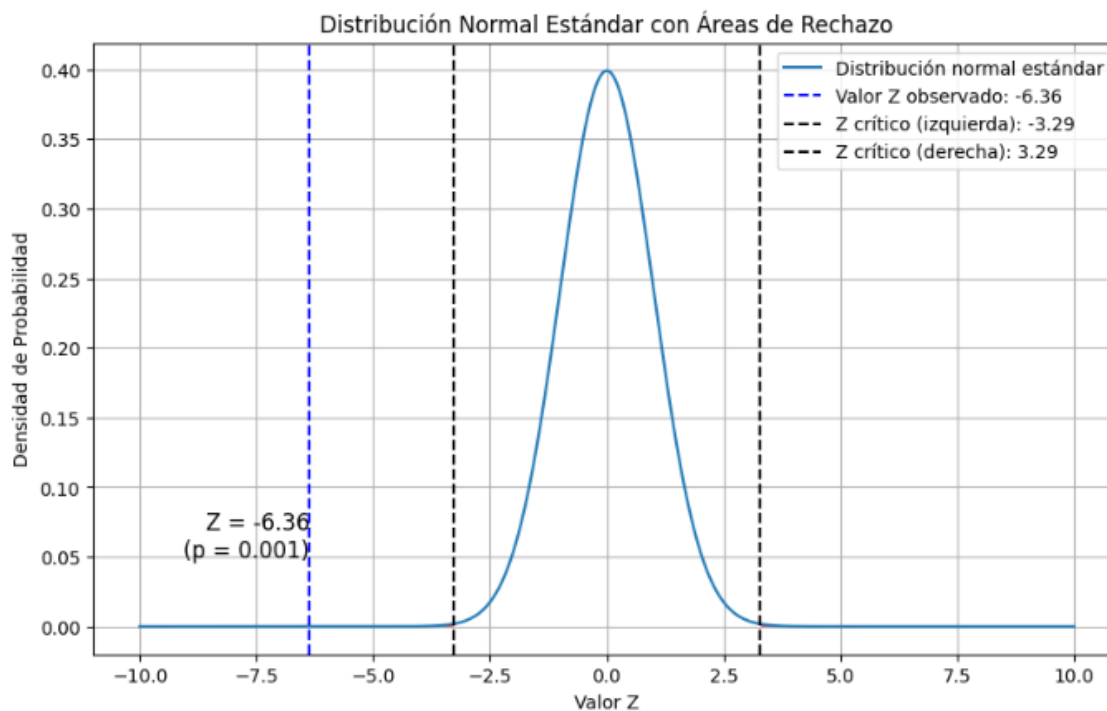
Estadísticos de prueba ^a	
	Post_Indice_Rotacion_Inventario - Pre_Indice_Rotacion_Inventario
Z	-6,360 ^b
Sig. asin. (bilateral)	<,001

a. Prueba de rangos con signo de Wilcoxon

b. Se basa en rangos negativos.

Figura 10

Prueba de Wilcoxon del índice de rotación



De la figura y los datos que se obtuvieron presentados, se verifico que en la tabla 13 el valor $Z=-6.36$, se obtiene $p=0.001 < 0.05$, deduciendo que se rechaza la Hipótesis nula y se acepta hipótesis alterna, como se observa en la figura; por lo expuesto se acepta hipótesis alterna, Sig. $< 0,05$. Por lo tanto, Un sistema basado en machine learning para la predicción mejora el índice de rotación de inventario en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos.

Del Indicador de duración la hipótesis es: Un sistema basado en machine learning para la predicción mejora el índice de duración de inventario en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos, de la cual se realizó la definición de variables:

IDIa: Índice de duración antes de utilizar el software predictivo con ML

IDId: Índice de duración después de utilizar el software predictivo con ML

La hipótesis nula fue la siguiente: Un sistema basado en machine learning para la predicción no mejora el índice de duración de inventario en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos. De la cual se derivó la siguiente ecuación:

$$H_0: IDId - IDIa \leq 0, \text{ entonces } IDId \leq IDIa$$

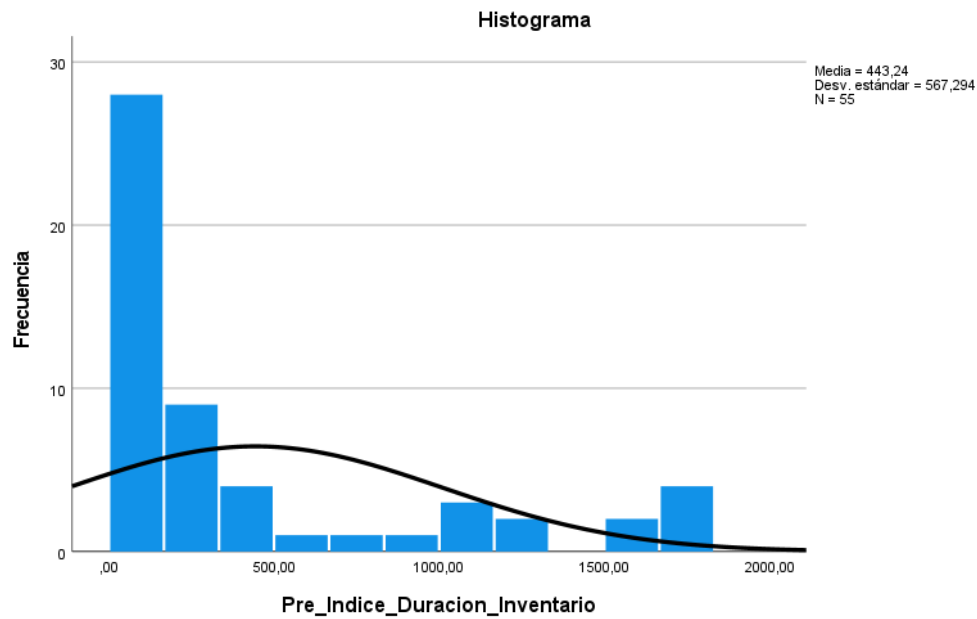
La hipótesis alterna fue la siguiente: Un sistema basado en machine learning para la predicción mejora el índice de duración de inventario en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos. De la cual se derivó la siguiente ecuación:

$$H_0: IDId - IDIa > 0, \text{ entonces } IDId > IDIa$$

En la figura 11, el índice de duración del pretest fue de 443.24

Figura 11

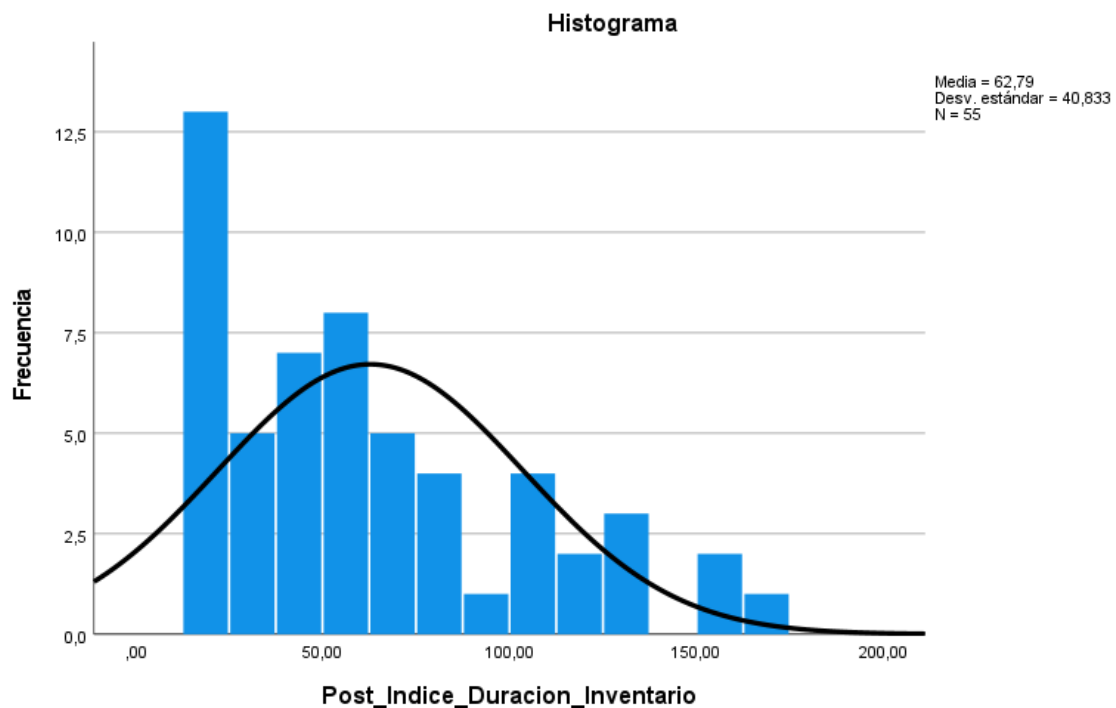
Índice de duración de inventario (PreTest)



En la figura se precisa que existe una disminución en la duración de 443.24 a 62.79

Figura 12

Índice de duración (PostTest)



Se presenta una disminución considerable para el índice de duración dentro del almacén, se evidencia una disminución de 380.45 equivalente a un 85.84%.

Tabla 14

Rangos de prueba de Wilcoxon para el índice de duración

		N	Rango promedio	Suma de rangos
Post_Indice_Duracion_Inv entario -	Rangos negativos	54 ^a	28,48	1538,00
	Rangos positivos	1 ^b	2,00	2,00
Pre_Indice_Duracion_Inv entario	Empates	0 ^c		
	Total	55		

a. Post_Indice_Duracion_Inventario < Pre_Indice_Duracion_Inventario

b. Post_Indice_Duracion_Inventario > Pre_Indice_Duracion_Inventario

c. Post_Indice_Duracion_Inventario = Pre_Indice_Duracion_Inventario

Tabla 15

Resultado de la prueba de Wilcoxon para el índice de duración


Estadísticos de prueba ^a	
	Post_Indice_Duracion_Inventario - Pre_Indice_Duracion_Inventario
Z	-6,435 ^b
Sig. asin. (bilateral)	,001

a. Prueba de rangos con signo de Wilcoxon

b. Se basa en rangos positivos.

Figura 13

Prueba de Wilcoxon del índice de duración



De la figura y los datos que se obtuvieron presentados, $Z = -6.43$, $p = 0.000 < 0.05$, rechazó Hipótesis nula y acepta hipótesis alterna. Sig. es menor a 0,05. Por lo tanto, Un sistema basado en machine learning para la predicción mejora el índice de duración de inventario en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos.

III. DISCUSIÓN

Respecto al objetivo general se precisa determinar cómo influye un sistema basado en machine learning para la predicción en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos. Para ello, se aplicó la metodología CRISP-DM, esta metodología nos proporcionó un marco estructurado y sistemático para abordar el proyecto, se realizó la comparación de los algoritmos con más precisión para la investigación, las cuales fueron seleccionadas gracias a que tuvieron mejores resultados en trabajos de investigación previos. Las pruebas se hicieron tomando como data las unidades de salida, inventario promedio, precio de venta, precio de compra, inventario inicial e inventario final; los resultados dieron que la correlación es mayor con las variables que se relación al inventario, es decir, las unidades salidas, inventario promedio, inventario inicial y final. También, como era de esperarse la correlación del precio de compra y venta con los índices de rotación y duración de inventario es nula.

Por otro lado, agregando una nueva columna para las pruebas, se hizo una revisión de la correlación de la variable de tiempo tomando los meses como una variable secuencial independiente usando también las variables IRI e IDI. Por lo cual se llega a la conclusión de usar el algoritmo gradient boosting dado que parte del mismo principio que random forest y se considera que este método da resultado más preciso porque cada iteración es mejorada y optimizada a partir de sus resultados y errores de pasos anteriores, se observa en los resultados presentados que fue él método que obtuvo mejores métricas, mayores coeficientes de determinación ($R^2 = 0.999$) y menores errores cuadráticos medios ($MSE = 0$), esto indica que el modelo de predicción elegido para el sistema influye positivamente a la gestión de inventario.

El objetivo específico 1 precisó determinar cómo influye un sistema basado en Machine learning para la predicción en el índice de rotación en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos, se determinó que el índice de rotación de inventario aumento de un 0.26% a 0.50% incrementando en un 0.24%, esta mejora estuvo en concordancia con las investigaciones previas que mencionan en la tesis.

Como en Bernaola y Varillas (2022) en su trabajo estudiaron la comparación de los modelos de regresión lineal simple y el modelo de red neuronal, la comparativa llevo a concluir que el mejor modelo de red neuronal fue significativamente más preciso y adecuado para las predicciones necesarias, obteniendo un mse de 0.079 y un r2 de 0.68, antes de la implementación del software, la rotación de inventario era de un 0.88% y despues el índice de rotación del inventario aumento a 0.94% lo cual representa un aumento del 0.07%, esto sugiere que el sistema de predicción mejora el control y la gestión de inventario.

Igualmente, para Silva (2019) en su estudio en el cual se obtuvo un indicador de rotación de inventario 0.85 en el pretest a 1.6 en el post test, incrementando en un 0.75%, en consecuencia, la implementación web en la empresa resulto en una mejora notable en la rotación del inventario mejorando asi el control y la gestión del inventario en general.

Por otro lado, Demizu, Fukazawa, Morita (2023) presentan que entre los modelos estudiados, redes neuronales, aprendizaje meta, DRL basado en modelo, enfoque heurístico y DRL sin modelo, fue el modelo DRL con modelo el que mostro una mayor eficiencia y rentabilidad, obteniendo de menores de mse 0.956 y r2 0.306, aplicado el modelo a tiendas minoristas dedicadas a la venta de productos tecnológicos específicamente a smartphones, el modelo propuesto logro una rotación de inventario de 14.367, lo que representa una mejora superior al 5% en comparación con otras técnicas utilizadas en el estudio. De tal manera se llega a concluir que el sistema basado en machine learning influye positivamente a incrementar la rotación de inventario.

El objetivo específico 2 precisa determinar cómo influye un sistema basado en machine learning para la predicción en el índice de duración en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos, se determinó que el índice de rotación de inventario se redujo de 443.24 a 62.79 días, siendo una mejoría del 85.84%, esto en concordancia con las investigaciones previas.

Para Jiménez (2022) su investigación llega a concluir que su sistema con la aplicación de regresión lineal, aumento el indicador de duración de inventario de un 17.04 días (5.11% del mes) a 9.28 días (2.78% del mes), esta mejora indica una

optimización en la gestión del inventario, lo que contribuyó a una mejor eficiencia operativa y posiblemente a una reducción de costos asociados al manejo de inventarios excesivos.

Asimismo, Bernaola y Varillas (2022), en su investigación mencionada anteriormente, también obtienen una mejora de la duración de inventario de un 0.87% a un 1.00%, equivalente a una mejoría del 0.13%, el problema que mencionaban era sobre el desbastecimiento de sus artículos por lo cual se buscaba maximizar su stock, esto contrasta con nuestro estudio el cual busca disminuir el stock en el inventario actual.

De igual manera para Aguirre et al. (2023) indicaron que en su investigación se mencionan principalmente la precisión y la exhaustividad (recall) como las métricas utilizadas para evaluar y comparar los modelos predictivos. La precisión del modelo de regresión logística fue del 97%, mientras que la precisión del modelo de árbol de decisión fue del 85%, concluyendo que los modelos mencionados lograron el objetivo de prevenir el sobrestock al predecir de manera precisa qué productos y categorías tienen mayor demanda en diferentes estaciones del año. Esto permite a la empresa tomar decisiones más informadas sobre el abastecimiento de productos, reduciendo así el riesgo de sobrestock respecto a la duración de inventarios.

Asimismo, en la investigación de Sridhar et al (2021) en su artículo científico se realiza la implementación de modelos de simulación del software arena, llegando a obtener una mejora en el nivel de inventario el cual se redujo en un 73% en comparación con el sistema existente, demostrando la efectividad de las técnicas avanzadas de simulación y optimización para mejorar la gestión de inventarios, lo que en contraste con la investigación realizada aplicando machine learning indica una mejora menor al resultado obtenido. Igualmente se llega a concluir que el software basado en machine learning influye positivamente a la disminución de la duración de inventario así consiguiendo que los productos consuman menos tiempo en el almacén y que los espacios del mismo sean repuestos por nuevos productos.

Finalmente, los resultados obtenidos precisan que el sistema realizado basado en machine learning para predicción en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos en concordancia con la mayoría de investigaciones

previamente señaladas en este estudio permite que la empresa mejore la elección de decisiones directivas, planificando mejor las órdenes de compra y la producción, alineando más estrechamente la oferta con la demanda.

IV. CONCLUSIONES

Se precisan las siguientes conclusiones:

El sistema basado en machine learning para la predicción mejoró la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos con el incremento del indicador de rotación y la disminución de la duración del inventario, logrando los objetivos precisados, influyendo positivamente al comprobar la hipótesis de investigación.

La implementación del sistema basado en machine learning para la predicción mejoró la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos, mejoró la rotación en términos porcentuales en un 0.50%, se debe tener en cuenta que el Pre-Test fue 0.26%. Asimismo, comprueba que el modelo para la predicción aumenta la rotación del inventario. Este resultado demuestra que el modelo ayuda a las empresas a mover sus productos más rápidamente, reduciendo el tiempo que permanecen en el inventario.

Del mismo modo la implementación del sistema basado en machine learning para la predicción mejoró la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos, mejoró el porcentaje de duración en 62.79 días, pues que en el Pre-Test se obtuvo 443.24 días. Se precisa que el modelo para la predicción disminuyó la rotación. Esta reducción significativa indica que las empresas pueden gestionar mejor sus existencias, manteniendo menos productos en stock por largos periodos y generando la mejoría de la eficiencia para las actividades y las operaciones.

La investigación confirma que el uso del sistema basado en machine learning para la predicción en la gestión de inventarios influyo positiva y significativamente en las PYMES de productos tecnológicos, mejorando tanto la rotación como la duración del inventario y contribuyendo a una gestión más eficiente y efectiva.

V. RECOMENDACIONES

A continuación, se detallaron algunas recomendaciones basadas en las conclusiones a las que se llegó la investigación:

Se debe de considerar la evaluación de múltiples algoritmos de ML para la predicción en la gestión de inventarios. Además del Gradient Boosting, es recomendable explorar otros algoritmos basados en Deep Learning o Model-Based Reinforcement Learning para determinar cuál ofrece el mejor rendimiento en diferentes contextos.

La metodología CRISP-DM demostró ser efectiva en este estudio. Se recomienda a los futuros investigadores seguir utilizando esta metodología, pero también explorar y adaptar otras metodologías ágiles y flexibles que puedan optimizar el desarrollo de sistemas predictivos en contextos específicos.

Es aconsejable que los futuros estudios amplíen su alcance más allá de las PYMES de productos tecnológicos, aplicando los modelos de predicción en diferentes industrias y tipos de inventarios. Esto permitirá evaluar la versatilidad y efectividad de los algoritmos de machine learning en una variedad de escenarios.

Finalmente, continuar realizando análisis comparativos con estudios previos para validar los resultados y obtener un panorama mucho más amplio sobre el impacto de los sistemas basados en machine learning en la gestión para los inventarios. Asimismo, es importante considerar la comparación de los resultados obtenidos con otros trabajos como los de Bernaola y Varillas (2022), Silva (2019), y Demizu et al. (2023) puede proporcionar una base sólida para justificar la elección de ciertos algoritmos y metodologías.

REFERENCIAS

Aggarwal, C. C. (2023). *Neural Networks and Deep Learning: A Textbook*. En *Neural Networks and Deep Learning: A Textbook*. Springer International Publishing. <https://doi.org/10.1007/978-3-031-29642-0>

Aguirre Méndez, K. M., Moreno Torres, A. L. & Ovalle, C. (2023). Predictive model based on machine learning for the prevention of overstock in a footwear company. *Proceedings of the LACCEI international Multi-conference for Engineering, Education and Technology, 2023-July*. <https://doi.org/10.18687/laccei2023.1.1.216>

Atoche, J. C. (2021). *Sistema web utilizando machine learning para mejorar la planificación de requerimientos de materiales de la producción en el sector industrial* [Universidad César Vallejo]. <https://hdl.handle.net/20.500.12692/78659>

Bernaola, D. E. & Varillas, P. D. (2022). Sistema predictivo con Machine Learning para la gestión de inventario para la Empresa Inversiones Ferreteras Mendoza S.A.C [Universidad César Vallejo]. En *Repositorio Institucional - UCV*. <https://repositorio.ucv.edu.pe/handle/20.500.12692/97798>

Correa, A. (2023). *Análisis de modelos basados en Machine Learning para la predicción de la demanda de* [Universidad de Antioquia]. www.udea.edu.co

Demizu, T., Fukazawa, Y. & Morita, H. (2023). Inventory management of new products in retailers using model-based deep reinforcement learning. *Expert Systems with Applications*, 229. <https://doi.org/10.1016/j.eswa.2023.120256>

Dini, M., Gligo, N. & Patiño, A. (2021). *Transformación digital de las mipymes: elementos para el diseño de políticas*. <https://hdl.handle.net/11362/47183>

Falkner, D., Bögl, M., Gattinger, A., Stainko, R., Zenisek, J. & Affenzeller, M. (2024). Integrating Machine Learning into Supply Chain Management: Challenges and Opportunities. *Procedia Computer Science*, 232, 1779-1788. <https://doi.org/10.1016/j.procs.2024.01.176>

Fuior, F. (2021). Introducere în cadrele Python pentru dezvoltare web. *Revista Română de Informatică și Automatică*, 31(3), 97-108. <https://doi.org/10.33436/v31i3y202108>

Galarreta, A. A. & Márquez, E. M. (2021). *Sistema de gestión de inventarios en la producción de autotransformadores eléctricos para electrodomésticos en PYMES del sector manufactura usando machine learning* [Universidad Peruana de Ciencias Aplicadas]. <http://hdl.handle.net/10757/656319>

Gardas, R. & Narwane, S. (2024). An analysis of critical factors for adopting machine learning in manufacturing supply chains. *Decision Analytics Journal*, 10. <https://doi.org/10.1016/j.dajour.2023.100377>

Hadi, M., Martel, C., Huayta, F., Rojas, R. & Arias, J. (2023). Metodología de la investigación: Guía para el proyecto de tesis. En *Metodología de la investigación: Guía para el proyecto de tesis*. Instituto Universitario de Innovación Ciencia y Tecnología Inudi Perú. <https://doi.org/10.35622/inudi.b.073>

Hamed, Y. A. & Jawad, M. K. (2023). INVENTORY ANALYSIS USING THE ABC-VED MATRIX - APPLIED RESEARCH IN AL-ZAWRAA STATE COMPANY. *International Journal of Professional Business Review*, 8(5). <https://doi.org/10.26668/businessreview/2023.v8i5.1508>

Hernández Sampieri, R. & Mendoza Torres, C. P. (2018). *Metodología de la investigación : las rutas cuantitativa, cualitativa y mixta*.

Higa, H. (2021). *Análisis de pronóstico de demanda para poder gestionar el inventario aplicado al sector salud* [Universidad de Lima]. <https://hdl.handle.net/20.500.12724/14099>

Janiesch, C., Zschech, P. & Heinrich, K. (2021). *Machine learning and deep learning*. <https://doi.org/10.1007/s12525-021-00475-2/Published>

Jimenez Perez, J. I. (2022). *Sistema web con datamart aplicando Machine learning para controlar el inventario y predecir las ventas en la empresa LeoGan Motors, año 2022*. <https://hdl.handle.net/20.500.12692/99056>

Kurpicz-Briki, M. (2023). More than a Chatbot. En *More than a Chatbot*. Springer Nature Switzerland. <https://doi.org/10.1007/978-3-031-37690-0>

Llasaca Segil, G. M. (2020). *FACULTAD DE INGENIERÍA Y ARQUITECTURA ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS* [Universidad César Vallejo]. <https://hdl.handle.net/20.500.12692/56409>

Maldonado Reyes, F. B., Álvarez Ochoa, R. I., Maldonado Córdova, P. A., Cordero Cordero, G. & Capote Llanares, M. (2023). *METODOLOGÍA DE LA INVESTIGACIÓN: de la teoría a la práctica* (Primera Edición). Puerto Madero Editorial Académica.

Moina, V. B. & Changoluisa, J. L. (2021). *Diseño e implementación de un prototipo para el control de gestión de inventario del producto terminado en la Fábrica de Cueros El AL-CE basado en inteligencia artificial* [Escuela Superior Politécnica de Chimborazo]. <http://dspace.esPOCH.edu.ec/handle/123456789/15965>

Ñaupas Paitán, H., Mejía Mejía, E., Trujillo Román, I. R., Romero Delgado, H. E., Medina Bárcena, W. & Novoa Ramírez, E. (2023). *METODOLOGÍA DE LA INVESTIGACIÓN TOTAL Cuantitativa-Cualitativa y Redacción de tesis* (Sexta edición). Ediciones de la U. www.edicionesdelau.com

Osorio, C. A. (2022). *Modelado y simulación basada en agentes de la gestión de un inventario de productos perecederos usando aprendizaje por refuerzo profundo basado en modelos calibrados* [Universidad de Málaga]. <https://hdl.handle.net/10630/25973>

Park, H., Choi, D. G. & Min, D. (2023). Adaptive inventory replenishment using structured reinforcement learning by exploiting a policy structure. *International Journal of Production Economics*, 109029. <https://doi.org/10.1016/j.ijpe.2023.109029>

Purisaca, G. M. & Zavaleta, R. J. (2019). *Sistema web para el control de inventario del área de gabinete en el proyecto del museo de sitio de Túcumbe-Lambayeque* [Universidad Nacional de Trujillo].

<http://dspace.unitru.edu.pe/handle/UNITRU/13931>

Ramírez Torres, M. J. (2022). *Sistema web con apoyo de un chatbot para el proceso de control de inventarios en una empresa comercial de TI*. <https://hdl.handle.net/20.500.12692/105748>

Richards, T. J. & Hamilton, S. F. (2022). Inventory management and loss in beer retailing. *Agribusiness*, 38(3), 461-485. <https://doi.org/10.1002/agr.21740>

Rodríguez Rodríguez, C., Breña Oré, J. L. & Esenarro Vargas, D. (2021). *Las variables en la metodología de la investigación científica*. <https://doi.org/https://doi.org/10.17993/IngyTec.2021.78>

Sandoval, L. (2018). ALGORITMOS DE APRENDIZAJE AUTOMÁTICO PARA ANÁLISIS Y PREDICCIÓN DE DATOS. *REVISTA TECNOLÓGICA*, 11, 36-40.

Schröer, C., Kruse, F. & Gómez, J. M. (2021). A systematic literature review on applying CRISP-DM process model. *Procedia Computer Science*, 181, 526-534. <https://doi.org/10.1016/j.procs.2021.01.199>

Silva, S. D. (2019). *Aplicación web para el control de inventario en la empresa Popeyito del distrito de Ate* [Universidad César Vallejo]. <https://hdl.handle.net/20.500.12692/86570>

Sridhar, P., Vishnu, C. R. & Sridharan, R. (2021). Simulation of inventory management systems in retail stores: A case study. *Materials Today: Proceedings*, 47, 5130-5134. <https://doi.org/10.1016/J.MATPR.2021.05.314>

Valdemar, E., Avalos, O., Emanuel, P., Valdivia, A. & Pérez, A. (2021). *Introducción al Machine Learning con MATLAB* (Primera edición). MARCOMBO, S.L.

Wang, C. C., Chien, C. H. & Trappey, A. J. C. (2021). On the application of ARIMA and LSTM to predict order demand based on short lead time and on-time delivery requirements. *Processes*, 9(7). <https://doi.org/10.3390/pr9071157>

Xu, Y., Zhou, Y., Sekula, P. & Ding, L. (2021). Machine learning in

construction: From shallow to deep learning. *Developments in the Built Environment*, 6. <https://doi.org/10.1016/j.dibe.2021.100045>

Zapata Cortés, J. Andrés. & Londoño Pulgarín, D. Alejandra. (2014). *Fundamentos de la gestión de inventarios*. Centro Editorial Esumer.

ANEXOS

Anexo 1

Tabla 16

Matriz de Operacionalización de Variables

PROBLEMA	OBJETIVO	HIPÓTESIS	OPERACIONALIZACIÓN DE VARIABLES		DIMENSIÓN	INDICADOR	METODOLOGÍA
			Variable Independiente	Variable Dependiente			
General	General	General	Machine Learning		NO APLICA	NO APLICA	Tipo de investigación: Aplicada Diseño de investigación:
P.G: ¿Cómo influye el Machine Learning en el Proceso de Administración del inventario?	O.G: Desarrollar Machine Learning en el proceso de Administración del inventario.	H.G: El Machine Learning permite mejorar El proceso de Administración del inventario.					
Específicos	Específicos	Específicos					
P.E.1: ¿Cómo influye el Machine Learning en el índice de rotación de inventario en el proceso	O.E.1: Determinar la influencia del Machine Learning en el índice de rotación	H.E.1: Machine Learning ayuda en el índice de rotación del inventario en el	Gestión de inventario			Índice de rotación de inventario	

Administración del Inventario?	de inventario en el Proceso de Administración del Inventario.	Proceso de Administración del inventario.		Gestión		Experimental Técnicas e instrumentos: Fichas de registro, órdenes de compra, cuestionario, etc. Tipo de investigación: Cuantitativa
P.E.2: ¿Cómo influye el Machine Learning en el Índice Duración del inventario en el Proceso de Administración del Inventario?	O.E.2: Determinar la influencia del Machine Learning en el Índice de duración del inventario en el Proceso de Administración del Inventario.	H.E.2: Machine Learning ayuda en el Índice de Duración del inventario en el Proceso de Administración del inventario.			Índice de Duración de inventario	

Fuente: Elaboración propia

Anexo 2

Tabla 17

Operacionalización de variables

OPERACIONALIZACIÓN DE VARIABLES					
Variable Independiente	Definición Conceptual	Definición Operacional	Dimensión	Indicadores	Escala de Medición
Machine Learning	“Es una rama de la Inteligencia Artificial que se encarga de generar algoritmos que tienen la capacidad de aprender y no tener que programarlos de manera explícita” (Sandoval, 2018, p.37).	NO APLICA.		NO APLICA	
Variable Dependiente	Definición conceptual	Definición operacional	Dimensión	Indicador	Escala de medición
Administración del Inventario	“La Administración de inventarios es un proceso clave en los resultados de una empresa. Asegura el abastecimiento de materiales en las operaciones y permite el equilibrio entre la demanda, las existencias y el flujo del capital” (Espejo, 2022, p.5).	“La gestión por indicadores es quizás la herramienta más práctica para este fin, ya que mediante relaciones de diferentes variables se puede determinar el desempeño y comportamiento de los materiales a almacenar en la organización” (Montoya, 2019, p.55).	Gestión	Índice de rotación de inventario	razón
				Índice de duración del inventario	

Indicadores	Descripción	Técnica	Instrumento	Unidad de medida	Formula
Índice de rotación de inventario	“Este indicador busca medir las veces en que la mercancía entra y sale de la organización (rotación del inventario) y es expresado como las veces en que el capital invertido en el inventario se recupera a través de las ventas” (Montoya, 2019, p. 56).	Fichaje	Ficha de registro	Unidad	$IRI = \frac{US}{IP}$ <p>IRI = Índice de rotación de inventario US = Unidades de salida IP =Inventario promedio</p>
Índice de Duración de inventario	“Este indicador busca determinar el tiempo que la mercancía está en inventario, de manera que pueda conocerse el nivel de inventario en riesgo de perderse o quedar obsoleto.” (Montoya, 2019, p. 57).	Fichaje	Ficha de registro	Unidad	$IDI = \frac{IF}{SP} x 30$ <p>IDI = Índice de duración de inventario IF = Inventario Final SP = Salidas Promedio</p>

Fuente: Elaboración propia

Anexo 4

Autorización de la empresa



Autorización de la organización para publicar su identidad en los resultados de las investigaciones

Datos Generales

Nombre de la Organización:	RUC: 20669362201
GROUP ALCANTARA	
Nombre del Titular o Representante legal:	Alcantara Gutierrez Nelly Nathalie
Nombres y Apellidos	DNI:
Nelly Nathalie Alcantara Gutierrez	46352538

Consentimiento:

De conformidad con lo establecido en el artículo 8°, literal "c" del Código de Ética en Investigación de la Universidad César Vallejo (RCU Nro. 0470-2022/UCV) (*), autorizo [x], no autorizo [] publicar LA IDENTIDAD DE LA ORGANIZACIÓN, en la cual se lleva a cabo la investigación:



Nombre del Trabajo de Investigación	
Machine Learning en el Proceso de Administración del inventario	
Nombre del Programa Académico:	
Autor: Nombres y Apellidos	DNI:
James Steven Montalvo Celis Giuseppe Antony Flores Taguiri	45509704 48039011

En caso de autorizarse, soy consciente que la investigación será alojada en el Repositorio Institucional de la UCV, la misma que será de acceso abierto para los usuarios y podrá ser referenciada en futuras investigaciones, dejando en claro que los derechos de propiedad intelectual corresponden exclusivamente al autor (a) del estudio.

Lugar y Fecha:

GROUP ALCANTARA E.I.R.L.

Firma: Nathalie Alcantara Gutierrez

(Titular o Representante legal de la Institución)

(* Código de Ética en Investigación de la Universidad César Vallejo-Artículo 8°, literal "c" Para difundir o publicar los resultados de un trabajo de investigación es necesario mantener bajo anonimato el nombre de la institución donde se llevó a cabo el estudio, salvo el caso en que haya un acuerdo formal con el gerente o director de la organización, para que se difunda la identidad de la institución. Por ello, tanto en los proyectos de investigación como en las tesis, no se deberá incluir la denominación de la organización, ni en el cuerpo de la tesis ni en los anexos, pero sí será necesario describir sus características.

Anexo 5

Consentimiento informado

Consentimiento Informado

Título de la investigación: Machine learning para la predicción en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos.

Investigador (a) (es): Flores Taquiri, Giuseppe Anthony y Montalvo Celis, James

Propósito del estudio

Le invitamos a participar en la investigación titulada "Machine learning para la predicción en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos", cuyo objetivo es determinar cómo influye un modelo de Machine learning para la predicción en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos. Esta investigación es desarrollada por estudiantes del programa de estudio de ingeniería de sistemas, de la Universidad César Vallejo del campus los Olivos, aprobado por la autoridad correspondiente de la Universidad y con el permiso de la institución Group Alcantara S.A.

Describir el impacto del problema de la investigación.

Es crucial para justificar la investigación y la implementación de soluciones basadas en machine learning. La identificación y cuantificación de estos impactos no solo destacan la gravedad del problema, sino que también subrayan la necesidad de mejorar la eficiencia operativa y la competitividad de la empresa. Al abordar estos problemas, la empresa puede mejorar significativamente su rendimiento financiero, satisfacción del cliente y sostenibilidad a largo plazo.

Procedimiento

Si usted decide participar en la investigación se realizará lo siguiente:

Se realizará una encuesta o entrevista donde se recogerán datos personales y algunas preguntas

Esta encuesta o entrevista tendrá un tiempo aproximado de 15 minutos y se realizará en el ambiente del área de recepción de la institución Group Alcantara S.A. Las respuestas al cuestionario o guía de entrevista serán codificadas usando un número de identificación y, por lo tanto, serán anónimas.

Participación voluntaria (principio de autonomía):

Puede hacer todas las preguntas para aclarar sus dudas antes de decidir si desea participar o no, y su decisión será respetada. Posterior a la aceptación no desea continuar puede hacerlo sin ningún problema.

Riesgo (principio de No maleficencia):

Indicar al participante la existencia que NO existe riesgo o daño al participar en la investigación. Sin embargo, en el caso que existan preguntas que le puedan generar incomodidad. Usted tiene la libertad de responderlas o no.

Beneficios (principio de beneficencia):

Se le informará que los resultados de la investigación se le alcanzará a la institución al término de la investigación. No recibirá ningún beneficio económico ni de ninguna otra índole. El estudio no va a aportar a la salud individual de la persona, sin embargo, los resultados del estudio podrán convertirse en beneficio de la salud pública.

Confidencialidad (principio de justicia):

Los datos recolectados deben ser anónimos y no tener ninguna forma de identificar al participante. Garantizamos que la información que usted nos brinde es totalmente Confidencial y no será usada para ningún otro propósito fuera de la investigación. Los datos permanecerán bajo custodia del investigador principal y pasado un tiempo determinado serán eliminados convenientemente.

Problemas o preguntas:

Si tiene preguntas sobre la investigación puede contactar con el Investigador (a) (es) Flores Taquiri, Giusseph Anthony y Montalvo Celis, James email: gfloresta@ucvvirtual.edu.pe y jmontalvoce@ucvvirtual.edu.pe y asesor Mg. Quinteros Navarro, Dino Michael email: dquinterosna@ucvvirtual.edu.pe

Consentimiento

Después de haber leído los propósitos de la investigación autorizo participar en la investigación antes mencionada. Nombre y apellidos: Alcantara Gutiérrez, Nelly Nathalie, Fecha y hora: 15/08/2023 15:30pm

Nombre y apellidos: Alcantara Gutiérrez, Nelly Nathalie

Firma(s):

Fecha y hora: 15/08/2023 15:30pm

GROUP ALCANTARA E.I.R.L.

Nathalie Alcantara Gutiérrez
GERENTE GENERAL

Anexo 6

Declaración jurada

Declaración jurada de asunción de responsabilidades en el caso de potencial daño físico o psicológico del participante

Título de la investigación: Machine learning para la predicción en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos.

Investigador (a) (es): Flores Taquiri, Giusseph Anthony y Montalvo Celis, James

Por medio de la presente declaración se precisa que el Trabajo de investigación / Tesis propuesto NO CORRESPONDE A ESTUDIOS O ENSAYOS CLÍNICOS; motivo por el cual, se declara que no se realizarán actividades relacionadas a ello bajo ninguna circunstancia.

El Estudiante declara que los datos emitidos en esta carta y en la Tesis son auténticos. En caso de comprobarse la falsedad de datos, el Estudiante será sometido al inicio del procedimiento disciplinario correspondiente; asimismo, asumirá toda la responsabilidad ante posibles actividades ajenas a la naturaleza de la investigación.



Firma del Estudiante

DNI: 48039011



Firma del Estudiante

DNI: 45509704

Anexo 7

Autorización de uso de información de la empresa

AUTORIZACIÓN DE USO DE INFORMACIÓN DE EMPRESA

Yo ALCANTARA GUTIERREZ NELLY NATHALIE identificado con DNI 46352538, en mi calidad de Gerente general del área de Logística de la empresa GROUP ALCANTARA con R.U.C N° 20609362201, ubicada en la ciudad de Lima.

OTORGO LA AUTORIZACIÓN,

Al señor JAMES STIVEN MONTALVO CELIS Y FLORES TAQUIRI GIUSSEPH ANTONY

Identificados con DNI N°45509704 y 48039011 respectivamente, de la Carrera profesional Ingeniería de sistemas, para que utilice la siguiente información de la empresa:

.....
.....
.....
(Detallar la información a entregar)

con la finalidad de que pueda desarrollar su Tesis para optar el Título Profesional, Trabajo de investigación para optar al grado de Bachiller, Trabajo de Investigación Formativa, Trabajo académico, Otro (especificar).

Indicar si el Representante que autoriza la información de la empresa, solicita mantener el nombre o cualquier distintivo de la empresa en reserva, marcando con una "X" la opción seleccionada.


- Mantener en Reserva el nombre o cualquier distintivo de la empresa; o
 Mencionar el nombre de la empresa.

GROUP ALCANTARA E.I.R.L.


Nathalie Alcantara Gutierrez
GERENTE GENERAL

Firma y sello del Representante Legal
DNI:46352538

El Estudiante declara que los datos emitidos en esta carta y en el Trabajo de Investigación / en la Tesis son auténticos. En caso de comprobarse la falsedad de datos, el Estudiante será sometido al inicio del procedimiento disciplinario correspondiente; asimismo, asumirá toda la responsabilidad ante posibles acciones legales que la empresa, otorgante de información, pueda ejecutar.


Firma del Estudiante
DNI: 45509704


Firma del Estudiante
DNI: 48039011

Anexo 8

Carta de aceptación

CARTA DE ACEPTACIÓN DE LA EMPRESA GROUP ALCÁNTARA

Lima, 1 de Julio del 2023

Doc. Lily Doris Salazar Chávez
Directora de la Escuela Profesional de Ingeniería de Sistemas
Universidad Cesar Vallejo

Asunto: Aprobación para realización de estudio de investigación

Presente. -

De mi mayor consideración:

Mediante la presente es grato dirigirme a usted a fin de saludarle quien suscribe Alcántara Gutiérrez, Nelly Nathalie , identificado con DNI N° 46352538, representante de la empresa GROUP ALCÁNTARA, con RUC N° 20609362201, hace constar que los Sr. Montalvo Celis, James Stiven identificado con DNI N° 45509704 y el Sr. Flores Taquiri, Giusseph Antony identificado con DNI N° 48039011, alumnos de la escuela de Ingeniería de sistemas de la Universidad Cesar Vallejo en Lima-Perú, han sido aprobados para realizar la investigación de desarrollo de tesis en nuestra empresa.

Agradeciendo su atención a la presente, es propia la oportunidad de expresarle las muestras de mi consideración y estima.

Atentamente.

GROUP ALCANTARA E.I.R.L.

Nathalie Alcántara Gutiérrez
GERENTE GENERAL

ALCÁNTARA GUTIERREZ NELLY NATHALIE
DNI: 46352538
Gerente General

Anexo 9

Carta de presentación

Lima, 15 de 08 de 2023

Señor (a):
Alcántara Gutiérrez, Nelly Nathalie
Gerente general
Group Alcántara E.I.R.L.
Presente.


Es grato dirigirme a usted para saludarlo, y a la vez manifestarle que dentro de mi formación académica en la experiencia curricular de investigación del X ciclo, se contempla la realización de una investigación con fines de obtención de mi título profesional al finalizar mi carrera.

En tal sentido, considerando la relevancia de su organización, solicito su colaboración, para que pueda realizar mi investigación en su representada y obtener la información necesaria para poder desarrollar la investigación titulada: "Machine Learning para la predicción en la gestión de Inventarios dirigida a PYMES de venta de productos tecnológicos". En dicha investigación me comprometo a mantener en reserva el nombre o cualquier distintivo de la empresa, salvo que se crea a bien su socialización.

Se adjunta la carta de autorización de uso de información en caso que se considere la aceptación de esta solicitud para ser llenada por el representante de la empresa.

Agradeciéndole anticipadamente por vuestro apoyo en favor de mi formación profesional, hago propicia la oportunidad para expresar las muestras de mi especial consideración.

Atentamente,



Flores Taquiri, Giusseph Anthony
DNI 48039011



Montalvo Celis, James
DNI 45509704

Anexo 10

Validación del cuestionario

VALIDACIÓN DE CONTENIDO DEL CUESTIONARIO SOBRE MACHINE LEARNING PARA LA PREDICCIÓN EN LA GESTIÓN DE INVENTARIOS DIRIGIDA A PYMES DE PRODUCTOS TECNOLÓGICOS.

INSTRUCCIÓN: A continuación, se le hace llegar el presente cuestionario que permitirá recoger los datos para la investigación: Machine learning para la predicción en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos, Por lo que se le solicita que tenga a bien evaluar este instrumento, haciendo, de ser caso, las sugerencias para realizar las correcciones pertinentes. Los criterios de validación de contenido son:

Criterios	Detalle	Calificación
Suficiencia	El ítem pertenece a la dimensión y basta para obtener la medición de esta	1: de acuerdo 0: en desacuerdo
Claridad	El ítem se comprende fácilmente, es decir, su sintáctica y semántica son adecuadas	1: de acuerdo 0: en desacuerdo
Coherencia	El ítem tiene relación lógica con el indicador que está midiendo	1: de acuerdo 0: en desacuerdo
Relevancia	El ítem es esencial o importante, es decir, debe ser incluido	1: de acuerdo 0: en desacuerdo

Nota. Criterios adaptados de la propuesta de Escobar y Cuervo (2008).

MATRIZ DE VALIDACIÓN DEL CUESTIONARIO DE LA VARIABLE DE GESTIÓN DE INVENTARIO

Definición de la variable: La gestión de inventario como al proceso encargado de asegurar la cantidad de productos adecuados en la organización, de tal manera que se pueda asegurar la operación continua de los procesos de comercialización de productos a los clientes; es decir, asegurar que las operaciones de manufactura y distribución no se detengan, cumpliendo con las promesas de entrega de productos a los clientes.

Instrumento elaborado en base a los aportes de Zapata Cortes, Julián Andrés en su libro "Fundamentos de la gestión de inventarios".

url: <https://www.academia.edu/36587620/Fundamentosdelagestiondeinventarios>.

Dimensión	Indicador	Ítem o enunciado	Suficiencia	Claridad	Coherencia	Relevancia	Observación
Gestión	Rotación de inventario	¿Qué tan frecuentemente los productos en su inventario tienen alta demanda?	1	1	1	1	
		¿Con qué frecuencia identifica productos específicos que no se están vendiendo bien y resultan en un exceso de stock?	1	1	1	1	
		¿Con qué frecuencia la falta de disponibilidad de productos de alta demanda resulta en pérdida de ventas?	1	1	1	1	
		¿Cree que los sistemas o métodos actuales que utiliza para gestionar su inventario son adecuados?	1	1	1	1	
		¿Con qué frecuencia sus métodos actuales de previsión de demanda son precisos?	1	1	1	1	
	Duración de inventario	¿Podría indicar si el estado actual de su inventario es óptimo?	1	1	1	1	
		¿Con qué frecuencia el exceso de inventario afecta significativamente sus costos de almacenamiento?	1	1	1	1	
		¿Con qué frecuencia el exceso de productos afecta la eficiencia del uso del espacio en su almacén?	1	1	1	1	
		¿Con qué frecuencia la inmovilización de capital en productos no	1	1	1	1	

		vendibles afecta la liquidez de la empresa?					
		¿Con qué frecuencia cree que la gestión ineficiente del inventario afecta la competitividad de su empresa en el mercado?	1	1	1	1	

Cuestionario para medir la variable de gestión de inventario

Estimado/a participante:

Esta es una investigación llevada a cabo por estudiantes de la Universidad César Vallejo; los datos recopilados serán anónimos, serán tratados de forma confidencial y tienen finalidad netamente académica. Por tanto, en forma voluntaria; SÍ (X) NO () doy mi consentimiento para participar en la investigación que tiene como título Machine learning para la predicción en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos, Asimismo, autorizo para que los resultados de la presente investigación se publiquen manteniendo mi anonimato.

Marque con una "X" valorando cada ítem o enunciado según la escala:

Siempre (S)	Casi siempre (CS)	A veces (A)	Casi nunca (CN)	Nunca (N)
5	4	3	2	1

Enunciado	S	CS	A	CN	N
Dimensión 1: Gestión	5	4	3	2	1
¿Qué tan frecuentemente los productos en su inventario tienen alta demanda?			X		
¿Con qué frecuencia identifica productos específicos que no se están vendiendo bien y resultan en un exceso de stock?				X	
¿Con qué frecuencia la falta de disponibilidad de productos de alta demanda resulta en pérdida de ventas?		X			
¿Cree que los sistemas o métodos actuales que utiliza para gestionar su inventario son adecuados?				X	
¿Con qué frecuencia sus métodos actuales de previsión de demanda son precisos?				X	
¿Podría indicar si el estado actual de su inventario es óptimo?			X		
¿Con qué frecuencia el exceso de inventario afecta significativamente sus costos de almacenamiento?		X			
¿Con qué frecuencia el exceso de productos afecta la eficiencia del uso del espacio en su almacén?		X			
¿Con qué frecuencia la inmovilización de capital en productos no vendibles afecta la liquidez de la empresa?	X				
¿Con qué frecuencia cree que la gestión ineficiente del inventario afecta la competitividad de su empresa en el mercado?		X			

¡Muchas gracias por su participación!

FICHA DE VALIDACIÓN DE JUICIO DE EXPERTO

Nombre del instrumento	
Nombres y apellidos del experto	Dino Michael Quinteros Navarro
Documento de identidad	41567782
Años de experiencia laboral	17
Máximo grado académico	Maestría Dirección de Tecnología de la Información
Nacionalidad	Peruana
Institución laboral	Universidad César Vallejo
Labor que desempeña	Docente Universitario
Número telefónico	981306306
Correo electrónico	dquinterosna@ucv.edu.pe
Firma	
Fecha	01 / 06 / 2024

Anexo 11

Ficha de Registro Re-test de la rotación de inventario

Ficha de registro					
Tipo de prueba:		Re-Test			
Empresa investigada:		Group Alcántara E.I.R.L.			
Motivo:		Índice de rotación de inventario			
Investigador(es):		Flores Taquiri, Giussep Anthony y Montalvo Celis, James Stiven			
Fecha de inicio:		01/08/2023	Fecha fin:	31/08/2023	
Variables		Indicadores		Medida	Formula
Gestión de inventario		Índice de rotación de inventario		Unidad	$IRI = \frac{\text{Unidades Salidas}}{\text{Inventario Promedio}}$
Id	Fecha	Articulo	Unidades salidas	Inventario promedio	IRI
1	Ago-23	DISCO SOLIDO KINGSTON 480GB	22	106	0.21
2	Ago-23	CABLE HDMI TEROS 5M	18	80	0.23
3	Ago-23	ADAPTADOR USB A TIPO C HOCO	31	78.5	0.39
4	Ago-23	TINTA EPSON LAGARTO T0631	39	46.5	0.84
5	Ago-23	PARLANTE HALION HA118	13	46.5	0.28
6	Ago-23	MOUSE LOGITECH M90	25	65.5	0.38
7	Ago-23	USB 32GB KINGSTON	6	60	0.10
8	Ago-23	TINTA BROTHER T500 BK	24	66	0.36
9	Ago-23	DISCO NV 500GB KINGSTON	12	87	0.14
10	Ago-23	TECLADO CYBERTEL K206 VORTEX	28	39	0.72
11	Ago-23	USB 32GB HP	3	49.5	0.06
12	Ago-23	TINTA 664 COLOR HP	23	36.5	0.63
13	Ago-23	CABLE HOCO IPHONE	4	61	0.07
14	Ago-23	CABEZAL HP 650 BK	4	63	0.06
15	Ago-23	AUDIFONO HOCO DM25	29	28.5	1.02
16	Ago-23	TINTAS 73 TOPJET	21	36.5	0.58
17	Ago-23	ADAPTADOR OTG V8 HOCO	1	59.5	0.02
18	Ago-23	AUDIFONO HALION S2	22	40	0.55
19	Ago-23	COMBO LOGITECH MK120	8	41	0.20
20	Ago-23	CABEZAL CANON KIT	16	56	0.29
21	Ago-23	MOUSE ENKORE GAMER	26	64	0.41
22	Ago-23	COMBO CYBERTEL TWISTER 3 EN 1	20	43	0.47
23	Ago-23	ESTABILIZADOR FORZA 900VA	14	38	0.37
24	Ago-23	PROCESADOR AMD RYZEN 3 2200G	7	41.5	0.17
25	Ago-23	PROCESADOR AMD RYZEN 5 2600X	8	31	0.26
26	Ago-23	PROCESADOR AMD RYZEN 3 3200G	2	45	0.04
27	Ago-23	PROCESADOR AMD RYZEN 5 3400G	12	32	0.38
28	Ago-23	PROCESADOR AMD RYZEN 5 3600	2	46	0.04
29	Ago-23	PROCESADOR AMD RYZEN 7 3700X	2	23	0.09
30	Ago-23	PROCESADOR AMD RYZEN 5 5600G	13	49.5	0.26
31	Ago-23	PROCESADOR AMD RYZEN 5 5600X	1	47.5	0.02
32	Ago-23	PROCESADOR AMD RYZEN 7 5700G	1	41.5	0.02
33	Ago-23	PROCESADOR AMD RYZEN 7 5800X3D	1	45.5	0.02

34	Oct-23	PROCESADOR AMD RYZEN 9 5950X	30	8	112.50
35	Oct-23	PROCESADOR INTEL I3 10100F	32	6	180.00
36	Oct-23	PROCESADOR INTEL I5 10400F	41	8	153.75
37	Oct-23	PROCESADOR INTEL I5 10600K	42	11	114.55
38	Oct-23	PROCESADOR INTEL I3 12100F	44	10	132.00
39	Oct-23	PROCESADOR INTEL I5 12600K	21	11	57.27
40	Oct-23	PROCESADOR INTEL I7 12700K	30	14	64.29
41	Oct-23	PROCESADOR INTEL I9 12900K	20	10	60.00
42	Oct-23	TARJETA VIDEO ASUS RTX3060 8GB OC	25	13	57.69
43	Oct-23	TARJETA VIDEO ASUS RTX3060TI 8GB OC	18	24	22.50
44	Oct-23	TARJETA VIDEO GIGABYTE GT730 2GB	25	9	83.33
45	Oct-23	TARJETA DE VIDEO GIGABYTE GT1030 2GB	22	11	60.00
46	Oct-23	TARJETA DE VIDEO GIGABYTE RTX3070 8GB	24	15	48.00
47	Oct-23	TARJETA DE VIDEO MSI GT730 2GB	23	12	57.50
48	Oct-23	TARJETA DE VIDEO MSI RTX3050 8GB	20	13	46.15
49	Oct-23	TARJETA DE VIDEO ZOTAC GTX1650 4GB	22	12	55.00
50	Oct-23	TARJETA DE VIDEO ZOTAC RTX3070 TI 8GB	8	12	20.00
51	Oct-23	CASE GAMBYTE SCALE ARGB BLACK	17	13	39.23
52	Oct-23	CASE DEEPCOOL MATREXX CC560 ARGB BLACK	11	19	17.37
53	Oct-23	CASE ANTEC NX410 ARGB BLACK	13	19	20.53
54	Oct-23	FUENTE COOLER MASTER 650W 80 PLUS BRONZE	12	20	18.00
55	Oct-23	FUENTE GIGABYTE P550B 550W 80 PLUS BRONZE	15	25	18.00


 GROUP ALCANTARA E.I.R.L.
 Nethelle Alcantara Gutiérrez
 GERENTE GENERAL

Anexo 13

Ficha de Registro Re-test de la duración de inventario

Ficha de registro					
Tipo de prueba:		Re-Test			
Empresa investigada:		Group Alcantara E.I.R.L.			
Motivo:		Índice de duración de inventario			
Investigador(es):		Flores Taquiri, Giusseph Anthony y Montalvo Celis, James Stiven			
Fecha de inicio:		01/08/2023	Fecha fin:	31/08/2023	
Variables		Indicadores		Medida	Formula
Gestión de inventario		Índice de duración de inventario		Días	$IDI = \frac{\text{Inventario Final}}{\text{Salidas Promedio}} \times 30$
Id	Fecha	Articulo	Inventario final	Salidas promedio	IDI
1	Ago-23	DISCO SOLIDO KINGSTON 480GB	95	22	129.55
2	Ago-23	CABLE HDMI TEROS 5M	71	18	118.33
3	Ago-23	ADAPTADOR USB A TIPO C HOCO	63	31	60.97
4	Ago-23	TINTA EPSON LAGARTO T0631	27	39	20.77
5	Ago-23	PARLANTE HALION HA118	40	13	92.31
6	Ago-23	MOUSE LOGITECH M90	53	25	63.60
7	Ago-23	USB 32GB KINGSTON	57	6	285.00
8	Ago-23	TINTA BROTHER T500 BK	54	24	67.50
9	Ago-23	DISCO NV 500GB KINGSTON	81	12	202.50
10	Ago-23	TECLADO CYBERTEL K206 VORTEX	25	28	26.79
11	Ago-23	USB 32GB HP	48	3	480.00
12	Ago-23	TINTA 664 COLOR HP	25	23	32.61
13	Ago-23	CABLE HOCO IPHONE	59	4	442.50
14	Ago-23	CABEZAL HP 650 BK	61	4	457.50
15	Ago-23	AUDIFONO HOCO DM25	14	29	14.48
16	Ago-23	TINTAS 73 TOPJET	26	21	37.14
17	Ago-23	ADAPTADOR OTG V8 HOCO	59	1	1770.00
18	Ago-23	AUDIFONO HALION S2	29	22	39.55
19	Ago-23	COMBO LOGITECH MK120	37	8	138.75
20	Ago-23	CABEZAL CANON KIT	48	16	90.00
21	Ago-23	MOUSE ENKORE GAMER	51	26	58.85
22	Ago-23	COMBO CYBERTEL TWISTER 3 EN 1	33	20	49.50
23	Ago-23	ESTABILIZADOR FORZA 900VA	31	14	66.43
24	Ago-23	PROCESADOR AMD RYZEN 3 2200G	38	7	162.86
25	Ago-23	PROCESADOR AMD RYZEN 5 2600X	27	8	101.25
26	Ago-23	PROCESADOR AMD RYZEN 3 3200G	44	2	660.00
27	Ago-23	PROCESADOR AMD RYZEN 5 3400G	26	12	65.00
28	Ago-23	PROCESADOR AMD RYZEN 5 3600	45	2	675.00
29	Ago-23	PROCESADOR AMD RYZEN 7 3700X	22	2	330.00
30	Ago-23	PROCESADOR AMD RYZEN 5 5600G	43	13	99.23
31	Ago-23	PROCESADOR AMD RYZEN 5 5600X	47	1	1410.00
32	Ago-23	PROCESADOR AMD RYZEN 7 5700G	41	1	1230.00
33	Ago-23	PROCESADOR AMD RYZEN 7 5800X3D	45	1	1350.00
34	Ago-23	PROCESADOR AMD RYZEN 9 5950X	29	1	870.00

34	Oct-23	PROCESADOR AMD RYZEN 9 5950X	8	34	0.24
35	Oct-23	PROCESADOR INTEL I3 10100F	6	35	0.17
36	Oct-23	PROCESADOR INTEL I5 10400F	8	45	0.18
37	Oct-23	PROCESADOR INTEL I5 10600K	11	47.5	0.23
38	Oct-23	PROCESADOR INTEL I3 12100F	10	49	0.20
39	Oct-23	PROCESADOR INTEL I5 12600K	11	26.5	0.42
40	Oct-23	PROCESADOR INTEL I7 12700K	14	37	0.38
41	Oct-23	PROCESADOR INTEL I9 12900K	10	25	0.40
42	Oct-23	TARJETA VIDEO ASUS RTX3060 8GB OC	13	31.5	0.41
43	Oct-23	TARJETA VIDEO ASUS RTX3060TI 8GB OC	24	30	0.80
44	Oct-23	TARJETA VIDEO GIGABYTE GT730 2GB	9	29.5	0.31
45	Oct-23	TARJETA DE VIDEO GIGABYTE GT1030 2GB	11	27.5	0.40
46	Oct-23	TARJETA DE VIDEO GIGABYTE RTX3070 8GB	15	31.5	0.48
47	Oct-23	TARJETA DE VIDEO MSI GT730 2GB	12	29	0.41
48	Oct-23	TARJETA DE VIDEO MSI RTX3050 8GB	13	26.5	0.49
49	Oct-23	TARJETA DE VIDEO ZOTAC GTX1650 4GB	12	28	0.43
50	Oct-23	TARJETA DE VIDEO ZOTAC RTX3070 TI 8GB	12	14	0.86
51	Oct-23	CASE GAMBYTE SCALE ARGB BLACK	13	23.5	0.55
52	Oct-23	CASE DEEPCOOL MATREXX CC560 ARGB BLACK	19	20.5	0.93
53	Oct-23	CASE ANTEC NX410 ARGB BLACK	19	22.5	0.84
54	Oct-23	FUENTE COOLER MASTER 650W 80 PLUS BRONZE	20	22	0.91
55	Oct-23	FUENTE GIGABYTE P550B 550W 80 PLUS BRONZE	25	27.5	0.91

GROUP ALCANTARA E.I.R.L.

 Nathelle Alcantara Gubierrez
 GERENTE GENERAL

Anexo 14

Ficha de Registro Pre-test de la rotación de inventario

Ficha de registro					
Tipo de prueba:		Pre-Test			
Empresa investigada:		Group Alcantara E.I.R.L.			
Motivo:		Índice de rotación de inventario			
Investigador(es):		Flores Taquiri, Giusseph Anthony y Montalvo Celis, James Stiven			
Fecha de inicio:		01/09/2023	Fecha fin:	30/09/2023	
Variables		Indicadores		Medida	Formula
Gestión de inventario		Índice de rotación de inventario		Unidad	$IRI = \frac{\text{Unidades Salidas}}{\text{Inventario Promedio}}$
Id	Fecha	Articulo	Unidades salidas	Inventario promedio	IRI
1	Set-23	DISCO SOLIDO KINGSTON 480GB	112	26	0.23
2	Set-23	CABLE HDMI TEROS 5M	91.5	19	0.21
3	Set-23	ADAPTADOR USB A TIPO C HOCO	79.5	27	0.34
4	Set-23	TINTA EPSON LAGARTO T0631	43.5	37	0.85
5	Set-23	PARLANTE HALION HA118	53	14	0.26
6	Set-23	MOUSE LOGITECH M90	62.5	21	0.34
7	Set-23	USB 32GB KINGSTON	76	2	0.03
8	Set-23	TINTA BROTHER T500 BK	69.5	19	0.27
9	Set-23	DISCO NV 500GB KINGSTON	96.5	9	0.09
10	Set-23	TECLADO CYBERTEL K206 VORTEX	46	18	0.39
11	Set-23	USB 32GB HP	66	4	0.06
12	Set-23	TINTA 664 COLOR HP	35	30	0.86
13	Set-23	CABLE HOCO IPHONE	75	8	0.11
14	Set-23	CABEZAL HP 650 BK	78	6	0.08
15	Set-23	AUDIFONO HOCO DM25	35.5	27	0.76
16	Set-23	TINTAS 73 TOPJET	41	20	0.49
17	Set-23	ADAPTADOR OTG V8 HOCO	78	2	0.03
18	Set-23	AUDIFONO HALION S2	45.5	17	0.37
19	Set-23	COMBO LOGITECH MK120	45.5	23	0.51
20	Set-23	CABEZAL CANON KIT	67	12	0.18
21	Set-23	MOUSE ENKORE GAMER	59.5	23	0.39
22	Set-23	COMBO CYBERTEL TWISTER 3 EN 1	43	20	0.47
23	Set-23	ESTABILIZADOR FORZA 900VA	38.5	15	0.39
24	Set-23	PROCESADOR AMD RYZEN 3 2200G	50.5	5	0.10
25	Set-23	PROCESADOR AMD RYZEN 5 2600X	36	12	0.33
26	Set-23	PROCESADOR AMD RYZEN 3 3200G	58.5	1	0.02
27	Set-23	PROCESADOR AMD RYZEN 5 3400G	35.5	11	0.31
28	Set-23	PROCESADOR AMD RYZEN 5 3600	59.5	1	0.02
29	Set-23	PROCESADOR AMD RYZEN 7 3700X	34.5	5	0.14
30	Set-23	PROCESADOR AMD RYZEN 5 5600G	62.5	11	0.18
31	Set-23	PROCESADOR AMD RYZEN 5 5600X	61.5	1	0.02
32	Set-23	PROCESADOR AMD RYZEN 7 5700G	54.5	3	0.06
33	Set-23	PROCESADOR AMD RYZEN 7 5800X3D	60.5	1	0.02

34	Ago-23	PROCESADOR AMD RYZEN 9 5950X	1	29.5	0.03
35	Ago-23	PROCESADOR INTEL I3 10100F	4	35	0.11
36	Ago-23	PROCESADOR INTEL I5 10400F	1	40.5	0.02
37	Ago-23	PROCESADOR INTEL I5 10600K	1	44.5	0.02
38	Ago-23	PROCESADOR INTEL I3 12100F	1	45.5	0.02
39	Ago-23	PROCESADOR INTEL I5 12600K	12	31	0.39
40	Ago-23	PROCESADOR INTEL I7 12700K	2	36	0.06
41	Ago-23	PROCESADOR INTEL I9 12900K	3	23.5	0.13
42	Ago-23	TARJETA VIDEO ASUS RTX3060 8GB OC	5	34.5	0.14
43	Ago-23	TARJETA VIDEO ASUS RTX3060TI 8GB OC	19	20.5	0.93
44	Ago-23	TARJETA VIDEO GIGABYTE GT730 2GB	8	32	0.25
45	Ago-23	TARJETA DE VIDEO GIGABYTE GT1030 2GB	7	30.5	0.23
46	Ago-23	TARJETA DE VIDEO GIGABYTE RTX3070 8GB	2	31	0.06
47	Ago-23	TARJETA DE VIDEO MSI GT730 2GB	5	30.5	0.16
48	Ago-23	TARJETA DE VIDEO MSI RTX3050 8GB	6	27	0.22
49	Ago-23	TARJETA DE VIDEO ZOTAC GTX1650 4GB	6	31	0.19
50	Ago-23	TARJETA DE VIDEO ZOTAC RTX3070 TI 8GB	10	16	0.63
51	Ago-23	CASE GAMBYTE SCALE ARGB BLACK	7	19.5	0.36
52	Ago-23	CASE DEEPCOOL MATREXX CC560 ARGB BLACK	9	18.5	0.49
53	Ago-23	CASE ANTEC NX410 ARGB BLACK	8	19	0.42
54	Ago-23	FUENTE COOLER MASTER 650W 80 PLUS BRONZE	13	29.5	0.44
55	Ago-23	FUENTE GIGABYTE P550B 550W 80 PLUS BRONZE	14	33	0.42

GRUPO

 Nathalia Alcántara Gutiérrez
 GERENTE GENERAL

Anexo 14

Ficha de Registro Pre-test de la duración de inventario

Ficha de registro					
Tipo de prueba:		Pre-Test			
Empresa investigada:		Group Alcantara E.I.R.L.			
Motivo:		Índice de duración de inventario			
Investigador(es):		Flores Taquiri, Giusseph Anthony y Montalvo Celis, James Stiven			
Fecha de inicio:		01/09/2023	Fecha fin:	30/09/2023	
Variables		Indicadores		Medida	Formula
Gestión de inventario		Índice de duración de inventario		Días	$IDI = \frac{\text{Inventario Final}}{\text{Salidas Promedio}} \times 30$
Id	Fecha	Articulo	Inventario final	Salidas promedio	IDI
1	Set-23	DISCO SOLIDO KINGSTON 480GB	99	26	114.23
2	Set-23	CABLE HDMI TEROS 5M	82	19	129.47
3	Set-23	ADAPTADOR USB A TIPO C HOCO	66	27	73.33
4	Set-23	TINTA EPSON LAGARTO T0631	25	37	20.27
5	Set-23	PARLANTE HALION HA118	46	14	98.57
6	Set-23	MOUSE LOGITECH M90	52	21	74.29
7	Set-23	USB 32GB KINGSTON	75	2	1125.00
8	Set-23	TINTA BROTHER T500 BK	60	19	94.74
9	Set-23	DISCO NV 500GB KINGSTON	92	9	306.67
10	Set-23	TECLADO CYBERTEL K206 VORTEX	37	18	61.67
11	Set-23	USB 32GB HP	64	4	480.00
12	Set-23	TINTA 664 COLOR HP	20	30	20.00
13	Set-23	CABLE HOCO IPHONE	71	8	266.25
14	Set-23	CABEZAL HP 650 BK	75	6	375.00
15	Set-23	AUDIFONO HOCO DM25	22	27	24.44
16	Set-23	TINTAS 73 TOPJET	31	20	46.50
17	Set-23	ADAPTADOR OTG V8 HOCO	77	2	1155.00
18	Set-23	AUDIFONO HALION S2	37	17	65.29
19	Set-23	COMBO LOGITECH MK120	34	23	44.35
20	Set-23	CABEZAL CANON KIT	61	12	152.50
21	Set-23	MOUSE ENKORE GAMER	48	23	62.61
22	Set-23	COMBO CYBERTEL TWISTER 3 EN 1	33	20	49.50
23	Set-23	ESTABILIZADOR FORZA 900VA	31	15	62.00
24	Set-23	PROCESADOR AMD RYZEN 3 2200G	48	5	288.00
25	Set-23	PROCESADOR AMD RYZEN 5 2600X	30	12	75.00
26	Set-23	PROCESADOR AMD RYZEN 3 3200G	58	1	1740.00
27	Set-23	PROCESADOR AMD RYZEN 5 3400G	30	11	81.82
28	Set-23	PROCESADOR AMD RYZEN 5 3600	59	1	1770.00
29	Set-23	PROCESADOR AMD RYZEN 7 3700X	32	5	192.00
30	Set-23	PROCESADOR AMD RYZEN 5 5600G	57	11	155.45
31	Set-23	PROCESADOR AMD RYZEN 5 5600X	61	1	1830.00
32	Set-23	PROCESADOR AMD RYZEN 7 5700G	53	3	530.00
33	Set-23	PROCESADOR AMD RYZEN 7 5800X3D	60	1	1800.00

35	Ago-23	PROCESADOR INTEL I3 10100F	33	4	247.50
36	Ago-23	PROCESADOR INTEL I5 10400F	40	1	1200.00
37	Ago-23	PROCESADOR INTEL I5 10600K	44	1	1320.00
38	Ago-23	PROCESADOR INTEL I3 12100F	45	1	1350.00
39	Ago-23	PROCESADOR INTEL I5 12600K	25	12	62.50
40	Ago-23	PROCESADOR INTEL I7 12700K	35	2	525.00
41	Ago-23	PROCESADOR INTEL I9 12900K	22	3	220.00
42	Ago-23	TARJETA VIDEO ASUS RTX3060 8GB OC	32	5	192.00
43	Ago-23	TARJETA VIDEO ASUS RTX3060TI 8GB OC	11	19	17.37
44	Ago-23	TARJETA VIDEO GIGABYTE GT730 2GB	28	8	105.00
45	Ago-23	TARJETA DE VIDEO GIGABYTE GT1030 2GB	27	7	115.71
46	Ago-23	TARJETA DE VIDEO GIGABYTE RTX3070 8GB	30	2	450.00
47	Ago-23	TARJETA DE VIDEO MSI GT730 2GB	28	5	168.00
48	Ago-23	TARJETA DE VIDEO MSI RTX3050 8GB	24	6	120.00
49	Ago-23	TARJETA DE VIDEO ZOTAC GTX1650 4GB	28	6	140.00
50	Ago-23	TARJETA DE VIDEO ZOTAC RTX3070 TI 8GB	11	10	33.00
51	Ago-23	CASE GAMBYTE SCALE ARGB BLACK	16	7	68.57
52	Ago-23	CASE DEEPCOOL MATREXX CC560 ARGB BLACK	14	9	46.67
53	Ago-23	CASE ANTEC NX410 ARGB BLACK	15	8	56.25
54	Ago-23	FUENTE COOLER MASTER 650W 80 PLUS BRONZE	23	13	53.08
55	Ago-23	FUENTE GIGABYTE P550B 550W 80 PLUS BRONZE	26	14	55.71

GROUP ALCANTARA E.I.R.L.

 Nathalle Alcantara Gutierrez
 GERENTE GENERAL

Anexo 15

Ficha de Registro Post-test de la rotación de inventario

Ficha de registro					
Tipo de prueba:		Post-Test			
Empresa investigada:		Group Alcantara E.I.R.L.			
Motivo:		Índice de rotación de inventario			
Investigador(es):		Flores Taquiri, Giusseph Anthony y Montalvo Celis, James Stiven			
Fecha de inicio:		01/10/2023	Fecha fin:	31/10/2023	
Variables		Indicadores		Medida	Formula
Gestión de inventario		Índice de rotación de inventario		Unidad	$IRI = \frac{\text{Unidades Salidas}}{\text{Inventario Promedio}}$
Id	Fecha	Artículo	Unidades salidas	Inventario promedio	IRI
1	Oct-23	DISCO SOLIDO KINGSTON 480GB	64	67	0.96
2	Oct-23	CABLE HDMI TEROS 5M	32	66	0.48
3	Oct-23	ADAPTADOR USB A TIPO C HOCO	40	50	0.80
4	Oct-23	TINTA EPSON LAGARTO T0631	45	42.5	1.06
5	Oct-23	PARLANTE HALION HA118	16	38	0.42
6	Oct-23	MOUSE LOGITECH M90	23	40.5	0.57
7	Oct-23	USB 32GB KINGSTON	20	65	0.31
8	Oct-23	TINTA BROTHER T500 BK	30	45	0.67
9	Oct-23	DISCO NV 500GB KINGSTON	27	78.5	0.34
10	Oct-23	TECLADO CYBERTEL K206 VORTEX	21	31.5	0.67
11	Oct-23	USB 32GB HP	19	54.5	0.35
12	Oct-23	TINTA 664 COLOR HP	29	30.5	0.95
13	Oct-23	CABLE HOCO IPHONE	16	63	0.25
14	Oct-23	CABEZAL HP 650 BK	17	66.5	0.26
15	Oct-23	AUDIFONO HOCO DM25	35	37.5	0.93
16	Oct-23	TINTAS 73 TOPJET	19	30.5	0.62
17	Oct-23	ADAPTADOR OTG V8 HOCO	22	66	0.33
18	Oct-23	AUDIFONO HALION S2	22	29	0.76
19	Oct-23	COMBO LOGITECH MK120	25	32.5	0.77
20	Oct-23	CABEZAL CANON KIT	21	50.5	0.42
21	Oct-23	MOUSE ENKORE GAMER	25	37.5	0.67
22	Oct-23	COMBO CYBERTEL TWISTER 3 EN 1	18	33	0.55
23	Oct-23	ESTABILIZADOR FORZA 900VA	17	27.5	0.62
24	Oct-23	PROCESADOR AMD RYZEN 3 2200G	13	41.5	0.31
25	Oct-23	PROCESADOR AMD RYZEN 5 2600X	16	32	0.50
26	Oct-23	PROCESADOR AMD RYZEN 3 3200G	11	52.5	0.21
27	Oct-23	PROCESADOR AMD RYZEN 5 3400G	12	34	0.35
28	Oct-23	PROCESADOR AMD RYZEN 5 3600	13	52.5	0.25
29	Oct-23	PROCESADOR AMD RYZEN 7 3700X	6	29	0.21
30	Oct-23	PROCESADOR AMD RYZEN 5 5600G	17	48.5	0.35
31	Oct-23	PROCESADOR AMD RYZEN 5 5600X	13	54.5	0.24
32	Oct-23	PROCESADOR AMD RYZEN 7 5700G	8	49	0.16
33	Oct-23	PROCESADOR AMD RYZEN 7 5800X3D	15	52.5	0.29

34	Set-23	PROCESADOR AMD RYZEN 9 5950X	38.5	1	0.03
35	Set-23	PROCESADOR INTEL I3 10100F	40.5	5	0.12
36	Set-23	PROCESADOR INTEL I5 10400F	50	2	0.04
37	Set-23	PROCESADOR INTEL I5 10600K	53.5	1	0.02
38	Set-23	PROCESADOR INTEL I3 12100F	54.5	1	0.02
39	Set-23	PROCESADOR INTEL I5 12600K	30.5	9	0.30
40	Set-23	PROCESADOR INTEL I7 12700K	44.5	1	0.02
41	Set-23	PROCESADOR INTEL I9 12900K	31	2	0.06
42	Set-23	TARJETA VIDEO ASUS RTX3060 8GB OC	40	4	0.10
43	Set-23	TARJETA VIDEO ASUS RTX3060TI 8GB OC	21	20	0.95
44	Set-23	TARJETA VIDEO GIGABYTE GT730 2GB	36	4	0.11
45	Set-23	TARJETA DE VIDEO GIGABYTE GT1030 2GB	35	4	0.11
46	Set-23	TARJETA DE VIDEO GIGABYTE RTX3070 8GB	39.5	1	0.03
47	Set-23	TARJETA DE VIDEO MSI GT730 2GB	36.5	3	0.08
48	Set-23	TARJETA DE VIDEO MSI RTX3050 8GB	33.5	1	0.03
49	Set-23	TARJETA DE VIDEO ZOTAC GTX1650 4GB	36	4	0.11
50	Set-23	TARJETA DE VIDEO ZOTAC RTX3070 TI 8GB	17	8	0.47
51	Set-23	CASE GAMBYTE SCALE ARGB BLACK	31	10	0.32
52	Set-23	CASE DEEPCOOL MATREXX CC560 ARGB BLACK	22	14	0.64
53	Set-23	CASE ANTEC NX410 ARGB BLACK	24	12	0.50
54	Set-23	FUENTE COOLER MASTER 650W 80 PLUS BRONZE	30.5	15	0.49
55	Set-23	FUENTE GIGABYTE P550B 550W 80 PLUS BRONZE	30	22	0.73


GROUP ALCANTARA E.I.R.L.
 Nathalie Alcantara Gutiérrez
 GERENTE GENERAL

Anexo 16

Ficha de Registro Post-test de la duración de inventario

Ficha de registro					
Tipo de prueba:		Post-Test			
Empresa investigada:		Group Alcantara E.I.R.L.			
Motivo:		Índice de duración de inventario			
Investigador(es):		Flores Taquiri, Giusseph Anthony y Montalvo Celis, James Stiven			
Fecha de inicio:		31/10/2023	Fecha fin:	31/10/2023	
Variables		Indicadores		Medida	
Gestión de inventario		Índice de duración de inventario		Días	
				$IDI = \frac{\text{Inventario Final}}{\text{Salidas Promedio}} \times 30$	
Id	Fecha	Articulo	Inventario final	Salidas promedio	IDI
1	Oct-23	DISCO SOLIDO KINGSTON 480GB	35	64	16.41
2	Oct-23	CABLE HDMI TEROS 5M	50	32	46.88
3	Oct-23	ADAPTADOR USB A TIPO C HOCO	30	40	22.50
4	Oct-23	TINTA EPSON LAGARTO T0631	20	45	13.33
5	Oct-23	PARLANTE HALION HA118	30	16	56.25
6	Oct-23	MOUSE LOGITECH M90	29	23	37.83
7	Oct-23	USB 32GB KINGSTON	55	20	82.50
8	Oct-23	TINTA BROTHER T500 BK	30	30	30.00
9	Oct-23	DISCO NV 500GB KINGSTON	65	27	72.22
10	Oct-23	TECLADO CYBERTEL K206 VORTEX	21	21	30.00
11	Oct-23	USB 32GB HP	45	19	71.05
12	Oct-23	TINTA 664 COLOR HP	16	29	16.55
13	Oct-23	CABLE HOCO IPHONE	55	16	103.13
14	Oct-23	CABEZAL HP 650 BK	58	17	102.35
15	Oct-23	AUDIFONO HOCO DM25	20	35	17.14
16	Oct-23	TINTAS 73 TOPJET	21	19	33.16
17	Oct-23	ADAPTADOR OTG V8 HOCO	55	22	75.00
18	Oct-23	AUDIFONO HALION S2	18	22	24.55
19	Oct-23	COMBO LOGITECH MK120	20	25	24.00
20	Oct-23	CABEZAL CANON KIT	40	21	57.14
21	Oct-23	MOUSE ENKORE GAMER	25	25	30.00
22	Oct-23	COMBO CYBERTEL TWISTER 3 EN 1	24	18	40.00
23	Oct-23	ESTABILIZADOR FORZA 900VA	19	17	33.53
24	Oct-23	PROCESADOR AMD RYZEN 3 2200G	35	13	80.77
25	Oct-23	PROCESADOR AMD RYZEN 5 2600X	24	16	45.00
26	Oct-23	PROCESADOR AMD RYZEN 3 3200G	47	11	128.18
27	Oct-23	PROCESADOR AMD RYZEN 5 3400G	28	12	70.00
28	Oct-23	PROCESADOR AMD RYZEN 5 3600	46	13	106.15
29	Oct-23	PROCESADOR AMD RYZEN 7 3700X	26	6	130.00
30	Oct-23	PROCESADOR AMD RYZEN 5 5600G	40	17	70.59
31	Oct-23	PROCESADOR AMD RYZEN 5 5600X	48	13	110.77
32	Oct-23	PROCESADOR AMD RYZEN 7 5700G	45	8	168.75
33	Oct-23	PROCESADOR AMD RYZEN 7 5800X3D	45	15	90.00

34	Set-23	PROCESADOR AMD RYZEN 9 5950X	38	1	1140.00
35	Set-23	PROCESADOR INTEL I3 10100F	38	5	228.00
36	Set-23	PROCESADOR INTEL I5 10400F	49	2	735.00
37	Set-23	PROCESADOR INTEL I5 10600K	53	1	1590.00
38	Set-23	PROCESADOR INTEL I3 12100F	54	1	1620.00
39	Set-23	PROCESADOR INTEL I5 12600K	26	9	86.67
40	Set-23	PROCESADOR INTEL I7 12700K	44	1	1320.00
41	Set-23	PROCESADOR INTEL I9 12900K	30	2	450.00
42	Set-23	TARJETA VIDEO ASUS RTX3060 8GB OC	38	4	285.00
43	Set-23	TARJETA VIDEO ASUS RTX3060TI 8GB OC	11	20	16.50
44	Set-23	TARJETA VIDEO GIGABYTE GT730 2GB	34	4	255.00
45	Set-23	TARJETA DE VIDEO GIGABYTE GT1030 2GB	33	4	247.50
46	Set-23	TARJETA DE VIDEO GIGABYTE RTX3070 8GB	39	1	1170.00
47	Set-23	TARJETA DE VIDEO MSI GT730 2GB	35	3	350.00
48	Set-23	TARJETA DE VIDEO MSI RTX3050 8GB	33	1	990.00
49	Set-23	TARJETA DE VIDEO ZOTAC GTX1650 4GB	34	4	255.00
50	Set-23	TARJETA DE VIDEO ZOTAC RTX3070 TI 8GB	13	8	48.75
51	Set-23	CASE GAMBYTE SCALE ARGB BLACK	26	10	78.00
52	Set-23	CASE DEEPCOOL MATREXX CC560 ARGB BLACK	15	14	32.14
53	Set-23	CASE ANTEC NX410 ARGB BLACK	18	12	45.00
54	Set-23	FUENTE COOLER MASTER 650W 80 PLUS BRONZE	23	15	46.00
55	Set-23	FUENTE GIGABYTE P550B 550W 80 PLUS BRONZE	19	22	25.91

GROUP ALCANTARA E.I.R.L.

 Nathalie Alcántara Gutiérrez
 GERENTE GENERAL

1) Comprensión del Negocio

En esta fase se trabajará es estrecha colaboración con los interesados para comprender los objetivos del proyecto, los requerimientos y los desafíos comerciales. Se buscará definir claramente los que se espera lograr a través del análisis de datos.

Interesados clave: Se define a los stakeholder 's del proyecto, en este caso para la presente investigación se establece como principal interesado a la gerente de la empresa estudiada y al encargado del área de almacén.

Objetivos de Negocio: El objetivo establecido en el proyecto es la implementación de un sistema que mejore la administración del inventario en la cual se pueda tener la medición de la rotación y duración del inventario aplicando un algoritmo de machine learning que ayude a la toma de decisiones de las cuales se tiene:

Determinar cómo influye un modelo de Machine Learning para la predicción en el índice de rotación de inventario en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos y Determinar cómo influye un modelo de Machine Learning para la predicción en el índice de duración del inventario en la gestión de inventarios dirigida a PYMES de venta de productos tecnológicos.

Alcance del proyecto: Para el alcance del proyecto, se tomará al área de almacén, en este caso no se está tomando parte del área de ventas como (registro de clientes, registros contables y ventas de ciertos meses) ya que la gerenta determina que por ser información sensible para la empresa no se puede ser proveída a los investigadores.

Recopilación de información: Se pasa a explorar toda la información posible otorgada por la gerenta de la organización, en este caso boletas y facturas de los meses de julio, agosto y septiembre, documentación de los productos que ingresaron en esos meses y lista de los productos inventariados.

Tabla 18

Plan del Proyecto

Fase	Tarea	Tiempo	Riesgos
Comprensión datos	Análisis del conjunto de datos.	24 horas	Problemas con los datos.
	Descripción de los datos.	24 horas	Ninguno.
Preparación datos	Preparación.	15 horas	Problemas con los datos.
Modelado	Selección de algoritmos.	5 días	No encontrar los algoritmos adecuados.
	Construcción del modelo.	1 semana	No encontrar el modelo adecuado.
	Calibración de parámetros.	1 semana	No encontrar parámetros válidos y darnos cuenta que el modelo no es el adecuado.
	Comprobación y documentación.	1 semana	Encontrar fallos que hagan replantear el modelo.
Evaluación	Revisar el proceso	2 días	No lograr objetivos.
	Determinar siguientes pasos y documentar	5 días	Ninguno.

Implantación	Plan de implantación	2 días	Problemas técnicos.
	Informe final	1 día	
	Revisión de todo el proceso	1 día	Encontrar fallos en la revisión final.

2) Comprensión de los Datos

En esta fase se estudiará con detenimiento el conjunto de datos sobre el que se pretende trabajar.

Recopilación inicial

Se trabajará con datos ya existentes. En concreto se trabajará con la data proporcionada por la empresa Group Alcantara, la cual fue recogida e insertada a la base de datos de un sistema de inventario a la cual se le aplicara el machine learning.

Descripción

El conjunto de datos que utilizaremos se compone de información extraída de las siguientes tablas las cuales pasamos a describir:

Articulo_articulo: es la tabla de la cual se extrae toda la información del artículo inventariado.

Id_articulo (entero): primary key, id del artículo.

Nombre_articulo (alfanumérico): nombre del artículo máximo de 220 caracteres.

Stock_minimo (entero): se registra un mínimo de la cantidad por artículo para las alertas.

Id_categoria_id (entero): foreign key, adquiere el id de la categoría a la cual pertenece el artículo.

Art_categoria_categoria: es la tabla de la cual se extrae la información de las categorías a la cual pertenecen los artículos registrados.

Id_categoria (entero): primary key id de la categoría.

Nombre_categoria (alfanumérico): nombre de la categoría máximo de 220

caracteres.

Inventario_inventario: es la tabla principal que recoge la información histórica del inventario.

Id_inventario (entero): primary key, id del inventario.

Referencia inventario (alfanumerico): identifica si el inventario es inicial o final del mes al que pertenezca, máximo de 220 caracteres.

Inventario_detalleinventario: es la tabla la cual muestra los datos de los artículos relacionados al inventario.

Id (entero): primary key, id del detalle de inventario.

Articulo_id (entero): foreign key, muestra el id del artículo.

Cantidad (entero): registra la cantidad de los artículos.

Precio (decimal): registra el precio de los artículos inventariados.

Fecha_registro (date): registra la fecha a la cual pertenece el inventario.

Inventario_id (entero): foreign key, muestra el id del inventario al cual está ligado.

Movimiento_movimiento: es la tabla que registra los movimientos realizados como salida y la entrada de productos.

Id_movimiento (entero): primary key, id del detalle del movimiento.

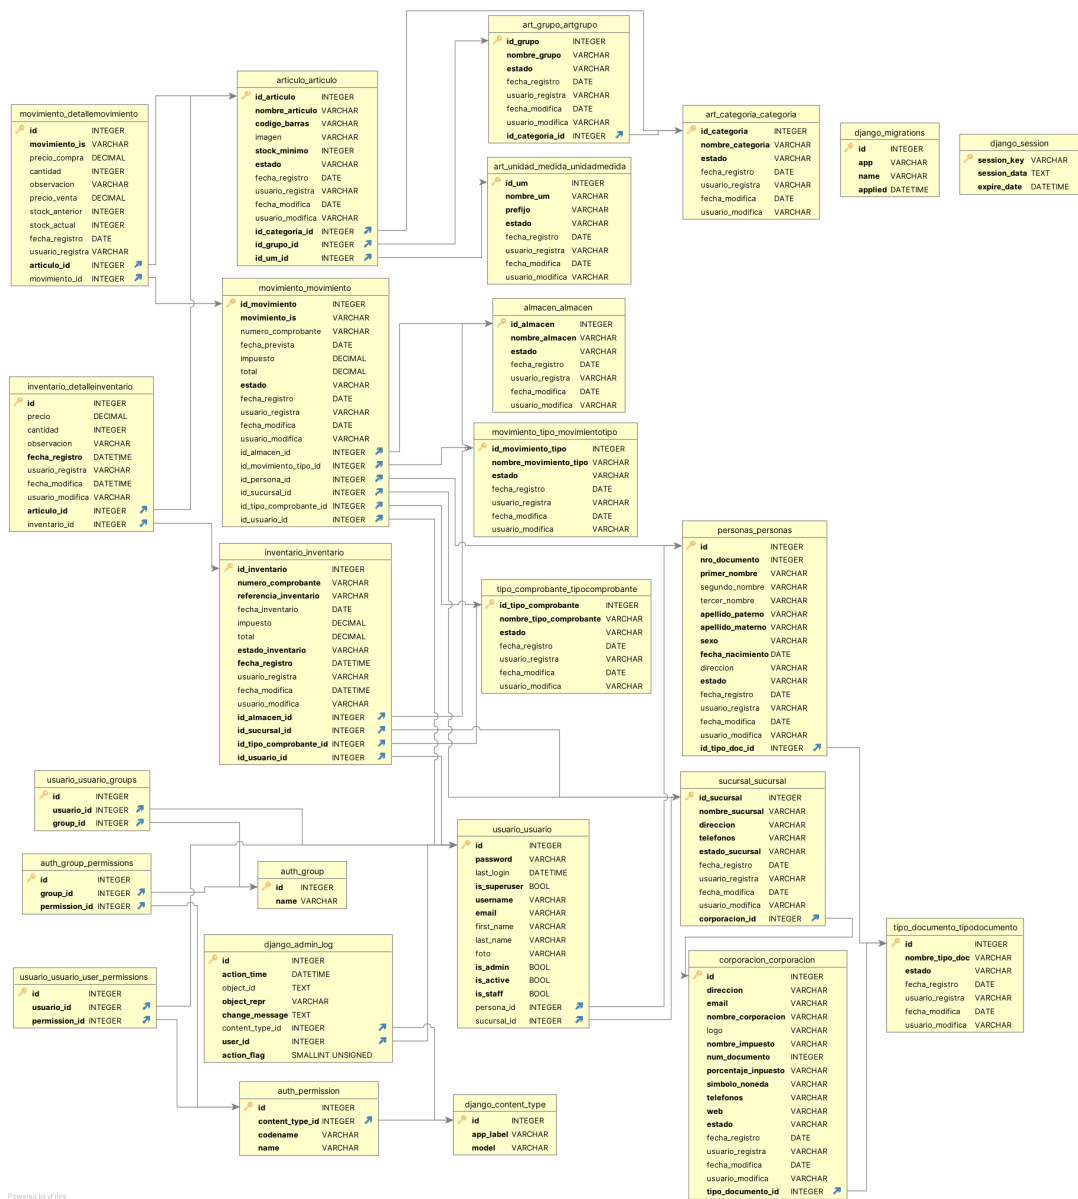
Estado (varchar 2): registra el estado del movimiento.

Id_almacen_id (entero): foreign key, muestra id del almacén.

A continuación, se muestra el esquema de la base de datos usada en el proyecto:

Figura 14

Esquema de la base de datos



Powered by fllis

Exploración

Para realizar la exploración del conjunto de datos y tener una mejor idea del conjunto con el cual estamos trabajando muestra lo siguiente:

Tabla 19

Data del Mes de Julio

FECHA	PRODUCTOS	Unidades	Inventario Promedio (IP)	precio de compra	precio de venta	Inventario ini	inventario fin	stock minimo	categoria
01/08/2023 - 31/08/2023	DISCO SOLIDO KINGSTON 480GB	26	112	100	135	125	39	20	DISCO DURO
01/08/2023 - 31/08/2023	CABLE HDMI TERO5 5M	19	91.5	22	33	101	82	15	CABLE
01/08/2023 - 31/08/2023	ADAPTADOR USB A TIPO C HOCO	27	79.5	13	20	33	66	25	ADAPTADOR
01/08/2023 - 31/08/2023	TINTA EPSON LAGARTO T0631	37	43.5	110	145	62	25	30	TINTA
01/08/2023 - 31/08/2023	PARLANTE HALION HA118	14	53	30	49	60	46	10	PARLANTE
01/08/2023 - 31/08/2023	MOUSE LOGTECH M30	21	62.5	20	24.97	73	52	10	MOUSE
01/08/2023 - 31/08/2023	USB 32GB KINGSTON	2	76	15	20	77	75	6	USB
01/08/2023 - 31/08/2023	TINTA BROTHER T500 BK	19	69.5	32	40.85	79	60	30	TINTA
01/08/2023 - 31/08/2023	DISCO NV 500GB KINGSTON	9	96.5	115.94	128	101	32	30	DISCO DURO
01/08/2023 - 31/08/2023	TECLADO CYBERTEL K206 VORTEX	18	46	20	39.9	55	37	20	TECLADO
01/08/2023 - 31/08/2023	USB 32GB HP	4	66	20	27.99	68	64	10	USB
01/08/2023 - 31/08/2023	TINTA 664 COLOR HP	30	35	43	55	50	20	15	TINTA
01/08/2023 - 31/08/2023	CABLE HOCO IPHONE	8	75	9	15	79	71	20	CABLE
01/08/2023 - 31/08/2023	CABEZAL HP 650 BK	6	78	156	210	81	75	30	CABEZAL
01/08/2023 - 31/08/2023	AUDIFONO HOCO DM25	27	35.5	4.5	9.5	49	22	30	AUDIFONO
01/08/2023 - 31/08/2023	TINTAS T3 TOPJET	20	41	36	46.98	51	31	40	TINTA
01/08/2023 - 31/08/2023	ADAPTADOR OTG V8 HOCO	2	78	12	21	79	77	25	ADAPTADOR
01/08/2023 - 31/08/2023	AUDIFONO HALION S2	17	45.5	40	79	54	37	16	AUDIFONO
01/08/2023 - 31/08/2023	COMBO LOGTECH MK120	23	45.5	55	135	57	34	13	COMBO GAMER
01/08/2023 - 31/08/2023	CABEZAL CANON KIT	12	67	135	190	73	61	12	CABEZAL
01/08/2023 - 31/08/2023	MOUSE ENKORE GAMER	23	59.5	30	45	71	48	6	MOUSE
01/08/2023 - 31/08/2023	COMBO CYBERTEL TWISTER 3 EN 1	20	43	60	79	53	33	15	COMBO GAMER
01/08/2023 - 31/08/2023	ESTABILIZADOR FORZA 300VA	15	38.5	75	109	46	31	20	ESTABILIZADOR
01/08/2023 - 31/08/2023	PROCESADOR AMD RYZEN 3 2200G	5	50.5	355	429	53	48	23	PROCESADOR
01/08/2023 - 31/08/2023	PROCESADOR AMD RYZEN 3 2600X	12	36	699	762	42	30	24	PROCESADOR
01/08/2023 - 31/08/2023	PROCESADOR AMD RYZEN 3 3200G	1	58.5	370	430	59	58	20	PROCESADOR
01/08/2023 - 31/08/2023	PROCESADOR AMD RYZEN 3 3400G	11	35.5	720	805	41	30	24	PROCESADOR
01/08/2023 - 31/08/2023	PROCESADOR AMD RYZEN 3 3600	1	59.5	660	799	60	59	24	PROCESADOR
01/08/2023 - 31/08/2023	PROCESADOR AMD RYZEN 7 3700X	5	34.5	1004	1128	37	32	13	PROCESADOR
01/08/2023 - 31/08/2023	PROCESADOR AMD RYZEN 5 5600G	11	62.5	595	630	68	57	22	PROCESADOR
01/08/2023 - 31/08/2023	PROCESADOR AMD RYZEN 5 5600X	1	61.5	890	969	62	61	12	PROCESADOR
01/08/2023 - 31/08/2023	PROCESADOR AMD RYZEN 7 5700G	3	54.5	746	865	56	53	12	PROCESADOR
01/08/2023 - 31/08/2023	PROCESADOR AMD RYZEN 7 5800X3D	1	60.5	1260	1472	61	60	14	PROCESADOR
01/08/2023 - 31/08/2023	PROCESADOR AMD RYZEN 9 5950X	1	38.5	2799	3086	39	38	12	PROCESADOR
01/08/2023 - 31/08/2023	PROCESADOR INTEL I3 10100F	5	40.5	225	299	43	38	15	PROCESADOR
01/08/2023 - 31/08/2023	PROCESADOR INTEL I5 10400F	2	50	459	566	51	49	16	PROCESADOR
01/08/2023 - 31/08/2023	PROCESADOR INTEL I5 10600K	1	53.5	1004.86	1100	54	53	13	PROCESADOR
01/08/2023 - 31/08/2023	PROCESADOR INTEL I3 12100F	1	54.5	394	498.79	55	54	23	PROCESADOR
01/08/2023 - 31/08/2023	PROCESADOR INTEL I5 12600K	9	30.5	1128	1197.78	35	26	17	PROCESADOR
01/08/2023 - 31/08/2023	PROCESADOR INTEL I7 12700K	1	44.5	1442	1603	45	44	15	PROCESADOR
01/08/2023 - 31/08/2023	PROCESADOR INTEL I9 12900K	2	31	2202	2416	32	30	15	PROCESADOR
01/08/2023 - 31/08/2023	TARJETA DE VIDEO ASUS RTX3060 8GB OC	4	40	1294	1410.29	42	38	15	TARJETA DE VIDEO
01/08/2023 - 31/08/2023	TARJETA DE VIDEO ASUS RTX3060 TI 8GB OC	20	21	1927	2198	31	11	13	TARJETA DE VIDEO
01/08/2023 - 31/08/2023	TARJETA DE VIDEO GIGABYTE GT730 2GB	4	36	305	462	38	34	20	TARJETA DE VIDEO
01/08/2023 - 31/08/2023	TARJETA DE VIDEO GIGABYTE GT1030 2GB	4	35	390	520	37	33	25	TARJETA DE VIDEO
01/08/2023 - 31/08/2023	TARJETA DE VIDEO GIGABYTE RTX3070 8GB	1	39.5	1783	2200	40	39	18	TARJETA DE VIDEO
01/08/2023 - 31/08/2023	TARJETA DE VIDEO MSI GT730 2GB	3	36.5	319	469	38	35	23	TARJETA DE VIDEO
01/08/2023 - 31/08/2023	TARJETA DE VIDEO MSI RTX3050 8GB	1	33.5	895	1309	34	33	18	TARJETA DE VIDEO
01/08/2023 - 31/08/2023	TARJETA DE VIDEO ZOTAC GTX1650 4GB	4	36	755	899	38	34	24	TARJETA DE VIDEO
01/08/2023 - 31/08/2023	TARJETA DE VIDEO ZOTAC RTX3070 TI 8GB	8	17	3263	3599	21	13	21	TARJETA DE VIDEO
01/08/2023 - 31/08/2023	CASE GAMBYTE SCALE ARGB BLACK	10	31	100	160	36	26	14	CASE
01/08/2023 - 31/08/2023	CASE DEEPCOOL MATREXX CC560 ARGB BLACK	14	22	185	255	29	15	12	CASE
01/08/2023 - 31/08/2023	CASE ANTEC NX410 ARGB BLACK	12	24	188	265	30	18	23	CASE

Fuente: elaboración propia

En este caso la tabla muestra los productos del inventario obtenida por un query a la base de datos.

Para mayor veracidad de la información al momento de entrenar el modelo también se tomará en cuenta la información de enero a septiembre del 2023 proporcionada por la empresa.

Calidad

El principal problema con el conjunto de datos que nos hemos encontrado durante la fase de comprensión ha sido:

Datos incompletos: nos hemos encontrado con datos incompletos ya que

en la data proporcionada por la empresa del mes de julio solo mostraba datos hasta el día 20/07/2023, cuando julio consta de 31 días, para no contaminar la veracidad de los datos se trató de llenar con información de los productos salientes del almacén de esos días.

Inconsistencias: se encontraron productos que no pertenecían a la categoría correcta en el mes de agosto, en este caso a través de un filtrado se los coloco en la categoría correcta para no afectar la consistencia de la data.

3) Preparación de los Datos

La fase de preparación de datos cubre todas las actividades con las que se construye el conjunto final de datos a partir de los datos de los que disponemos y se guardaran en un xls para la comparación de algoritmos.

Selección

En cuanto a la información que se tomara será toda la que pertenezca a la tabla de datos que pertenezcan a los meses de enero hasta septiembre del 2023.

Construcción de los nuevos datos

Añadiremos las siguientes columnas a la tabla:

Columna de índice de rotación de stock: se llenará con toda la data obtenida a través de la siguiente formula.

$$IRI = \frac{US}{IP}$$

IRI = índice de rotación de inventario

US = unidades salidas

IP = Inventario Promedio = (inventario inicial - inventario final) /2

Fuente: Llasaca (2020)

Columna de índice de duración de inventario: se llenará con toda la data obtenida a través de la siguiente formula.

$$IDI = \frac{IF}{SP} \times 30$$

IDI = índice de duración de inventario

IF = inventario final

SP = salidas promedio

Fuente: Llasaca (2020)

“Query a la base de datos para obtener la informacion”

```
@method_decorator(csrf_exempt, name='dispatch')
```

```
class DashboardPrediccion(View):
```

```
    def get(self, request):
```

```
        cursor = connection.cursor()
```

```
        if request.is_ajax():
```

```
            search_value = request.GET.get('q', '%')
```

```
            sql_query = """
```

```
                SELECT DISTINCT articulo_articulo.id_articulo
```

```
                ID_ARTICLE, inventario_inventario.fecha_inventario AS DATE,
```

```
                articulo_articulo.nombre_articulo AS NAME_PRODUCT, (pi.cantidad - pf.cantidad) AS
```

```
                UNITS_OUTPUT, (((pi.cantidad*1.0) + pf.cantidad)/2) AS INVENTORY_AVERAGE,
```

```
                round(((pi.cantidad - pf.cantidad)/(((pi.cantidad*1.0) + pf.cantidad)/2)),2) AS IRI,
```

```
                round(((pf.cantidad*1.0) / (pi.cantidad - pf.cantidad))*30,2) AS IDI, pm.precio_compra AS
```

```
                PURCHASE_PRICE, pm.precio_venta AS SALE_PRICE, pi.cantidad AS
```

```
                INITIAL_INVENTORY, pf.cantidad AS FINAL_INVENTORY,
```

```
                articulo_articulo.stock_minimo AS MINIMUN_STOCK_ALERT,
```

```
                art_categoria_categoria.nombre_categoria AS CATEGORY
```

```
                FROM articulo_articulo, inventario_inventario, inventario_detalleinventario,
```

```
                art_categoria_categoria, movimiento_movimiento, movimiento_detallemovimiento,
```

```
                (SELECT articulo_articulo.id_articulo, inventario_detalleinventario.cantidad from
```

```
                inventario_inventario, inventario_detalleinventario, articulo_articulo WHERE
```

```
                inventario_inventario.id_inventario = inventario_detalleinventario.inventario_id AND
```

```
                inventario_detalleinventario.articulo_id = articulo_articulo.id_articulo AND
```

```
                inventario_inventario.referencia_inventario like '%INICI%' and
```

```
                inventario_inventario.fecha_inventario BETWEEN '2023-01-01' and '2023-09-30') pi,
```

```
                (SELECT articulo_articulo.id_articulo, inventario_detalleinventario.cantidad from
```

```
                inventario_inventario, inventario_detalleinventario, articulo_articulo WHERE
```



```

inventario_inventario.id_inventario = inventario_detalleinventario.inventario_id AND
inventario_detalleinventario.articulo_id = articulo_articulo.id_articulo AND
inventario_inventario.referencia_inventario like '%FIN%' and
inventario_inventario.fecha_inventario BETWEEN '2023-01-01' and '2023-09-30') pf,
(SELECT articulo_articulo.id_articulo, movimiento_detallemovimiento.precio_compra,
movimiento_detallemovimiento.precio_venta from movimiento_movimiento,
movimiento_detallemovimiento, articulo_articulo WHERE
movimiento_movimiento.id_movimiento = movimiento_detallemovimiento.movimiento_id
and movimiento_detallemovimiento.articulo_id = articulo_articulo.id_articulo and
movimiento_movimiento.fecha_prevista BETWEEN '2023-01-01' and '2023-09-30'
and movimiento_movimiento.id_almacen_id = '1') pm
WHERE inventario_detalleinventario.articulo_id = articulo_articulo.id_articulo
and inventario_inventario.id_inventario = inventario_detalleinventario.inventario_id
and art_categoria_categoria.id_categoria = articulo_articulo.id_categoria_id
and movimiento_movimiento.id_movimiento =
movimiento_detallemovimiento.movimiento_id
and movimiento_detallemovimiento.articulo_id = articulo_articulo.id_articulo
and articulo_articulo.id_articulo = pm.id_articulo
and articulo_articulo.id_articulo = pi.id_articulo
and articulo_articulo.id_articulo = pf.id_articulo
and inventario_inventario.fecha_inventario BETWEEN '2023-01-02' and '2023-09-30'

```

4) Modelado

En esta fase es donde se seleccionan las técnicas de modelado, y se aplican y ajustan sus parámetros para obtener los valores óptimos, en este caso se realizó una comparación del R2, MSE de los algoritmos de predicción y su comportamiento con la data seleccionada.

Figura 15

Importación de librerías

```
[ ] import openpyxl as oxl
import pandas as pd
from google.colab import drive
import seaborn as sns
import numpy as np

from sklearn.linear_model import LinearRegression
from sklearn.ensemble import RandomForestRegressor
from sklearn.ensemble import GradientBoostingRegressor

from sklearn.metrics import r2_score as R2
from sklearn.metrics import mean_squared_error as MSE
import matplotlib as plt
```

Figura 16

Acceso a la data

```
▶ xlsx_link = 'https://docs.google.com/spreadsheets/d/16ktr0ALsxBp10W7IV8IQivZK3501MS-U/export'

df = pd.read_excel(xlsx_link)
productos=df.iloc[:,1].values

drive.mount('/content/drive')
```

Figura 17

Obtención de información para la predicción

```
r2completo_RL_IDI=[]
r2completo_RF_IDI=[]
r2completo_GB_IDI=[]

r2completo_RL_IRI=[]
r2completo_RF_IRI=[]
r2completo_GB_IRI=[]

msecompleto_RL_IDI=[]
msecompleto_RF_IDI=[]
msecompleto_GB_IDI=[]

msecompleto_RL_IRI=[]
msecompleto_RF_IRI=[]
msecompleto_GB_IRI=[]

for i in range(0,len(w3.sheetnames),1):
    vx1 = "Unidades\nSalidas (US)"
    vx2 = "Inventario\nPromedio (IP)"
    vx3 = "precio de compra"
    vx4 = "precio de venta"
    vx5 = "Inventario inicial"
    vx6 = "inventario final"
    vx7 = "Tiempo"
    vy1 = "Índice de rotación de\ninventario (IRI)"
    vy2 = "Índice de duración de inventario (IDI)"

    vx = [vx7]
```

Figura 18

Aplicación del modelamiento de regresión lineal

```
# #print (" ----- Regresión lineal múltiple ----- ")
modelo_Multiple_Linear_Regression_VY1 = LinearRegression()
modelo_Multiple_Linear_Regression_VY1.fit(df[vx], df[vy1])
modelo_Multiple_Linear_Regression_VY1_R2 = round(R2(df[vy1], modelo_Multiple_Linear_Regression_VY1.predict(df[vx])), 3)
modelo_Multiple_Linear_Regression_VY1_MSE = round(MSE(df[vy1], modelo_Multiple_Linear_Regression_VY1.predict(df[vx])), 3)
print ('IRI :: Coeficiente de determinación (R2): ', modelo_Multiple_Linear_Regression_VY1_R2)
print ('IRI :: Coeficiente de error cuadrático medio (MSE): ', modelo_Multiple_Linear_Regression_VY1_MSE)
r2completo_RL_IRI.append(modelo_Multiple_Linear_Regression_VY1_R2)
msecompleto_RL_IRI.append(modelo_Multiple_Linear_Regression_VY1_MSE)
modelo_Multiple_Linear_Regression_VY2 = LinearRegression()
modelo_Multiple_Linear_Regression_VY2.fit(df[vx], df[vy2])
modelo_Multiple_Linear_Regression_VY2_R2 = round(R2(df[vy2], modelo_Multiple_Linear_Regression_VY2.predict(df[vx])), 3)
modelo_Multiple_Linear_Regression_VY2_MSE = round(MSE(df[vy2], modelo_Multiple_Linear_Regression_VY2.predict(df[vx])), 3)
print ('IDI :: Coeficiente de determinación (R2): ', modelo_Multiple_Linear_Regression_VY2_R2)
print ('IDI :: Coeficiente de error cuadrático medio (MSE): ', modelo_Multiple_Linear_Regression_VY2_MSE)
r2completo_RL_IDI.append(modelo_Multiple_Linear_Regression_VY2_R2)
msecompleto_RL_IDI.append(modelo_Multiple_Linear_Regression_VY2_MSE)
# #print (" ----- ")
```

Figura 19

Aplicación del modelamiento de random forest

```
# #print (" ----- Random forest ----- ")
modelo_Random_fotest_VY1 = RandomForestRegressor(n_estimators=2000, random_state=0, oob_score=True)
modelo_Random_fotest_VY1.fit(df[vx], df[vy1])
modelo_Random_fotest_VY1_R2 = round(R2(df[vy1], modelo_Random_fotest_VY1.predict(df[vx])), 3)
modelo_Random_fotest_VY1_MSE = round(MSE(df[vy1], modelo_Random_fotest_VY1.predict(df[vx])), 3)
print ('IRI :: Coeficiente de determinación (R2): ', modelo_Random_fotest_VY1_R2)
print ('IRI :: Coeficiente de error cuadrático medio (MSE): ', modelo_Random_fotest_VY1_MSE)
r2completo_RF_IRI.append(modelo_Random_fotest_VY1_R2)
msecompleto_RF_IRI.append(modelo_Random_fotest_VY1_MSE)
modelo_Random_fotest_VY2 = RandomForestRegressor(n_estimators=2000, random_state=0, oob_score=True)
modelo_Random_fotest_VY2.fit(df[vx], df[vy2])
modelo_Random_fotest_VY2_R2 = round(R2(df[vy2], modelo_Random_fotest_VY2.predict(df[vx])), 3)
modelo_Random_fotest_VY2_MSE = round(MSE(df[vy2], modelo_Random_fotest_VY2.predict(df[vx])), 3)
print ('IDI :: Coeficiente de determinación (R2): ', modelo_Random_fotest_VY2_R2)
print ('IDI :: Coeficiente de error cuadrático medio (MSE): ', modelo_Random_fotest_VY2_MSE)
r2completo_RF_IDI.append(modelo_Random_fotest_VY2_R2)
msecompleto_RF_IDI.append(modelo_Random_fotest_VY2_MSE)
# #print (" ----- ")
```

Figura 20

Aplicación del modelamiento de gradient boosting

```
# #print (" ----- Gradient Boosting ----- ")
modelo_Gradient_Boosting_VY1 = GradientBoostingRegressor(max_depth=2, random_state=2)
modelo_Gradient_Boosting_VY1.fit(df[vx], df[vy1])
modelo_Gradient_Boosting_VY1_R2 = round(R2(df[vy1], modelo_Gradient_Boosting_VY1.predict(df[vx])), 5)
modelo_Gradient_Boosting_VY1_MSE = round(MSE(df[vy1], modelo_Gradient_Boosting_VY1.predict(df[vx])), 3)
print ('IRI :: Coeficiente de determinación (R2): ', modelo_Gradient_Boosting_VY1_R2)
print ('IRI :: Coeficiente de error cuadrático medio (MSE): ', modelo_Gradient_Boosting_VY1_MSE)
r2completo_GB_IRI.append(modelo_Gradient_Boosting_VY1_R2)
msecompleto_GB_IRI.append(modelo_Gradient_Boosting_VY1_MSE)
modelo_Gradient_Boosting_VY2 = GradientBoostingRegressor(max_depth=2, random_state=2)
modelo_Gradient_Boosting_VY2.fit(df[vx], df[vy2])
modelo_Gradient_Boosting_VY2_R2 = round(R2(df[vy2], modelo_Gradient_Boosting_VY2.predict(df[vx])), 5)
modelo_Gradient_Boosting_VY2_MSE = round(MSE(df[vy2], modelo_Gradient_Boosting_VY2.predict(df[vx])), 3)
print ('IDI :: Coeficiente de determinación (R2): ', modelo_Gradient_Boosting_VY2_R2)
print ('IDI :: Coeficiente de error cuadrático medio (MSE): ', modelo_Gradient_Boosting_VY2_MSE)
# #print (" ----- ")
r2completo_GB_IDI.append(modelo_Gradient_Boosting_VY2_R2)
msecompleto_GB_IDI.append(modelo_Gradient_Boosting_VY2_MSE)
```

Figura 21

Lógica para impresión

```
r2completo_RL_IDI_prom=round((np.mean(r2completo_RL_IDI)), 4)
print('IDI Regresión lineal múltiple :: Coeficiente de determinación (R2) ',r2completo_RL_IDI_prom)
msecompleto_RL_IDI_prom=round((np.mean(msecompleto_RL_IDI)), 4)
print('IDI Regresión lineal múltiple :: Coeficiente de error cuadrático medio (MSE) ',msecompleto_RL_IDI_prom)

r2completo_RF_IDI_prom=round((np.mean(r2completo_RF_IDI)), 4)
print('IDI Random Forest :: Coeficiente de determinación (R2) ',r2completo_RF_IDI_prom)
msecompleto_RF_IDI_prom=round((np.mean(msecompleto_RF_IDI)), 4)
print('IDI Random Forest :: Coeficiente de error cuadrático medio (MSE) ',msecompleto_RF_IDI_prom)

r2completo_GB_IDI_prom=round((np.mean(r2completo_GB_IDI)), 4)
print('IDI Gradient Boosting :: Coeficiente de determinación (R2) ',r2completo_GB_IDI_prom)
msecompleto_GB_IDI_prom=round((np.mean(msecompleto_GB_IDI)), 4)
print('IDI Gradient Boosting :: Coeficiente de error cuadrático medio (MSE) ',msecompleto_GB_IDI_prom)

r2completo_RL_IRI_prom=round((np.mean(r2completo_RL_IRI)), 4)
print('IRI Regresión lineal múltiple :: Coeficiente de determinación (R2) ',r2completo_RL_IRI_prom)
msecompleto_RL_IRI_prom=round((np.mean(msecompleto_RL_IRI)), 4)
print('IRI Regresión lineal múltiple :: Coeficiente de error cuadrático medio (MSE) ',msecompleto_RL_IRI_prom)

r2completo_RF_IRI_prom=round((np.mean(r2completo_RF_IRI)), 4)
print('IRI Random Forest :: Coeficiente de determinación (R2) ',r2completo_RF_IRI_prom)
msecompleto_RF_IRI_prom=round((np.mean(msecompleto_RF_IRI)), 4)
print('IRI Random Forest :: Coeficiente de error cuadrático medio (MSE) ',msecompleto_RF_IRI_prom)

r2completo_GB_IRI_prom=round((np.mean(r2completo_GB_IRI)), 4)
print('IRI Gradient Boosting :: Coeficiente de determinación (R2) ',r2completo_GB_IRI_prom)
msecompleto_GB_IRI_prom=round((np.mean(msecompleto_GB_IRI)), 4)
print('IRI Gradient Boosting :: Coeficiente de error cuadrático medio (MSE) ',msecompleto_GB_IRI_prom)
```

Figura 22

Impresión para los gráficos

```
def addlabels(ctx,x,y):
    for i in range(len(x)):
        ctx.text(i,y[i],y[i],color = 'darkblue', fontweight = 'bold',ha="center", va="center")

fig, ((ax0,ax1,ax3,ax4)) = plt.subplots(nrows=4, ncols=1,figsize=(8, 10))
plt.subplots_adjust(left=0.1, right=0.9, bottom=0.1, top=0.9, wspace=0.2, hspace=0.02)

x1 = ["Regresión lineal múltiple", "Random Forest", "Gradient Boosting"]
y1 = [r2completo_RL_IRI_prom, r2completo_RF_IRI_prom, r2completo_GB_IRI_prom]
ax0.bar(x = x1, height = y1)
addlabels(ax0,x1, y1)
ax0.set_title('IRI - R2')

x2 = ["Regresión lineal múltiple", "Random Forest", "Gradient Boosting"]
y2 = [msecompleto_RL_IRI_prom, msecompleto_RF_IRI_prom, msecompleto_GB_IRI_prom]
ax1.bar(x = x2, height = y2)
addlabels(ax1,x2,y2)
ax1.set_title('IRI - MSE')

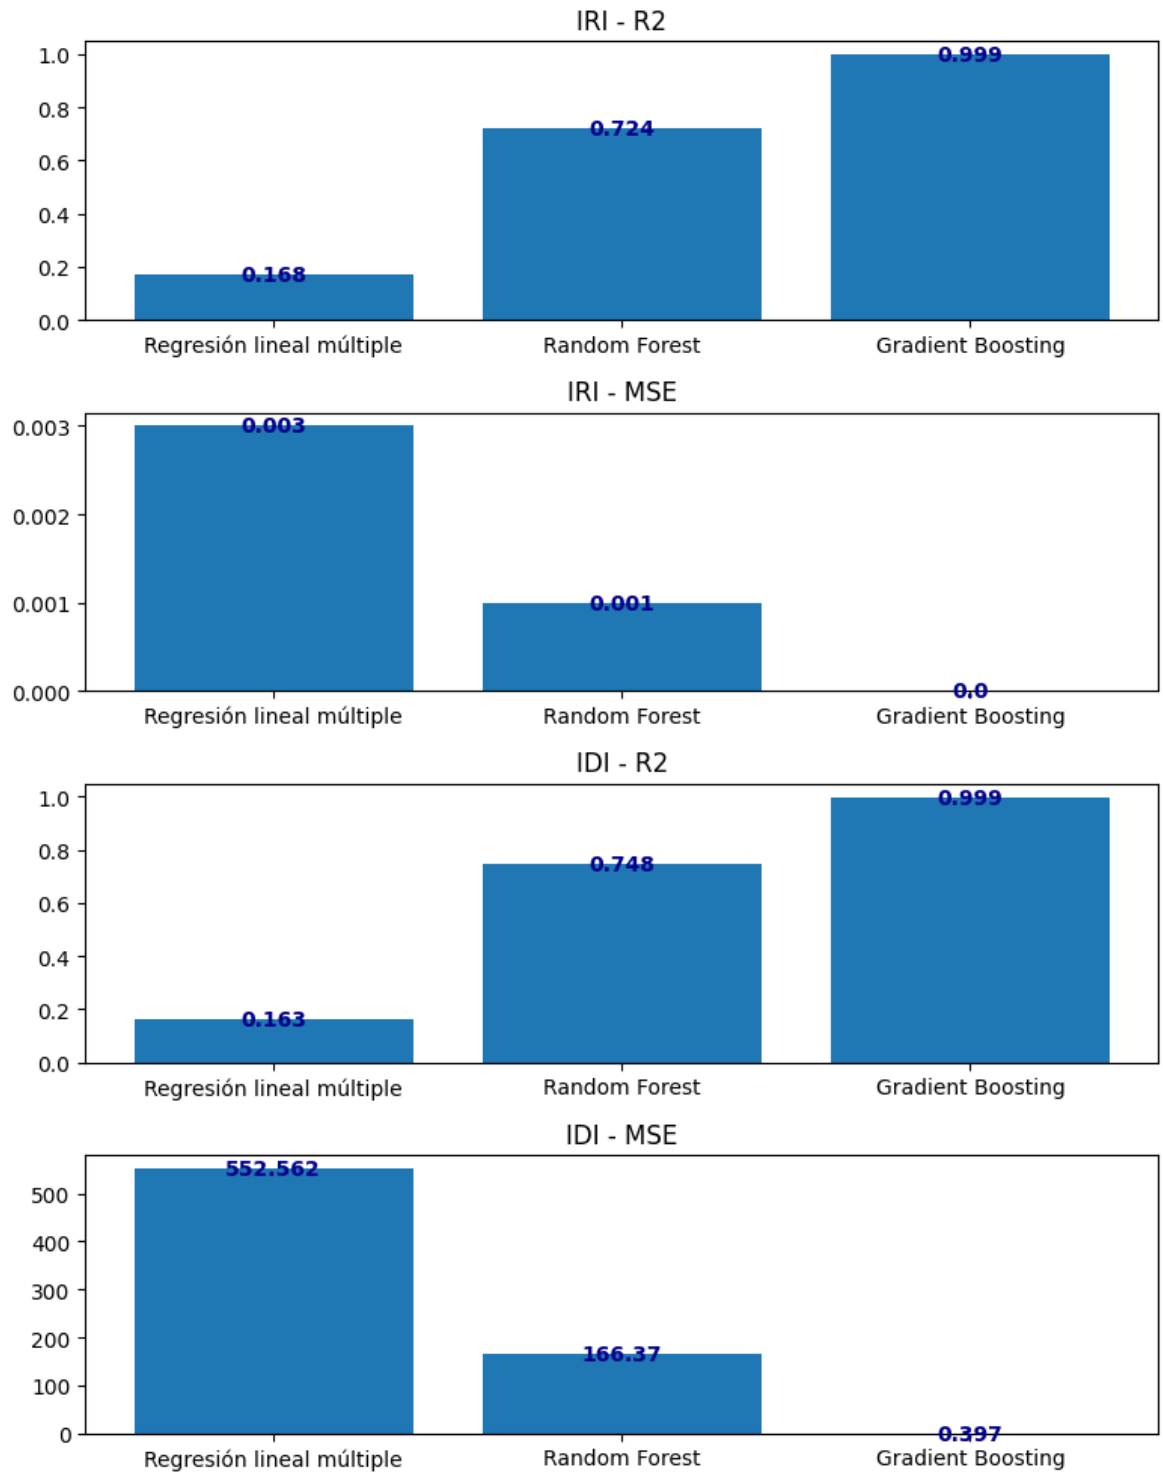
x3 = ["Regresión lineal múltiple", "Random Forest", "Gradient Boosting"]
y3 = [r2completo_RL_IDI_prom, r2completo_RF_IDI_prom, r2completo_GB_IDI_prom]
ax3.bar(x = x3, height = y3)
addlabels(ax3,x3,y3)
ax3.set_title('IDI - R2')

x4 = ["Regresión lineal múltiple", "Random Forest", "Gradient Boosting"]
y4 = [msecompleto_RL_IDI_prom, msecompleto_RF_IDI_prom, modelo_Gradient_Boosting_VV2_MSE]
ax4.bar(x = x4, height = y4)
addlabels(ax4,x4,y4)
ax4.set_title('IDI - MSE')

fig.tight_layout()
plt.show()
```

Figura 23

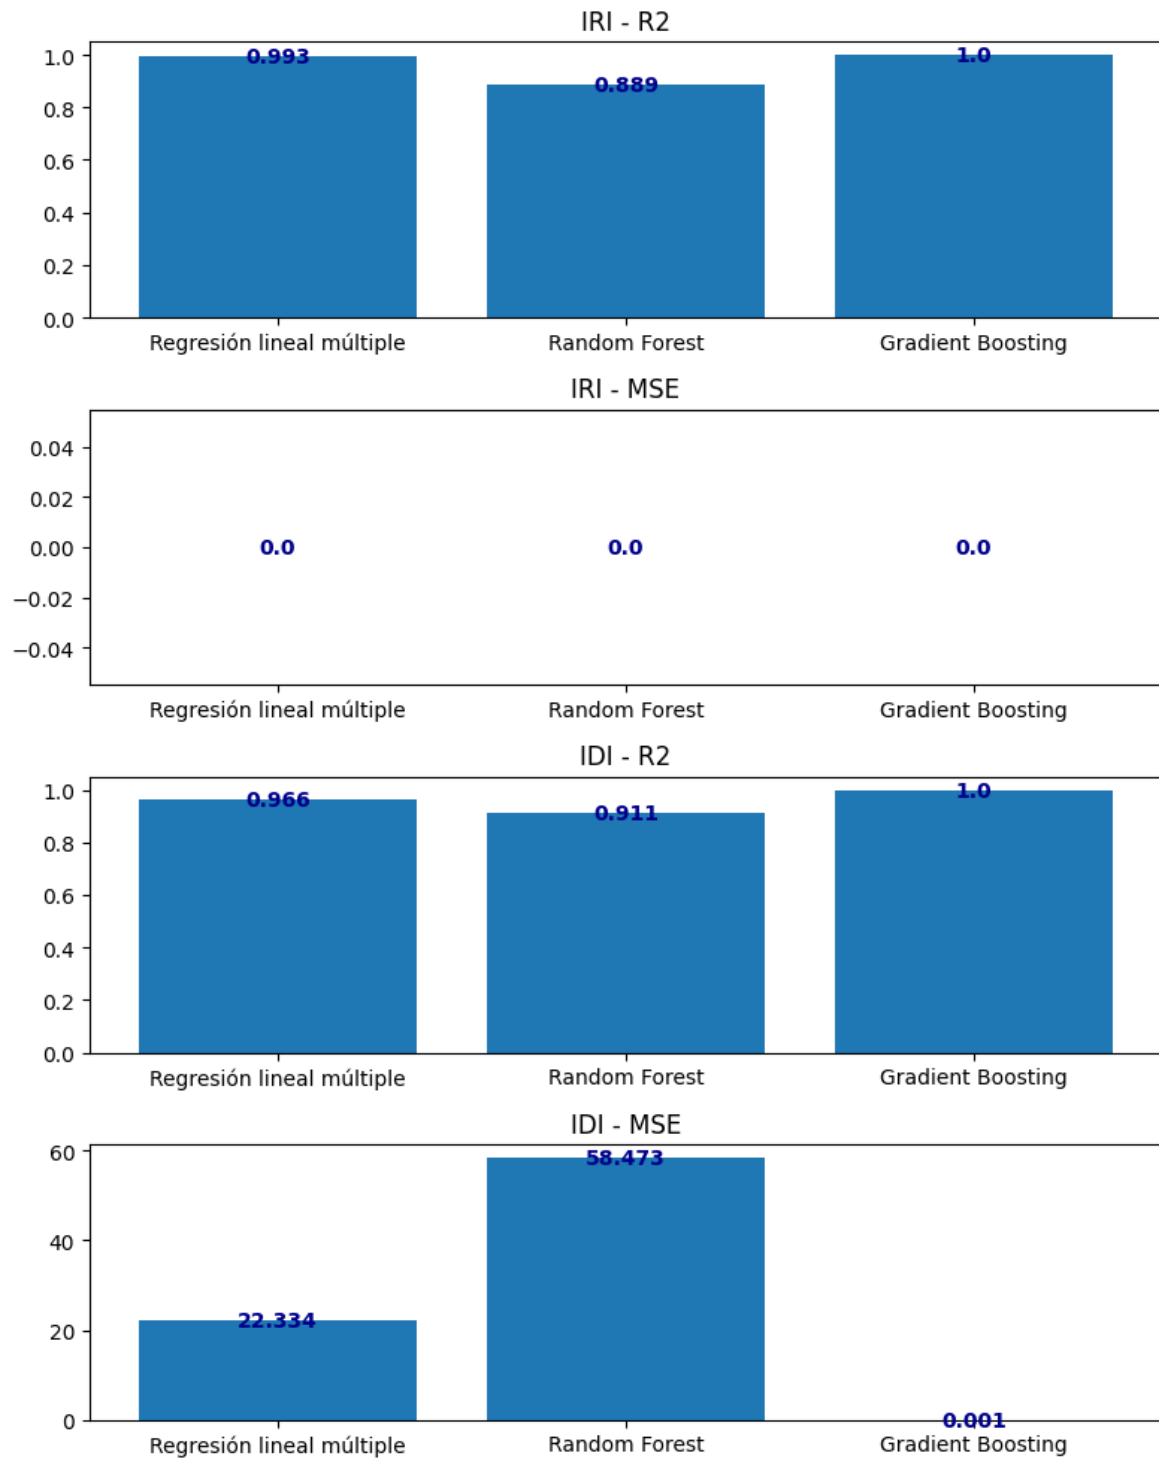
Resultados de correlación de tiempo con IRI e IDI



Nota: la figura muestra la comparación de los algoritmos elegidos con respecto a la rotación y duración de inventario Fuente: Elaboración propia

Figura 24

Todas las variables vs columna secuencial del tiempo



Nota: la figura muestra la comparación de los algoritmos elegidos con respecto al tiempo Fuente: Elaboración propia

5) Evaluación

Al llegar a esta etapa, ya se ha determinado que los modelos planteados en la etapa anterior cumplen los objetivos de la ciencia de datos. Ahora corresponde hacer una evaluación del sistema teniendo en cuenta los objetivos de negocio.

Evaluación de resultados

En nuestro caso los objetivos de negocio son bastante claros y concisos: se trata de predecir los productos con mayor y menos rotación de inventario para los meses posteriores, como la duración de estos productos en el inventario.

En base a los indicadores obtenidos mediante la herramienta de machine learning, a continuación, podemos hacer una evaluación de cada modelo para así descartar aquellos que no cumplan con los requisitos mínimos.

Modelo 1

Respecto a regresión lineal, no recomiendo su uso dado que la data va a ser alimentada a lo largo del tiempo y no se puede descartar que la relación de las variables involucradas se vuelva compleja y si éste llega a ser el caso regresión lineal no es el método adecuado para tratar con correlaciones de variables complejas.

Modelo 2

Random forest es un método que su precisión depende mucho del número de iteraciones o árboles que se realicen durante la ejecución del método, para las pruebas hechas se le asignaron 2000 iteraciones y aunque sus resultados fueron muy buenos, pudiera tener un mejor comportamiento con una muestra enriquecida, pero además hay que tener que el consumo de recursos para probar debe ser un factor a considerar

Modelo 3 para nuestro objetivo

En base a las pruebas, se recomienda usar gradient boosting dado que parte

del mismo principio que random forest y se considera que este método da resultado más preciso porque cada iteración es mejorada y optimizada a partir de sus resultados y errores de pasos anteriores, se observa en los resultados presentados en la figura 18 que fue él método que obtuvo mejores métricas, mayores coeficientes de determinación (R^2) y menores errores cuadráticos medios (MSE). Independientemente del enriquecimiento de la muestra va a tener menos iteraciones que random forest y a pesar de que la correlación de las variables se vuelva compleja dará buenos resultados. Sin embargo, se hace una notación de que si la muestra se vuelve muy dispersa empezará a tener alta varianza y por ende afectar a la precisión de la predicción.

6) Implantación

En esta fase se utilizará el conocimiento adquirido con el sistema desarrollado para conseguir mejoras en la organización en la que se va a implantar.

Planear la implementación

Para la implantación de este proyecto en la empresa Group Alcantara.

La primera tarea es obtener un conjunto de datos históricos robusta la cual pueda alimentar al entrenamiento de los modelos de predicción para obtener información más precisa.

También es importante que las personas implicada o stakeholder's tengan los conocimientos necesarios y estén preparados y concienciados para la implementación.

Plan de monitorización y mantenimiento

La tarea más importante es la de comprobar que el sistema para el proceso de administración de inventario efectivamente mejora la toma de decisiones por parte del gestor y del impacto que tienen en la empresa.

Se comprobará de forma periódica si los datos de entrenamiento (data histórica) siguen siendo válidos para la predicción actual, y si, en caso de que no lo

sea, haría falta entrenar el sistema desde cero con un nuevo conjunto de datos de entrenamiento.

Informe final

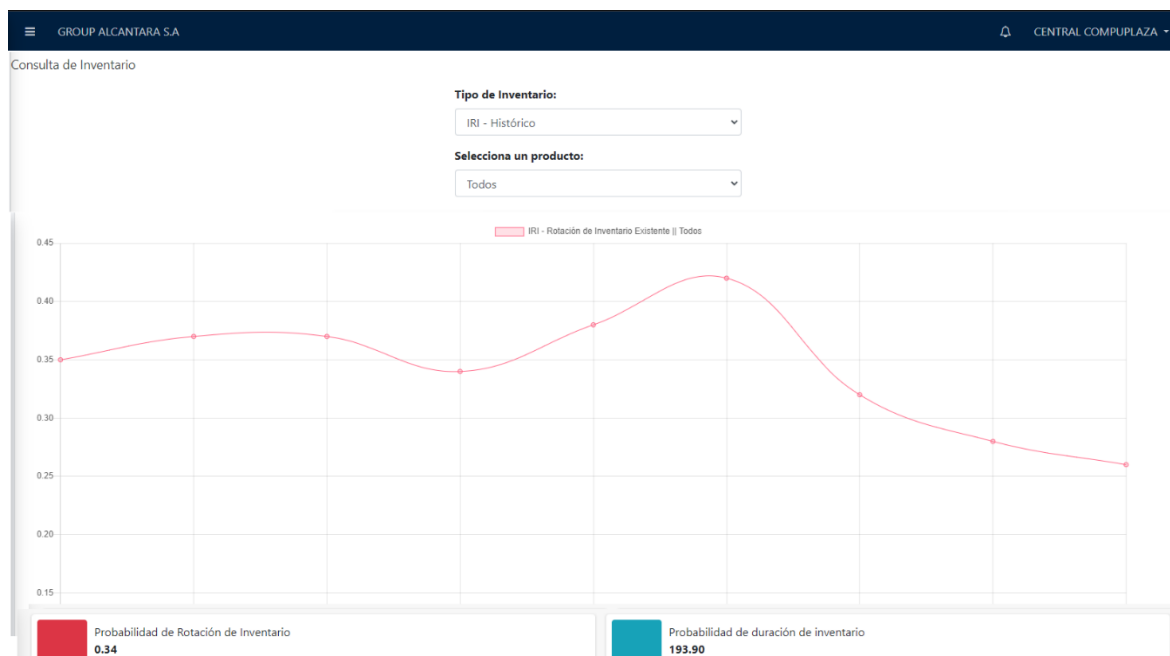
Tomaremos el presente trabajo como informe final, donde se evalúa, informa y compara por completo el sistema desarrollado.

Revisión del proyecto

En esta última etapa se evalúan los procedimientos que se hicieron correctamente en el transcurso del proyecto y aquellas que no, así como posibles mejoras para que en las futuras predicciones del sistema se vayan puliendo la data, como ya se ha comentado en puntos anteriores la falta de data histórica es uno de los puntos más desventajosos al momento de entrenar el modelo, esto es debido a la falta de confianza por parte de la empresa para con la entrega de la información y que más adelante debe ser conversada con los stakeholder's.

Figura 25

Dashboard del IRI - Histórico



Nota: La figura muestra la gráfica de la rotación de inventario histórica a través del tiempo Fuente: Elaboración propia

Figura 26

Dashboard del IDI - Histórico



Nota: La figura muestra la gráfica de la duración de inventario histórica a través del tiempo Fuente: Elaboración propia

Figura 27

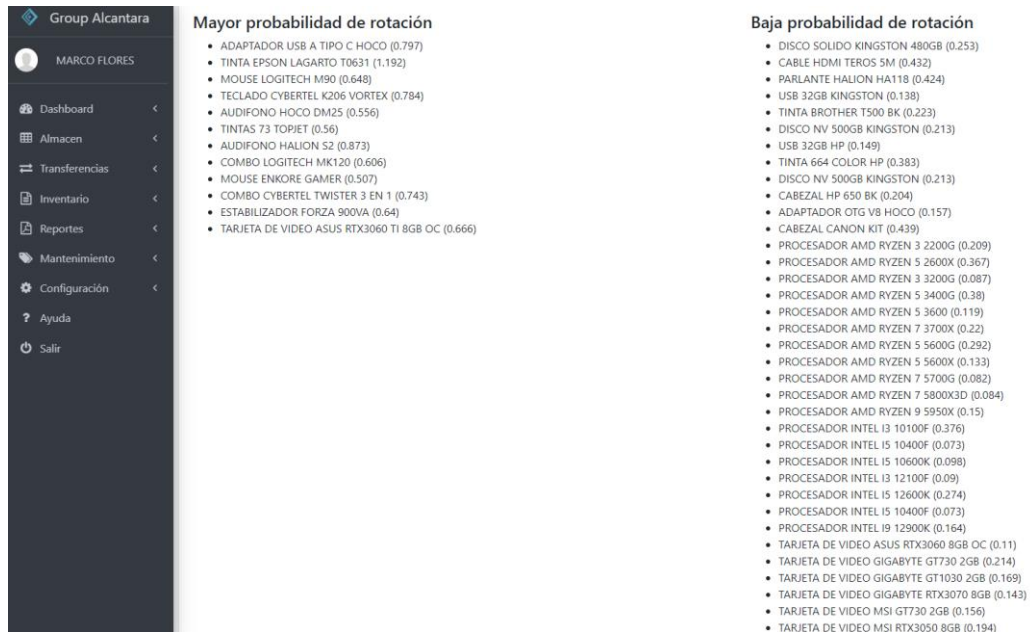
Dashboard del IRI - Proyectado



Nota: La figura muestra la gráfica de la rotación de inventario a través del tiempo y su proyección Fuente: Elaboración propia

Figura 28

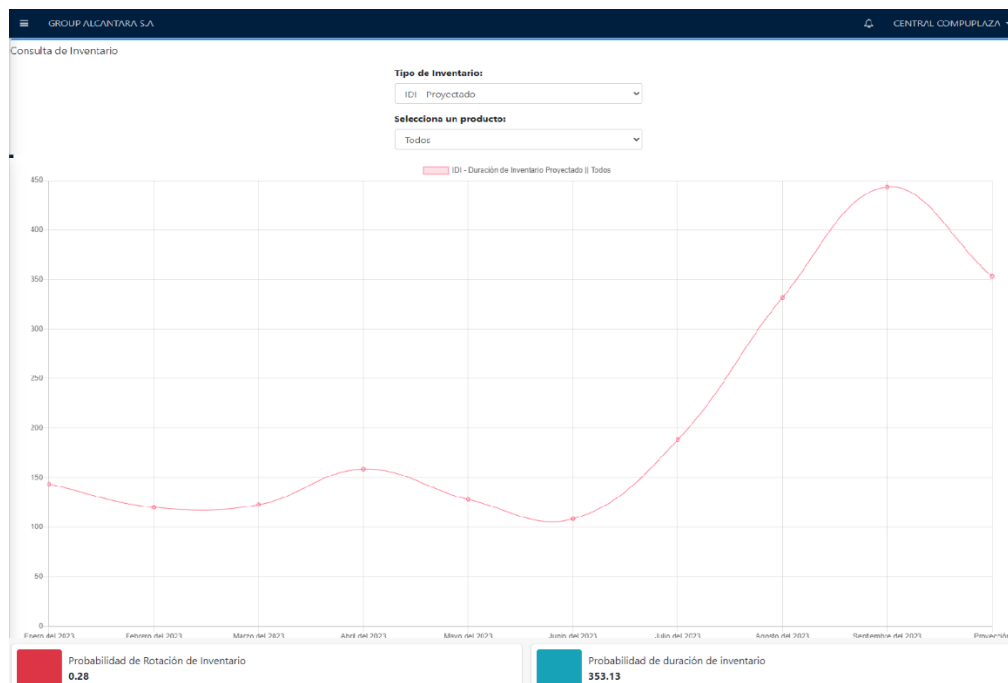
Lista del IRI proyectado de mayor y baja probabilidad



Nota: La figura muestra la lista de los productos con mayor y baja probabilidad de rotación de inventario Fuente: Elaboración propia

Figura 29

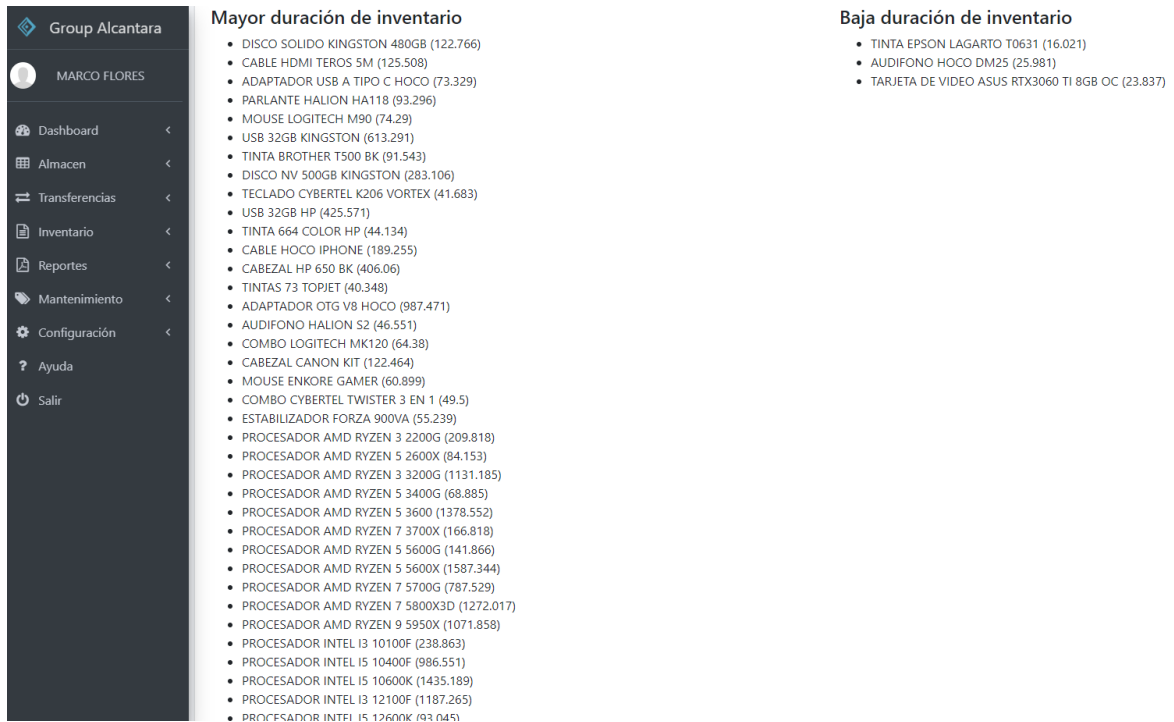
Dashboard del IDI - Proyectado



Nota: La figura muestra la gráfica de la duración de inventario a través del tiempo y su proyección Fuente: Elaboración propia

Figura 30

Lista del IDI proyectado de mayor y baja duración



Nota: La figura muestra la lista de los productos con mayor y baja duración de inventario Fuente: Elaboración propia