



FACULTAD DE INGENIERÍA INDUSTRIAL Y DE SISTEMAS

**APLICACIÓN DE MACHINE LEARNING EN EL PRONÓSTICO DE LA DEMANDA
PARA REDUCIR COSTOS DE PRODUCCIÓN EN UNA EMPRESA
METALMECÁNICA**

**Línea de investigación:
Competitividad industrial, diversificación productiva y prospectiva**

Tesis para optar el Título Profesional de Ingeniero Industrial

Autora

Flores Gomez, Nelida Marcela

Asesor

Castro Retes, Augusto Angel

ORCID: 0000-0002-0130-3527

Jurado


Batállanos Casas, Williams Hernán

Carlos Reyes, Gabriel Jorge

Meza Armas, Orlando Eleodoro

Lima - Perú

2025



APLICACIÓN DE MACHINE LEARNING EN EL PRONÓSTICO DE LA DEMANDA PARA REDUCIR COSTOS DE PRODUCCIÓN EN UNA EMPRESA METALMECÁNICA

INFORME DE ORIGINALIDAD

13%	11%	4%	6%
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	www.coursehero.com Fuente de Internet	2%
2	Submitted to Corporación Universitaria Reformada Trabajo del estudiante	1%
3	hdl.handle.net Fuente de Internet	1%
4	repositorio.ucv.edu.pe Fuente de Internet	1%
5	Aceituno Rojo, Miguel Romilio. "Modelo predictivo de análisis de riesgo crediticio usando Machine Learning en una entidad del sector microfinanciero", Universidad Nacional del Altiplano de Puno (Peru) Publicación	1%
6	repositorio.unfv.edu.pe:8080 Fuente de Internet	1%
7	www.repositorio.usac.edu.gt Fuente de Internet	<1%
8	Submitted to Universidad San Ignacio de Loyola Trabajo del estudiante	<1%
9	repositorio.unfv.edu.pe Fuente de Internet	<1%



Universidad Nacional
Federico Villarreal

VRIN | VICERRECTORADO
DE INVESTIGACIÓN

FACULTAD DE INGENIERÍA INDUSTRIAL Y DE SISTEMAS

APLICACIÓN DE MACHINE LEARNING EN EL PRONÓSTICO
DE LA DEMANDA PARA REDUCIR COSTOS DE
PRODUCCIÓN EN UNA EMPRESA METALMECÁNICA

Línea de Investigación:

Competitividad industrial, diversificación productiva y prospectiva
Tesis para optar el Título Profesional de Ingeniero Industrial

Autora

Flores Gomez, Nelida Marcela

Asesor

Castro Retes, Augusto Angel
ORCID: 0000-0002-0130-3527

Jurado

Batállanos Casas, Williams Hernán
Carlos Reyes, Gabriel Jorge
Meza Armas, Orlando Eleodoro

Lima – Perú
2025

Agradecimiento

Agradezco a mis padres y mis hermanos por haberme apoyado donde nadie creía en mí y por ser mi razón para superar los obstáculos.

Así mismo, agradezco a mi asesor por avivar mi espíritu crítico y brindarme las herramientas para poder desarrollar el presente trabajo

INDICE

Resumen.....	8
Abstract.....	9
I. INTRODUCCIÓN.....	1
<u>1.1.</u> Descripción y formulación del problema.....	1
1.1.1. <i>Descripción del problema</i>	1
1.1.2. <i>Formulación del problema</i>	3
<u>1.2.</u> Antecedentes.....	3
1.2.1. <i>A nivel Internacional</i>	3
1.2.2. <i>A nivel Nacional</i>	5
<u>1.3.</u> Objetivos.....	6
1.3.1. <i>Objetivo general</i>	6
1.3.2. <i>Objetivos específicos</i>	6
<u>1.4.</u> Justificación.....	7
<u>1.5.</u> Hipótesis.....	7
1.5.1. <i>Hipótesis General</i>	7
1.5.2. <i>Hipótesis Específicos</i>	7
II. MARCO TEÓRICO.....	9
<u>2.1.</u> Bases teóricas sobre el tema de investigación.....	9
2.1.1. <i>Machine Learning</i>	9
2.1.2. <i>Planificación de la producción</i>	10
2.1.3. <i>Costos de Producción</i>	13
III. MÉTODO.....	15
<u>3.1.</u> Tipo de Investigación.....	15
<u>3.2.</u> Ámbito temporal y espacial.....	15
3.2.1. <i>Ámbito Temporal</i>	15
3.2.2. <i>Ámbito Espacial</i>	15
<u>3.3.</u> Variables.....	15
3.3.1. <i>Variable independiente</i>	15

3.3.2. <i>Variable dependiente</i>	16
<u> </u> 3.4. Población y muestra	16
<u> </u> 3.5. Instrumentos.....	17
<u> </u> 3.6. Procedimientos.....	17
<u> </u> 3.7. Análisis de datos	17
IV. RESULTADOS	18
<u> </u> 4.1. Consideraciones iniciales	18
<u> </u> 4.2. Estimación de la demanda.....	24
4.2.1. <i>Definición del problema</i>	24
4.2.2. <i>Recolección y preparación de datos</i>	25
4.2.3. <i>Selección del modelo adecuado</i>	26
4.2.4. <i>Entrenamiento y validación del modelo</i>	26
4.2.5. <i>Integración en el sistema de planificación</i>	28
4.2.6. <i>Pruebas piloto, ajustes y Evaluación del modelo</i>	28
4.2.7. <i>Pronóstico basado en SARIMA</i>	30
<u> </u> 4.3. Impacto en la empresa.....	31
4.3.1. <i>Reducción de costos de producción</i>	31
4.3.2. <i>Mejora de productividad</i>	34
4.3.3. <i>Reducción de costos de Materia Prima</i>	36
4.3.4. <i>Reducción de desperdicio de Metales</i>	39
4.3.5. <i>Aumento de Ontime</i>	42
V. DISCUSIÓN DE RESULTADOS	44
VI. CONCLUSIONES	46
VII. RECOMENDACIONES	47
VIII. REFERENCIAS	48
IX. ANEXOS	52
<u> </u> Anexo A: Matriz operacional de variables.....	52
<u> </u> Anexo B: Matriz de consistencia.....	53

INDICE DE TABLAS

Tabla 1. Tipos de modelos de pronósticos y sus principales usos	12
Tabla 2. Operacionalización de las variables: Machine Learning y el pronóstico de la demanda	15
Tabla 3. Operacionalización de las variables: Costos de Producción.....	16
Tabla 4. Máquinas de la empresa metalmecánica por proceso	20
Tabla 5. Set Up por proceso 2024.....	23
Tabla 6. Cronograma de mantenimiento anual	24
Tabla 7. Producción estándar mensual de sillas apilables tapizadas.	24
Tabla 8. Unidades Vendidas de Sillas apilables para un periodo de 24 meses por % de participación de cada familia	25
Tabla 9. Tabulación del pronóstico de la demanda del modelo SARIMA	31
Tabla 10. Tabulación del pronóstico del periodo mayo - octubre 2024	32
Tabla 11. Sobrecostos de la producción de mayo - octubre 2024	32
Tabla 12. Sobrecostos del pronóstico de la producción de mayo - octubre 2024.....	33
Tabla 13. Disminución de los sobrecostos al usar el modelo	34
Tabla 14. Productividad de Mayo a Octubre del 2024	34
Tabla 15. Productividad calculada para Mayo a Octubre del 2024	35
Tabla 16. Costos de Materia Prima Directa	36
Tabla 17. Costos de las compras de los materiales ABC.....	37
Tabla 18. Costos de las compras de la materia prima ABC del pronóstico.....	38
Tabla 19. Comparativo total del periodo de mayo a octubre de los costos del pronóstico SARIMA y el real	39
Tabla 20. Peso de materia prima usada por tipo de material	39

INDICE DE FIGURAS

Figura 1. Participación de ventas (\$) por familia 2021-2023	18
Figura 2. Pareto de Ventas (unid) por tipo de silla del periodo 2023 (Enero - Diciembre).....	19
Figura 3. Pareto de Ventas (unid) por tipo de silla del periodo 2024 (Enero-Octubre).....	19
Figura 4. Silla apilable tapizada estándar.....	20
Figura 5. Diagrama de Operaciones del Proceso (DOP) de producción de sillas apilables tapizadas.....	21
Figura 6. Diagrama de Operaciones (DOP) de Producción de Sillas apilables Tapizadas especiales	22
Figura 7. Flujo de la producción de sillas apilables.....	23
Figura 8. Gráfico Lineal de ventas en unidades de sillas tapizadas.....	26
Figura 9. Ingreso de datos para el entrenamiento y validación del modelo.....	27
Figura 10. Cálculo del Error Absoluto % en google Collabs (Lenguaje Phyton).....	28
Figura 11. Prueba Piloto de SARIMA en Google Collabs (Lenguaje Phyton)	28
Figura 12. Evaluación del modelo inicial en Google Collabs (Lenguaje Phyton).....	29
Figura 13. Cálculo de Errores en Google Collabs (Lenguaje Phyton) luego de ejecutar auto_arima.....	29
Figura 14. Evaluación del modelo modificadol en Google Collabs (Lenguaje Phyton)	30
Figura 15. Proyección de los meses nov-2024 a jul-2024	30
Figura 16. Cambio de la prueba del modelo SARIMA	31
Figura 17. Comparativo de los Set ups del pronóstico y la producción real	35
Figura 18. Comparativo de la productividad generada por el modelo de SARIMA y el real alcanzado.....	36
Figura 19.	37
Figura 20. Comparativa por mes del costo real de M.P de la producción de sillas tapizadas	

apiladas y de la proyección	38
Figura 21. Pareto de Peso por material usado en la fabricación de sillas apilables	40
Figura 22. Merma total en kilos por mes de la producción de sillas apilables tapizadas y el peso calculado de la merma del pronóstico SARIMA	40
Figura 23. %SCRAP real de la producción de sillas apilables tapizadas versus %SCRAP calculado apartir del pronóstico SARIMA	41
Figura 24. % On time del despacho de sillas apilables del periodo Mayo a octubre 2024.....	42
Figura 25. %On time de la aplicación del modelo SARIMA de la producción de sillas apilables tapizadas del periodo Mayo a Octubre 2024	42
Figura 26. Comparación del %On time real y del pronóstico.....	43

Resumen

Objetivo: el presente trabajo de tesis se ha realizado con el objetivo de identificar el impacto en la reducción de costos de la aplicación del pronóstico de la demanda con machine learning en una empresa metalmecánica ubicado en la ciudad de Lima, Perú. **Método:** para la demostración de los objetivos el método utilizado es la investigación aplicada, cuantitativa, explicativa, transversal y cuasi experimental a través del estudio de la data histórica y la aplicación de un modelo algorítmico quedará demostrado el punto de esta investigación. **Resultados:** Entre los principales resultados se observó que la aplicación del modelo reduce los sobrecostos de producción en 69.5%, la reducción del Sobre stock fue de 98.3% lo que redujo las temporadas de promoción de stock recesivo que la empresa ofertaba a sus clientes donde el precio era reducido en un 15% lo que reducía el margen de ganancia en 16%, además de que se mantiene el capital rotando y los costos de sobreproducción se redujeron en 70.2%. Añadir que para la constante alimentación del sistema planteado se ha establecido un sistema de actualización relacionado con el ERP inhouse de la empresa. **Conclusiones:** se llega a la conclusión que la aplicación del modelo en el pronóstico de la producción reduce los costos de producción, mejora la productividad, garantiza una mejor entrega a tiempo de los pedidos, mejora los márgenes de ganancia y posiciona a la empresa en una mejor situación para competir en el mercado y gestionar sus recursos de manera más eficiente

Palabras clave: Machine learning, Pronóstico de la demanda, Reducción de costos, Inteligencia artificial, Algoritmos predictivos

Abstract

Objective: This thesis aims to identify the impact of demand forecasting using machine learning on cost reduction in a metalworking company located in Lima, Peru. **Method:** To demonstrate the objectives, the applied, quantitative, explanatory, cross-sectional, and quasi-experimental research method was employed. Through the analysis of historical data and the application of an algorithmic model, the focus of this research is validated. **Results:** Among the main findings, the application of the model resulted in a 69.5% reduction in production overruns. Overstock was reduced by 98.3%, which minimized the need for promotional sales of stagnant stock previously offered to customers. These promotions typically reduced prices by 15%, leading to a 16% decrease in profit margins. Additionally, capital rotation was maintained, and overproduction costs decreased by 70.2%. Furthermore, a system for continuous data input was established, integrated with the company's in-house ERP system. **Conclusions:** The application of the model in production forecasting reduces production costs, improves productivity, ensures better on-time delivery of orders, enhances profit margins, and positions the company more competitively in the market while enabling more efficient resource management.

Keywords: Machine learning, Demand forecasting, Cost reduction, Artificial intelligence, Predictive algorithms

I. INTRODUCCIÓN

1.1. Descripción y formulación del problema

1.1.1. Descripción del problema

La industria metalmeccánica es parte fundamental de la economía del país que definido en términos de PBI representa un 11.2% para la manufactura y un 1.4% a nivel nacional. Sin embargo, su crecimiento se ha visto afectado desde el 2019 al 2023 dando como resultado un descenso de 8.9%, esto debido a diversos factores externos que han frenado la inversión. A pesar de esta contrariedad la cantidad de empresas metalmeccánicas formales en el país sigue aumentando, tal es el caso que a fines del 2023 el número asciende a 72,711 lo que representa un incremento constante con tendencia al alza de un 14.6% medido desde el 2019. En términos del tamaño de las empresas la cantidad viene liderada por microempresas con un 93.5% del total de empresas, el 5.9% para pequeña empresa, el 0.1% para mediana empresa y solo un 0.4% como gran empresa de las cuales casi la mitad se encuentran en Lima. Si bien es cierto el crecimiento de la industria es exponencial con un promedio de 2.8% de aumento cada año, se observa que cada vez el margen de ganancia por los productos ofertados en el año es menor, lo cual genera una alta competencia. (Oficina General de Evaluación de Impacto y Estudios Económicos, [OGEIEE], 2024)

La alta competencia y la falta de adaptación hacen que más empresas caigan en el fracaso siendo imposible el reflatamiento de las mismas ya que se ven obstaculizadas por factores externos que imposibilitan el acceso al crédito que a diferencia de las grandes empresas, las cuales tienen mayores posibilidades a anteponerse a estos factores externos al cambiar de mercado y continuar su vida económica sin que le afecte la depresión. (Flint, 2006)

De otro lado, para Cameron et al. (1987) son las medianas, pequeñas y microempresas las más afectadas. A parte de los factores externos ya mencionados, estas empresas lidian con factores internos identificados como 14 según Flint (2006), de las cuales para el marco de

este trabajo de tesis nos centraremos en la deficiencia de la planificación a largo plazo, la ausencia de innovación y pérdida del margen.

Esta alta competencia nos encamina en la revisión de nuestros procesos estratégicos como en la planificación a largo plazo cuyo principal objetivo será el de establecer un adecuado pronóstico de la demanda que de ejecutarse correctamente tendrá un alto impacto en los costos de producción. Según Chopra y Meindl (2016), un pronóstico preciso permite a la empresa como primera instancia mantener niveles de inventarios óptimos reduciendo los costos operativos del almacenamiento y traslado de productos, segundo permite planificar la capacidad de producción que impacta en los costos de utilización de los recursos minimizando desperdicios y tiempos muertos, tercero permite plantear estrategias sobre producción y distribución impactando en los costos relacionado a las compras o la falta de preparación en picos de demanda y cuarto nos permite antepoernos a fluctuaciones del mercado impactando en la reducción de costos imprevistos.

Este pronóstico nos conlleva a la interrogante sobre cuáles son las herramientas más efectivas para garantizar que nuestras predicciones sean precisas reduciendo al mínimo error absoluto. Analizando las tendencias de innovación con las cuales las empresas se adaptan rápidamente a los cambios de su entorno, tienen un alto índice de confiabilidad el uso de nuevas tecnologías como machine learning, la cual nos brinda una actualización en tiempo real donde el algoritmo va identificando las variaciones de nuestra empresa para poder hacer proyecciones que nos permite antepoernos a los cambios en el mercado, lo que hace que la planificación de la producción a largo plazo sea más controlada evitando incurrir en sobrecostos y aprovechando las oportunidades del mercado en cuanto a la baja de los costos de materia prima.

1.1.2. Formulación del problema

1.1.2.1. Problema General. ¿La aplicación de Machine Learning en el pronóstico de la demanda reducirá los costos de producción en una empresa metalmecánica?

1.1.2.2. Problema Específicos. ¿La aplicación de Machine Learning en el pronóstico de la demanda optimizará el uso de los recursos productivos de una empresa metalmecánica?

¿La aplicación de Machine Learning en el pronóstico de la demanda mejorará la productividad de una empresa metalmecánica?

¿La aplicación de Machine Learning en el pronóstico de la demanda garantizará el cumplimiento de los plazos de fabricación de una empresa metalmecánica?

¿La aplicación de Machine Learning en el pronóstico de la demanda mejorará la competitividad de los precios de una empresa metalmecánica?

¿La aplicación de Machine Learning en el pronóstico de la demanda mejorará los márgenes de ganancia de una empresa metalmecánica?

1.2. Antecedentes

1.2.1. A nivel Internacional

En Estados Unidos, Sungbum (2020) desarrolló la investigación *Scheduling and Control with Machine Learning in Manufacturing Systems*, en el cual abordó la problemática del bajo rendimiento del sistema productivo en el sector manufactura debido a la deficiente planificación de la producción en los robots, este trabajo estableció una nueva metodología con el uso de machine learning para mejorar la eficiencia en el árbol de problemas para la solución de los problemas NP-difíciles, además nos brinda una guía para su implementación en fábricas inteligentes.

En Finlandia, Kajander (2020) desarrolló la investigación “*Predicting product cost development throughout production life cycle*” exploró cómo mejorar la estimación de costos de producción en sistemas de energía solar, centrándose en inversores solares. La investigación destacó la necesidad de integrar técnicas de pronóstico durante las etapas iniciales del desarrollo de productos para gestionar eficientemente los costos y responder a las dinámicas cambiantes del mercado.

En Finlandia, Zeeshan (2020) Desarrollo la investigación “*Demand drivers’ analysis and forecasting for production Planning*” donde utilizó modelos de predicción basados en indicadores macroeconómicos para ajustar la planificación de producción en industrias manufactureras. Este estudio destacó la efectividad de combinar modelos estadísticos como ARIMA y VAR que permitan anticiparse a cambios en la demanda y, por ende, minimizar costos asociados al exceso o déficit de capacidad.

En Estados Unidos, Zhang (2022) desarrolló la investigación “*Demand forecasting and decision making under uncertainty for long-term production planning in aviation industry*” en el cual abordó como aplicar modelos probabilísticos para pronosticar la demanda en la industria de la aviación, donde la alta variabilidad y los grandes costos de inversión plantean desafíos significativos. La investigación desarrolló modelos de movimiento browniano para mejorar la precisión de los pronósticos, lo que permitió optimizar las decisiones de planificación de capacidad y reducir riesgos financieros a largo plazo

En Estados Unidos, Guirguis (2024) desarrolló la investigación *Machine Learning-Enabled Multi-scale Process Monitoring and Development for Metal Additive Manufacturing*, en el cual abordó la problemática de la variabilidad de la impresión en el sector de manufactura aditiva de metales que implicaba sobrecostos por la baja calidad de las piezas, con este trabajo investigativo se pudo establecer métodos de monitoreo inteligente utilizando machine learning para identificar los defectos de los productos lo que llevó a una mejora de la

calidad y reducción de los costos de fabricación.

1.2.2. A nivel Nacional

En Lima, Rodríguez et al. (2017) desarrollaron la investigación *"Análisis y propuesta de implementación de un sistema de planificación de producción y gestión de inventarios y almacenes aplicado a una empresa de fabricación de perfiles de plásticos de PVC"* en el cual abordó el problema de la ineficiente planificación de la producción y gestión de inventarios en una empresa de fabricación de perfiles de PVC, las propuestas que estableció le permitieron un ahorro significativo en costos de producción además mejoró la eficiencia en la gestión de inventarios y almacenes.

En Lima, Quispe (2019) desarrolló la investigación *"Forecast of demand for pre-orders and orders of campaign for costume jewelry in DML"*. La investigación analizó la falta de modelos de pronósticos adecuados para prever la demanda de productos nuevos, aplicando algoritmos de aprendizaje automático como random forest. Los resultados mostraron una reducción significativa de los costos por pedidos en exceso y faltantes, logrando mejoras en la utilidad bruta y en el uso de capital de trabajo.

En Lima, Ruiz (2019) desarrolló la investigación *"Relación entre los pronósticos de la demanda y la gestión de inventarios en la empresa Cuponium SAC"*. Con el objetivo de analizar cómo los pronósticos pueden optimizar la gestión de inventarios y reducir costos, la investigación concluyó que un manejo adecuado de los pronósticos mejora la eficiencia operativa y minimiza problemas como el sobreabastecimiento o desabastecimiento.

En Lima, Fosca (2020) desarrolló la investigación *"Desarrollo de un modelo para la predicción del precio del cobre empleando herramientas de Machine Learning"* en el cual abordó el problema de la deficiente predicción en los precios del cobre en los años venideros en el mercado, concluyendo que los modelos de machine learning son altamente efectivos para la predicción de precios y su constante retroalimentación significa un porcentaje de error

menor.

En Trujillo, Quiñonez (2020) desarrolló la investigación "*Diseño de un sistema de planificación de producción basado en la teoría de pronósticos de ventas para reducir costos de producción en MYPE Favyssem*". La investigación abordó la problemática de la falta de un sistema eficiente para planificar la producción en esta empresa, proponiendo herramientas de planificación que optimizaron los procesos de producción y redujeron costos. Se concluyó que la implementación de estas herramientas incrementó la eficiencia productiva y generó ahorros significativos en los costos de operación.

1.3. Objetivos

1.3.1. Objetivo general

Determinar si la aplicación de Machine Learning en el pronóstico de la demanda reducirá los costos de producción de una empresa metalmeccánica.

1.3.2. Objetivos específicos

1.3.2.1. Objetivo específico 1. Determinar si la aplicación de Machine Learning en el pronóstico de la demanda de una empresa metalmeccánica optimizará el uso los recursos productivos de una empresa metalmeccánica.

1.3.2.2. Objetivo específico 2. Determinar si la aplicación de Machine Learning en el pronóstico de la demanda mejorará la productividad de una empresa metalmeccánica.

1.3.2.3. Objetivo específico 3. Determinar si la aplicación de Machine Learning en el pronóstico de la demanda garantizará la entrega a tiempo de los pedidos de una empresa metalmeccánica.

1.3.2.4. Objetivo específico 4. Determinar si la aplicación de Machine Learning en el pronóstico de la demanda mejorará la competitividad de los precios de una empresa metalmeccánica.

1.3.2.5. Objetivo específico 5. Determinar si la aplicación de Machine Learning en el

pronóstico de la demanda mejorará los márgenes de ganancia de una empresa metalmecánica.

1.4. Justificación

El presente trabajo de investigación tiene su justificación a nivel teórico según se puede estimar la aplicación de los conceptos teóricos del uso de Machine Learning en el pronóstico de la demanda y su impacto para reducir los costos de producción principalmente en una empresa metalmecánica.

En base al nivel metodológico, se expone cuantitativamente los resultados obtenidos por la aplicación del machine Learning en el pronóstico de la demanda y el porcentaje de reducción de los costos de fabricación previo diagnóstico cuantitativo del estado real de la empresa metalmecánica.

En base al nivel práctico, la aplicación de herramientas dentro del Machine Learning como Python mejoraran la planificación a largo plazo mediante estudios estadísticos que conllevan el seguimiento en tiempo real, donde el algoritmo aprenderá del mercado y los datos históricos de la empresa metalmecánica dando resultados más ajustados a la realidad.

1.5. Hipótesis

1.5.1. Hipótesis General

Es factible la aplicación de Machine Learning en el pronóstico de la demanda para reducir los costos de producción en una empresa metalmecánica.

1.5.2. Hipótesis Específicos

1.5.2.1. Hipótesis específica 1. Es factible la aplicación de Machine Learning en el pronóstico de la demanda para optimizar los recursos productivos de una empresa metalmecánica.

1.5.2.2. Hipótesis específica 2. Es factible la aplicación de Machine Learning en el pronóstico de la demanda para mejorar la productividad de una empresa metalmecánica.

1.5.2.3. Hipótesis específica 3. Es factible la aplicación de Machine Learning en el

pronóstico de la demanda para garantizar la entrega a tiempo de los pedidos de una empresa metalmecánica.

1.5.2.4. Hipótesis específica 4. Es factible la aplicación de Machine Learning en el pronóstico de la demanda para mejorar la competitividad de los precios de una empresa metalmecánica.

1.5.2.5. Hipótesis específica 5. Es factible la aplicación de Machine Learning en el pronóstico de la demanda para mejorar los márgenes de ganancia de una empresa metalmecánica.

II. MARCO TEÓRICO

2.1. Bases teóricas sobre el tema de investigación

2.1.1. *Machine Learning*

Según Zi-Hua (2021) una forma sencilla de explicar el machine Learning es comparándolo con actitudes humanas, misma que hace referencia a la capacidad que tienen las personas en guardar ciertas características de eventos para predecir resultados, la misma que hace alegoría en la situación de una compra de sandías donde una persona es capaz de distinguir las maduras y dulces del resto debido a factores en la característica de la sandía como la raíz ondulada y la falta de sonido al estrujarla. Estas características han sido aprendidas en base a situaciones pasadas, con lo cual para realizarlas nos basamos en predicciones. Así como nosotros podemos predecir situaciones basadas en experiencias la inteligencia artificial a partir de métodos computacionales puede inferir lo mismo, es a lo que llamamos machine learning. Una definición más técnica sería que Machine Learning es una rama de la inteligencia artificial que se enfoca en desarrollar algoritmos que permiten a las máquinas aprender de los datos sin ser programadas para cada tarea.

2.1.1.1. Algoritmos del Machine Learning.

A. Supervised learning (aprendizaje supervisado). Según Alpaydın (2020), el aprendizaje supervisado es una técnica fundamental en el análisis predictivo y tiene gran aplicabilidad en la toma de decisiones empresariales, especialmente en contextos como la predicción de la demanda y la planificación de la producción, ya que los algoritmos aprenden a partir de datos etiquetados para realizar predicciones sobre datos no vistos.

Los Algoritmos de aprendizaje supervisado son la regresión lineal, máquinas de soporte vectorial (SVM) y bosques aleatorios (random forests).

B. *Unsupervised learning (aprendizaje no supervisado).* Bishop (2006) describe el aprendizaje no supervisado como un enfoque para aprender patrones y estructuras inherentes en los datos sin necesidad de que estén etiquetados; este enfoque aplicado nos permite descubrir información oculta que puede ser utilizada para mejorar la toma de decisiones empresariales.

2.1.2. *Planificación de la producción*

Según Chapman (2006), toda empresa a pesar de su tamaño pequeña, mediana o grande necesita brindar un servicio o producto a un cliente final y en la medida que este se requiera ofrecer con un margen de ganancia alto se debe utilizar la planificación para utilizar efectivamente todos los recursos que dispone el ente económico, esto incluye una serie de principios fundamentales que abordan los factores externos e internos como el adecuado pronóstico debido a que generalmente los tiempos que solicitan los clientes son muy cortos y los ciclos productivos son largos, en tanto no se puede esperar al requerimiento de un cliente, esto significaría perder el costo de oportunidad y la planificación nos permite evitar que sucedan esas situaciones.

2.1.2.1. Aspectos de la planificación de la producción.

A. *Definición de objetivos.* Según Triadó (2018) la planificación comienza estableciendo metas claras para la producción, como los volúmenes a fabricar, los costos objetivos y los plazos de entrega, con lo cual se asegura el cumplimiento de los objetivos estratégicos de la organización.

B. *Estimación de la demanda.* Según Chase et al. (2009) la estimación de la demanda es la realización de proyecciones basadas en datos históricos, tendencias del mercado y técnicas como análisis de series temporales que permite ajustar la producción según la demanda esperada.

Según Box et al. (2015) los modelos de series temporales como ARIMA requieren suficientes observaciones que cubran múltiples ciclos estacionales para poder capturar adecuadamente los patrones de tendencia y estacionalidad.

C. Gestión de recursos. Según Triadó (2018) la gestión de recursos implica la asignación eficiente de materiales, equipos y personal para cumplir con los requisitos del plan maestro, se evalúa la capacidad de la planta y se identifican los cuellos de botella.

D. Programación de la producción. Según Barcelli (2013), la programación de la producción consiste en desarrollar un cronograma detallado que indique los tiempos y secuencias de las actividades productivas, ajustándose a la disponibilidad de recursos.

E. Control de inventarios. Según Velásquez (2003), el control de inventarios es establecer niveles óptimos de inventario para materias primas y productos terminados, minimizando costos asociados al almacenamiento y desabastecimiento.

F. Gestión de riesgos. Según Triadó (2018), la gestión de riesgos incluye la identificación y mitigación de posibles interrupciones, como fallos técnicos, cambios en la demanda o retrasos en la cadena de suministro.

G. Coordinación interdepartamental. Según Barcelli (2013), la planificación requiere integración con áreas como compras, ventas y logística, garantizando un flujo fluido de materiales y productos.

2.1.2.2. Machine Learning aplicado en la planificación

Lee et al. (2015) indica que, en el ámbito industrial, el Machine Learning aplicado en la planificación mejora la adaptabilidad de los sistemas de producción y facilita la predicción de fallas o interrupciones, contribuyendo así a la reducción de costos y el aumento de la eficiencia.

Por otro lado, Alpaydin (2020) señala que Machine Learning se basa en el desarrollo de algoritmos que aprenden y predicen con precisión, siendo especialmente útil en la

planificación estratégica y operativa, donde el análisis de datos masivos puede mejorar la eficiencia de las decisiones.

A. Definición del problema y objetivos. Según Russell y Norvig (2020), la correcta definición del problema es un paso fundamental para aplicar técnicas de inteligencia artificial de manera efectiva en distintos contextos.

B. Recolección y preparación de datos. Según Provost y Fawcett (2013), el uso efectivo de modelos analíticos requiere la recopilación de datos históricos relevantes como costos de producción, recursos utilizados y resultados, así como su adecuada limpieza y estructuración para garantizar resultados confiables.

C. Selección del modelo adecuado. Según Goodfellow et al. (2016) se debe escoger el modelo que más se adecue a la fluctuación de nuestros datos en función de las características de los datos y del problema a resolver.

Tabla 1

Tipos de modelos de pronósticos y sus principales usos

Tipo de Modelo	Uso Principal
Promedio móvil (MA)	Datos simples, sin tendencia ni estacionalidad.
Suavizamiento exponencial (ETS)	Datos con tendencia o estacionalidad moderada; enfoque interpretativo.
ARIMA	Datos con tendencia, sin estacionalidad.
SARIMA	Datos con tendencia y estacionalidad (p. ej., ventas mensuales con picos anuales).
Prophet (Facebook)	Datos con tendencias no lineales, estacionalidad múltiple o días festivos.
Redes neuronales (LSTM/RNN)	Datos muy complejos, con interacciones no lineales, para predicciones de largo plazo.
Regresión múltiple	Datos donde variables externas (como clima o marketing) influyen en las ventas.
Random Forest / Boosting	Datos con muchas características adicionales o con ruido significativo.

D. Entrenamiento y validación del modelo. Según Chollet (2018), el desempeño del modelo establecido es evaluado a través del uso de métricas como el error cuadrático medio (RMSE) o el coeficiente de determinación (R^2) las cuales deben ser aplicadas en conjuntos de datos divididos de entrenamiento.

Interpretación del MAPE:

MAPE < 10%: El modelo tiene un excelente rendimiento.

$10\% \leq \text{MAPE} < 20\%$: El modelo tiene un buen rendimiento, pero podría mejorarse.

$20\% \leq \text{MAPE} < 50\%$: El modelo tiene un rendimiento moderado.

MAPE $\geq 50\%$: El modelo tiene un rendimiento deficiente.

E. Integración en el sistema de planificación. Según Domingos (2015), la aplicación efectiva de los modelos de aprendizaje automático requiere considerar su implementación y su uso práctico en contextos reales.

F. Pruebas piloto y ajustes. En el desarrollo de modelos, es recomendable realizar pruebas en entornos controlados para identificar problemas y ajustar parámetros según los resultados obtenidos.

G. Monitoreo continuo y actualización del modelo. Según Russell y Norvig (2020)

los sistemas de inteligencia artificial deben evaluarse y ajustarse continuamente en tiempo real para mantener su desempeño en distintos entornos para mantener su efectividad.

2.1.3. Costos de Producción

Según Chang, L et al. (2012) los costos de producción son todos los costos incurridos al fabricar un producto o servicio y puede o no ser recuperados mediante la venta del producto o servicio, además las empresas tienen particularidades como el tipo de organización que tiene el ente económico, la visión, misión, los objetivos entre otros aspectos que hacen que cada empresa sea diferente a otra y el tratamiento de sus costos debe darse a través de un estudio personalizado de estos rasgos. Para Zugarramurdi (2024), los costos de fabricación, producción

u operacionales son los gastos necesarios para mantener un proyecto, que no implica acortar los costos indiscriminadamente, sino que se debe mantener solo los esenciales que determinaran el éxito, permanencia o quiebre de las empresas.

2.1.3.1. Reducción de costos de producción. La reducción de costos de producción alude al conjunto de estrategias, técnicas y herramientas implementadas para disminuir los costos involucrados en la fabricación de bienes o servicios sin comprometer la calidad del producto final. Según Heizer et al. (2020), la gestión eficiente de recursos, la eliminación de desperdicios y la optimización de procesos son esenciales para lograr una producción rentable y sostenible.

2.1.3.2. Procesos para la reducción de costos

A. Optimización de procesos. Slack et al. (2016) señalan que la mejora continua en los procesos productivos y el uso eficiente de los recursos pueden reducir significativamente los costos operativos.

B. Gestión de inventarios. Según Krajewski et al. (2018), la correcta planificación y control de inventarios permite minimizar los costos de almacenamiento y evitar el desabastecimiento.

C. Mantenimiento predictivo. Christopher (2016) destaca que la implementación de sistemas de mantenimiento predictivo reduce los tiempos de inactividad no planificados, mejorando la eficiencia de los equipos y disminuyendo los costos por fallas.

La reducción de costos implica no solo la optimización de procesos internos, sino también la mejora en la gestión de la cadena de suministro y la adopción de tecnologías como el machine learning y la automatización para maximizar la productividad y minimizar los desperdicios (Chopra y Meindl, 2019), la cual puede ser aplicada en la industria metalmeccánica,

III. MÉTODO

3.1. Tipo de Investigación

El presente trabajo de investigación será por su propósito es aplicada ya que la investigación aplicada tiene como finalidad el uso práctico del conocimiento obtenido. (Tamayo, 2004)

Por su enfoque, será una investigación cuantitativa ya que busca explicar, predecir y/o controlar fenómenos a través de datos numéricos. (Hernández et al., 2014)

Por su diseño será cuasi-experimental ya que los estudios cuasi-experimentales son útiles cuando no es posible controlar todas las variables. (Hernández et al., 2014)

3.2. Ámbito temporal y espacial

3.2.1. *Ámbito Temporal*

El desarrollo del presente estudio se realizará en el año 2024 aplicando el periodo de mayo a octubre y tomará datos históricos de los años 2022, 2023 y 2024.

3.2.2. *Ámbito Espacial*

El presente trabajo de investigación se verá limitada por el espacio físico de la empresa metalmecánica que pertenece al área de mobiliario institucional en la línea de producción de sillas metálicas tapizadas orientadas a la producción made-to-stock.

3.3. Variables

3.3.1. *Variable independiente*

Tabla 2

Operacionalización de las variables: Machine Learning y el pronóstico de la demanda

Variable	Definición conceptual	Definición operacional	Dimensiones	Indicadores
Machine Learning	Es la parte de la inteligencia artificial que construye a través del aprendizaje con	Variable medida en torno a la precisión de	Tipo de aprendizaje	Tasa de éxito
			Algoritmo	Validación 80/20 y 70/30

	algoritmos y modelos estadísticos (Ramon, 2014).	los datos obtenidos.	Procesamiento de Datos	Datos incluidos sobre el total de datos
Pronóstico de la demanda	Es a base para las decisiones de planificación y control de la cadena de suministro, ya que permite alinear la oferta con la demanda esperada (Chopra y Meindl, 2020)	Variable medida en torno en el mínimo porcentaje de error de la proyección.	Temporalidad	Frecuencia de los pronósticos
			Método	Método cuantitativo
			Precisión	Porcentaje de error absoluto medio (MAPE)

3.3.2. Variable dependiente

Tabla 3

Operacionalización de las variables: Costos de Producción

Variable	Definición conceptual	Definición operacional	Dimensiones	Indicadores
Costos de Producción	Son todos los costos que un ente económico emplea para la fabricación o la prestación de un servicio estos incluyen todos los costos indirectos y directos. (Gnosis, 2010)	Variable medida en torno a los costos directos e indirectos de fabricación.	Costos Directos	Índice de variación de los costos Directos.
			Costos Indirectos	Índice de variación de los costos Indirectos
			Costos de Producción	Variación de Sobrecostos y %SCRAP

3.4. Población y muestra

La población del presente estudio está conformada por todos los registros/datos relacionados con ventas y de producción mensual de la empresa metalmecánica durante el periodo 2022 (Nov, Dic), 2023 y 2024 (Ene-Oct).

La muestra estará constituida por la totalidad de los datos presentados en la población delimitadas por el ámbito espacial ya señalado para el análisis y desarrollo del modelo propuesto.

El tipo de muestreo será no probabilístico ya que se seleccionarán los datos disponibles

y accesibles para la investigación.

3.5. Instrumentos

Para la recolección de datos se utilizará como instrumento una base de datos histórica proporcionada por la empresa, la cual contiene información de ventas, producción, costos.

Asimismo, se empleará Microsoft Excel y Python (Google Collabs) para el procesamiento, análisis y modelamiento de los datos.

Estos instrumentos serán validados mediante la revisión de la consistencia, integridad y confiabilidad de los datos recopilados.

3.6. Procedimientos

La primera etapa comprende en la evaluación de los datos teóricos que explican la aplicación del machine learning al planeamiento de la producción con el objetivo de reducir los altos costos productivos. La segunda etapa comprende en las técnicas de recolección de datos, por ello se desarrolló una base de datos de los registros históricos de producción de la empresa metalmecánica para facilitar las consultas de los datos cuantitativos. Finalmente, se realizará el desarrollo y ajuste del pronóstico de la demanda.

3.7. Análisis de datos

El análisis de datos se llevará a cabo utilizando herramientas como Microsoft Excel y software estadístico, donde se realizará la limpieza, transformación y análisis de los datos históricos.


IV. RESULTADOS

4.1. Consideraciones iniciales

La metalmecánica donde se aplica el presente estudio es una empresa peruana dedicada a la producción y comercialización de mobiliario institucional y médico cuyo mercado es variable y competitivo. La empresa desarrolla 7 tipos de productos en el área de mobiliario institucional llamados familias de donde mediante análisis tomaremos el más representativo para realizar la aplicación del modelo. Como se observa en la Figura 1, la familia con más presencia son las sillas.

Figura 1

Participación de ventas (\$) por familia 2021-2023




La figura 1 indica que la familia de Sillas en el periodo 2021–2023 tuvo un mayor porcentaje en las ventas anuales.

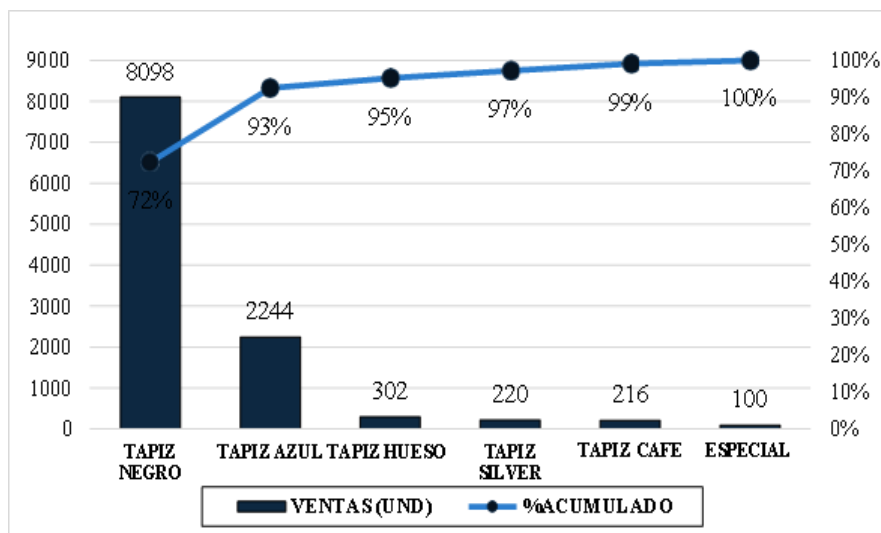
La empresa realiza un modelo de silla que se diferencia en el color del tapiz y adicional recibe pedidos especiales donde el cliente puede modificar las dimensiones de las sillas, el color del tapiz y si requiere adicionales. En las Figuras 2 y 3 podemos apreciar cual es la participación por tipo de silla de las ventas en unidades.

Figura 2

Pareto de Ventas (unid) por tipo de silla del periodo 2023 (Enero - Diciembre)

**Figura 3**

Pareto de Ventas (unid) por tipo de silla del periodo 2024 (Enero-October)



Según la Figura 2 y 3 en los periodos 2023 y 2024 las sillas con tapiz negro representaron la mayor venta.

La planta cuenta con diversas maquinarias para poder realizar el proceso de producción de las sillas y sus diferentes productos. La Tabla 4 indica las cantidades de máquinas asignadas en los procesos que involucra la producción de sillas apilables tapizadas.

Tabla 4*Máquinas de la empresa metalmecánica por proceso*

Proceso	Máquina/ estaciones	Cant
Cortado de tubos	Bodor	1
Cortado de planchas	Trulaser	1
Doblado de tubos	Dobladora de Tubos	1
Doblado de planchas	Dobladora de planchas	3
Soldadura MIG	Brazo robótico	1
	Estaciones MIG	3
Soldadura TIG	Estaciones TIG	5
Acabados	Esmerilado	1
Pintura	Linea de pintura	1
Ensamble y embalaje	Linea 1	1
Tapizado	Linea Tapizado	1

Nota. Para el periodo 2024, las sillas tapizadas, según el presupuesto anual, tienen asignadas las líneas detalladas. Sin embargo, estas son compartidas para la producción de los demás productos; solo el tapizado está asignado directamente a este proceso.

Figura 4*Silla apilable tapizada estándar*

Los pedidos estándar siguen el flujo de la Figura 5, sin embargo, los pedidos especiales las cuales se hacen a preferencia del cliente (medidas, color de tapiz, material, etc.) siguen el flujo de la Figura 6.

Figura 5

Diagrama de Operaciones del Proceso (DOP) de producción de sillas apilables tapizadas

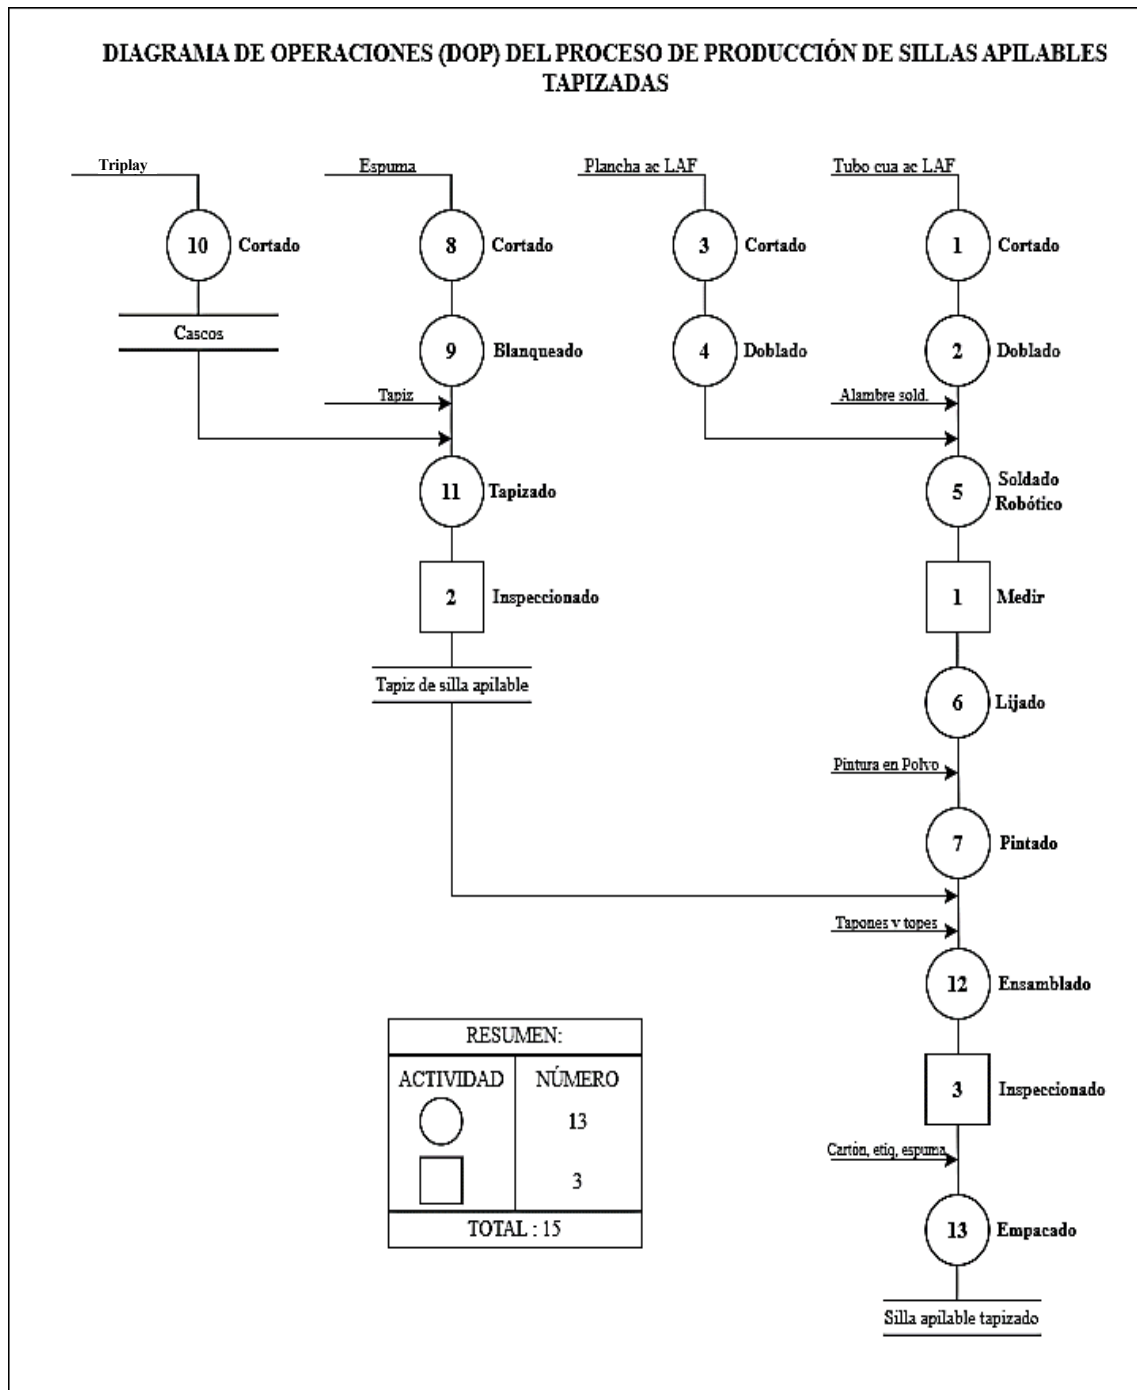
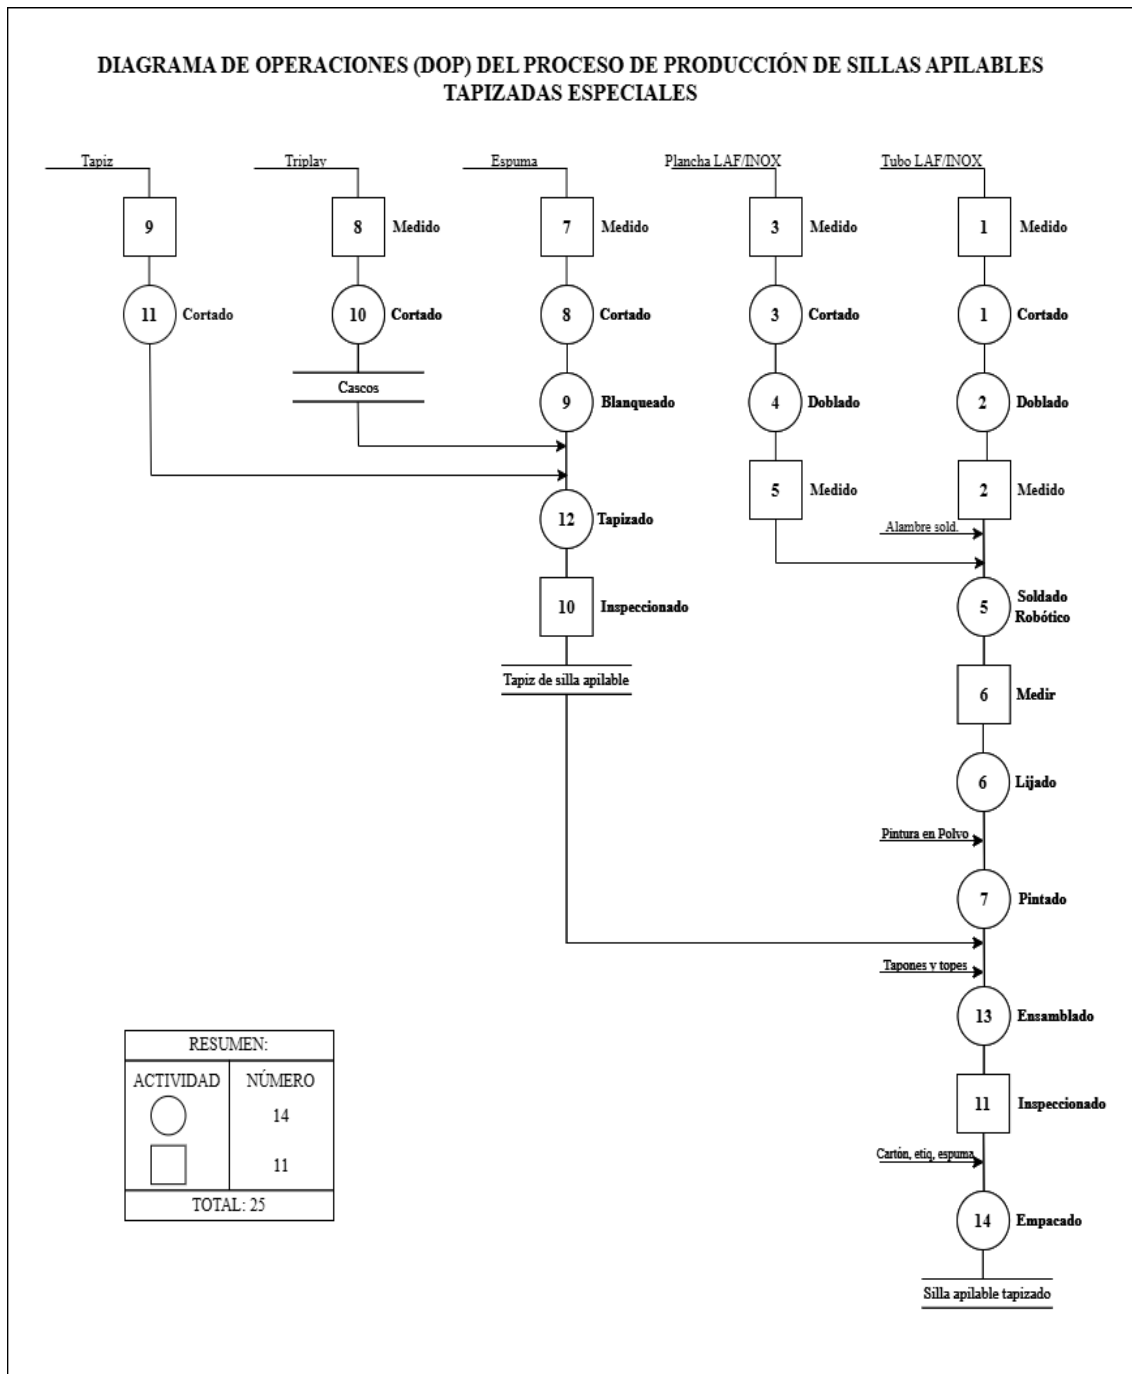


Figura 6

Diagrama de Operaciones (DOP) de Producción de Sillas apilables Tapizadas especiales




Para establecer los costos necesitamos identificar los tiempos de producción de las sillas y los tiempos de Set up, mismas que serán presentados en las Figura 7 para tiempos de producción y Tabla 5 para los Set ups por procesos.

Estos datos serán evaluados para la comparativa de costo beneficio de la presente investigación.

Figura 7

Flujo de la producción de sillas apilables.



Nota. El flujograma está en ciclo en unidades/semana, donde A = Cortado de tubos, B = Doblado de tubos, C = Cortado de planchas, D = Doblado de planchas, E = Tapizado, F = Brazo robótico, G = Acabados, H = Pintura, siendo el cuello de botella el proceso E = Tapizado.

Tabla 5

Set Up por proceso 2024

Proceso	Cantidad (Horas)	Aplica
Cortado de tubos	0.5	Por producto
Doblado de tubos	1	Por producto
Cortado de planchas	0.1	Por producto
Doblado de planchas	0.25	Por producto
Tapizado	3	Por producto
Brazo robótico	16	Por producto
Acabados	0	-
Pintura	15	Por día laborado
Ensamble y embalaje	0	-

La empresa Trabaja bajo régimen regular con 48 horas por semana de lunes a viernes, y anualmente las máquinas tienen mantenimiento predictivo según lo muestra el siguiente calendario de la Tabla 6.

Tabla 6

Cronograma de mantenimiento anual

Maq	H	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Set	Oct	Nov	Dic
Bodor	19.2	X						X					
Trulaser	28.8		X						X				
Doblado tubos	9.6			X						X			
ACL	9.6				X						X		
Brazo robótico	28.8					X						X	
Línea de pintura	38.4						X						X
Periféricos	9.6	X		X		X		X		X		X	
Equipos	9.6		X						X				

4.2. Estimación de la demanda

4.2.1. Definición del problema

El cuello de botella (ver Figura 7) es el proceso de tapizado donde se producen semanalmente 338 unid/semana con lo cual al mes se pueden fabricar 1,352 unid sin embargo, la demanda tiene picos altos que en el periodo 2023 al 2024 fue de 1388 unid. Adicional según la tabla 7 se indica el stock mínimo que se maneja

Tabla 7

Producción estándar mensual de sillas apilables tapizadas.

COLOR	CANTIDAD
TAPIZ NEGRO	1000
TAPIZ AZUL	300
TAPIZ SILVER	50

TAPIZ CAFÉ	50
TAPIZ HUESO	100
ESPECIALES	Make to Order

4.2.2. Recolección y preparación de datos

Se limpió los datos de la demanda, y se agrupo por los 4 productos de línea el cual muestra la Tabla 8, estos mismos datos se guardarán en un archivo Excel csv.

Tabla 8

Unidades Vendidas de Sillas apilables para un periodo de 24 meses por % de participación de cada familia


Fecha	Tapiz Negro	Tapiz Azul	Tapiz Silver	Tapiz Café	Tapiz Hueso	Ventas
Nov-22	46.60%	34.70%	0.10%	0.00%	18.60%	827
Dic-22	59.70%	39.90%	0.30%	0.00%	0.00%	1160
Ene-23	65.00%	31.40%	1.60%	2.00%	0.00%	995
Feb-23	54.80%	39.80%	4.10%	1.30%	0.00%	831
Mar-23	73.50%	16.20%	4.80%	1.40%	4.10%	796
Abr-23	71.30%	28.70%	0.00%	0.00%	0.00%	745
May-23	83.30%	16.70%	0.00%	0.00%	0.00%	1339
Jun-23	59.30%	30.70%	1.30%	0.60%	8.00%	846
Jul-23	68.20%	29.10%	0.00%	2.80%	0.00%	1191
Ago-23	75.80%	16.90%	4.40%	1.50%	1.40%	939
Set-23	98.70%	0.00%	0.20%	1.10%	0.00%	1055
Oct-23	46.20%	50.20%	3.60%	0.00%	0.00%	1183
Nov-23	57.60%	41.00%	1.40%	0.00%	0.00%	812
Dic-23	69.10%	0.90%	2.10%	0.00%	27.90%	1097
Ene-24	58.00%	40.20%	0.50%	1.30%	0.00%	824
Feb-24	43.30%	48.80%	6.30%	1.50%	0.00%	1388
Mar-24	74.40%	22.60%	0.40%	1.50%	1.20%	855
Abr-24	81.50%	6.70%	4.30%	6.10%	1.40%	1386
May-24	99.40%	0.60%	0.00%	0.00%	0.00%	1033
Jun-24	71.50%	5.80%	2.20%	0.00%	20.50%	1216
Jul-24	81.90%	15.10%	0.00%	1.60%	1.40%	1068
Ago-24	77.40%	17.20%	1.00%	4.50%	0.00%	1338
Set-24	90.10%	6.50%	3.00%	0.40%	0.00%	832
Oct-24	61.20%	37.50%	0.00%	0.50%	0.80%	1140

4.2.3. Selección del modelo adecuado

Según la Figura 8, se puede observar que los datos tienen una tendencia y que es estacional, con picos por ello se usará SARIMA.

Figura 8

Gráfico Lineal de ventas en unidades de sillas tapizadas



Durante el procesamiento de datos no fue necesario excluir registros, ya que todos los datos fueron completos, coherentes y aptos para el análisis. Por ello, el indicador datos incluidos sobre el total de datos obtuvo un valor de 100%, reflejando que la totalidad del dataset fue empleada en la modelación.

4.2.4. Entrenamiento y validación del modelo

En primera instancia se suben los datos relevantes para el pronóstico en un formato csv. La figura 9 muestra el query usado para la creación del modelo de pronóstico basado en SARIMA.

Se divide los datos para evaluar el modelo (80% entrenamiento, 20% prueba). Se usa el modelo brindado por `auto_arima` para realizar los ajustes a las tendencias previamente ejecutado el `! pip install pmdarima` para instalar las bibliotecas de datos.

Figura 9

Ingreso de datos para el entrenamiento y validación del modelo

```

import pandas as pd
import matplotlib.pyplot as plt
from statsmodels.tsa.statespace.sarimax import SARIMAX
from sklearn.metrics import mean_squared_error, mean_absolute_error
from pmdarima import auto_arima

# Paso 1: Cargar los datos desde el archivo Excel
# Cambia 'data_set.xlsx'
data = pd.read_excel("data_set.xlsx")

# Paso 2: Preparar los datos
data['Fecha'] = pd.to_datetime(data['Fecha'])
data.set_index('Fecha', inplace=True) # Establecer la fecha como índice
ventas = data.iloc[:, 0] # Seleccionar la columna de ventas

# Paso 3: Explorar los datos
plt.figure(figsize=(10, 6))
plt.plot(ventas, label="Ventas")
plt.title("Datos de Ventas Mensuales")
plt.xlabel("Fecha")
plt.ylabel("Ventas")
plt.legend()
plt.show()

# Paso 4: Selección automática de parámetros con auto_arima
# Esto sugerirá los mejores parámetros para SARIMA
auto_model = auto_arima(ventas, seasonal=True, m=12, trace=True, error_action="ignore", suppress_warnings=True)
print("Parámetros sugeridos por auto_arima:", auto_model.order, auto_model.seasonal_order)

# Paso 5: Dividir los datos en entrenamiento y prueba
train_size = int(len(ventas) * 0.8)
train, test = ventas[:train_size], ventas[train_size:]

# Paso 6: Ajustar el modelo SARIMA
model = SARIMAX(train, order=auto_model.order, seasonal_order=auto_model.seasonal_order)
results = model.fit(dispatch=False)

# Paso 7: Pronóstico en los datos de prueba
forecast = results.get_forecast(steps=len(test))
predicted_mean = forecast.predicted_mean
forecast_ci = forecast.conf_int()

# Paso 8: Calcular métricas de error
mse = mean_squared_error(test, predicted_mean)
mae = mean_absolute_error(test, predicted_mean)

# Paso 9: Visualizar resultados
plt.figure(figsize=(12, 6))
plt.plot(ventas, label="Datos originales", color="blue")
plt.plot(test.index, predicted_mean, label="Pronóstico (Prueba)", color="red")
plt.fill_between(test.index, forecast_ci.iloc[:, 0], forecast_ci.iloc[:, 1], color="pink", alpha=0.3, label="Intervalo de confianza")
plt.axvline(x=test.index[0], color="gray", linestyle="--", label="Inicio de prueba")
plt.legend()
plt.title("Pronóstico SARIMA en Datos de Prueba")
plt.xlabel("Fecha")
plt.ylabel("Ventas")
plt.show()

# Paso 10: Proyección de 12 meses hacia adelante
future_forecast = results.get_forecast(steps=12)
future_predicted = future_forecast.predicted_mean
future_ci = future_forecast.conf_int()

future_dates = pd.date_range(ventas.index[-1], periods=12, freq='M')
plt.figure(figsize=(12, 6))
plt.plot(ventas, label="Datos originales", color="blue")
plt.plot(future_dates, future_predicted, label="Proyección (12 meses)", color="green")
plt.fill_between(future_dates, future_ci.iloc[:, 0], future_ci.iloc[:, 1], color="lightgreen", alpha=0.3, label="Intervalo de confianza")
plt.legend()
plt.title("Proyección SARIMA para los Próximos 12 Meses")
plt.xlabel("Fecha")
plt.ylabel("Ventas")
plt.show()

# Paso 11: Mostrar resultados y errores
print("Error Cuadrático Medio (MSE):", mse)
print("Error Absoluto Medio (MAE):", mae)
print("\nProyección de ventas para los próximos 12 meses:")
projection = pd.DataFrame({'Fecha': future_dates, 'Proyección': future_predicted})
print(projection)

```

Con ello se puede calcular el error absoluto, según la Figura 10 nuestro modelo tiene un % error absoluto 15.7% (MAPE) El modelo tiene un buen rendimiento, pero podría mejorarse.

Figura 10

Cálculo del Error Absoluto % en google Collabs (Lenguaje Python)

```

1 ▶ mape = (abs(test - predicted_mean) / test).mean() * 100
2 print("MAPE:", mape, "%")

```

MAPE: 15.652208496229608 %

4.2.5. Integración en el sistema de planificación

Se integra con el ERP Software inhouse desarrollado de la empresa, subiendo los datos actualizados a final de cada mes y se añade para poder hacer las comparativas con los pronósticos.

4.2.6. Pruebas piloto, ajustes y Evaluación del modelo

Figura 11

Prueba Piloto de SARIMA en Google Collabs (Lenguaje Python)




Figura 12

Evaluación del modelo inicial en Google Collabs (Lenguaje Python)

```

0.5 ✓ [7] from sklearn.metrics import mean_squared_error
    mse = mean_squared_error(test, predicted_mean)
    print("MSE:", mse)
    ↕ MSE: 36031.49583877263

0.5 ✓ [8] from sklearn.metrics import mean_absolute_error
    mae = mean_absolute_error(test, predicted_mean)
    print("MAE:", mae)
    ↕ MAE: 162.34846718350158

0.5 ✓ [9] mape = (abs(test - predicted_mean) / test).mean() * 100
    print("MAPE:", mape, "%")
    ↕ MAPE: 15.652208496229608 %

0.5 ✓ [10] rmse = mse ** 0.5
    print("RMSE:", rmse)
    ↕ RMSE: 189.819640287228

```

Se tiene estacionalidad en los datos (ventas más altas en ciertos meses), por ello ejecutamos el comando `auto_arima` para maximizar los resultados y disminuir el MAPE.

Figura 13

Cálculo de Errores en Google Collabs (Lenguaje Python) luego de ejecutar `auto_arima`

```

0.5 ✓ [11] mape = (abs(test - predicted_mean) / test).mean() * 100
    print("MAPE:", mape, "%")
    ↕ MAPE: 10.465318681276177 %

```

En la figura 14 se observa que al ejecutar los demás cálculos de error con los parámetros establecidos por `auto_arima` estos han disminuido considerablemente.

Figura 14

Evaluación del modelo modificado en Google Collabs (Lenguaje Python)

```
[11] from sklearn.metrics import mean_squared_error
      mse = mean_squared_error(test, predicted_mean)
      print("MSE:", mse)
```

↔ MSE: 18013.13043064082

```
[12] from sklearn.metrics import mean_absolute_error
      mae = mean_absolute_error(test, predicted_mean)
      print("MAE:", mae)
```

↔ MAE: 103.4552667409815

```
[13] mape = (abs(test - predicted_mean) / test).mean() * 100
      print("MAPE:", mape, "%")
```

↔ MAPE: 10.465318681276177 %

```
rmse = mse ** 0.5
print("RMSE:", rmse)
```

↔ RMSE: 134.21300395505952

4.2.7. Pronóstico basado en SARIMA

Figura 15

Proyección de los meses nov-2024 a jul-2024




Tabla 9

Tabulación del pronóstico de la demanda del modelo SARIMA

FECHA	PRONÓSTICO
Nov-24	1,095
Dic-24	1,213
Ene-25	1,105
Feb-25	1,181
Mar-25	1,108
Abr-25	1,157
May-25	1,106
Jun-25	1,136
Jul-25	1,101

4.3. Impacto en la empresa

4.3.1. Reducción de costos de producción

Se realiza una corrida en el modelo SARIMA para poder hacer una comparativa de 6 meses desde mayo a octubre del 2024 tal como muestra la Figura 16 y la tabla 10.

Figura 16

Cambio de la prueba del modelo SARIMA




Tabla 10*Tabulación del pronóstico del periodo mayo - octubre 2024*

FECHA	REAL	PRONÓSTICO	APE
May-24	1,033	996	4%
Jun-24	1,216	1,198	1%
Jul-24	1,068	1,027	4%
Ago-24	1,338	1,147	14%
Set-24	832	1,040	25%
Oct-24	1,140	1,110	3%

En la Tabla 10 se observa que tenemos fuera del umbral de 15% de APE, un solo valor con lo cual nuestra tasa de éxito para los 6 pronósticos tomados de muestra es de 83.3% lo cual nos indica que 8 de cada 10 pronósticos están suficientemente cerca de la realidad como para ser útiles en decisiones de compra y planificación.

Tabla 11*Sobrecostos de la producción de mayo - octubre 2024*

MES	May	Jun	Jul	Ago	Set	Oct	TOTAL
Producido (unid)	1,236	1,124	1,268	1,124	1,236	1,236	7,224
Demanda Real (unid)	1,033	1,216	1,068	1,338	832	1,140	6,627
Sobre stock (unid)	203	-92	200	-214	404	96	597
Costo del almacenaje Sobre stock (\$)	\$253	-\$6	\$14	-\$15	\$28	\$7	
Meses Inmovilizado	6	5	4	3	2	1	
Costo total del almacenaje Sobre stock (\$)	\$1,517	-\$32	\$55	-\$44	\$56	\$7	\$1,559

Costo de producción (\$/unidad)	\$35	\$35	\$35	\$35	\$35	\$35	
Valorizado del Stock inmovilizado (\$)	\$7,105	-\$3,220	\$7,000	-\$7,490	\$14,140	\$3,360	\$20,895
SOBRECOSTO	\$8,622	-\$3,252	\$7,055	-\$7,534	\$14,196	\$3,367	\$22,454

Nota. La tabla muestra las cantidades de sillas apilables tapizadas producidas en el periodo de mayo a octubre del 2024, siendo el costo de producción de la silla \$35, el costo de almacenaje por mes de \$1.25/silla y el costo de sobretiempo de \$2.085/silla. En dicho periodo se ha tenido un sobrecosto total de \$22,454.

Tabla 12

Sobrecostos del pronóstico de la producción de mayo - octubre 2024

MES	May	Jun	Jul	Ago	Set	Oct	TOTAL
Pronóstico (unidad)	996	1,198	1,027	1,147	1,040	1,110	6,518
Demanda Real (unidad)	1,033	1,216	1,068	1,338	832	1,140	6,627
Sobre stock (unidad)	-	-	-	-	208	-30	178
Costo del almacenaje Sobre stock (\$)	\$0	\$0	\$0	\$0	\$14	-\$2	
Meses Inmovilizado	6	5	4	3	2	1	
Costo total del almacenaje Sobre stock (\$)	\$0	\$0	\$0	\$0	\$29	-\$2	\$27
Costo de producción (\$/unidad)	\$35	\$35	\$35	\$35	\$35	\$35	
Valorizado del Stock inmovilizado (\$)	\$0	\$0	\$0	\$0	\$7,280	-\$1,050	\$6,230

Unid no cubiertas	37	18	41	191			
Valorizado del Sobretiempo (\$)	\$77	\$37	\$85	\$398			\$598
SOBRECOSTO	\$77	\$37	\$85	\$398	\$7,309	-\$1,052	\$6,854

Nota. La tabla muestra las cantidades de sillas apilables tapizadas del modelo SARIMA de mayo a octubre del 2024, siendo el costo de producción de la silla \$35, el costo de almacenaje por mes de \$1.25/silla y el costo de sobretiempo de \$2.085/silla. En dicho periodo se ha tenido un sobrecosto total de \$6,854.

Tabla 13

Disminución de los sobrecostos al usar el modelo

Indicador	Producción	Pronóstico	Reducción (%)
Costo de inventario	\$1,559	\$27	98%
Costo de sobreproducción	\$20,895	\$6,230	70%
Costo de Sobretiempo	\$0	\$598	--
Total de costos	\$22,454	\$6,854	70%

4.3.2. Mejora de productividad

Tabla 14

Productividad de Mayo a Octubre del 2024

Mes	May	Jun	Jul	Ago	Set	Oct	TOTAL
Producido (unid)	1,236	1,124	1,268	1,124	1,236	1,236	7,224
Tiempo total usado	1,100	1,005	1,119	937	1031	1,058	6,251
Productividad und/hora	1.12	1.12	1.13	1.2	1.2	1.17	1.16

Nota. La tabla muestra la productividad de la producción de sillas apilables tapizadas de mayo a octubre del 2024.

Tabla 15

Productividad calculada para Mayo a Octubre del 2024

Mes	May	Jun	Jul	Ago	Set	Oct	TOTAL
Producido (unid)	1,033	1,216	1,068	1,338	1,040	1,140	6,835
Tiempo total usado	865	1,012	893	1,110	835	915	5,629
Productividad und/hora	1.19	1.2	1.2	1.21	1.25	1.25	1.21

Nota. La tabla muestra la productividad calculada de sillas apilables tapizadas del modelo SARIMA de mayo a octubre del 2024. Se basó en la eficiencia promedio de 88% y el declive en la cantidad de *set-ups* que se ejecutarían.

Figura 17

Comparativo de los Set ups del pronóstico y la producción real

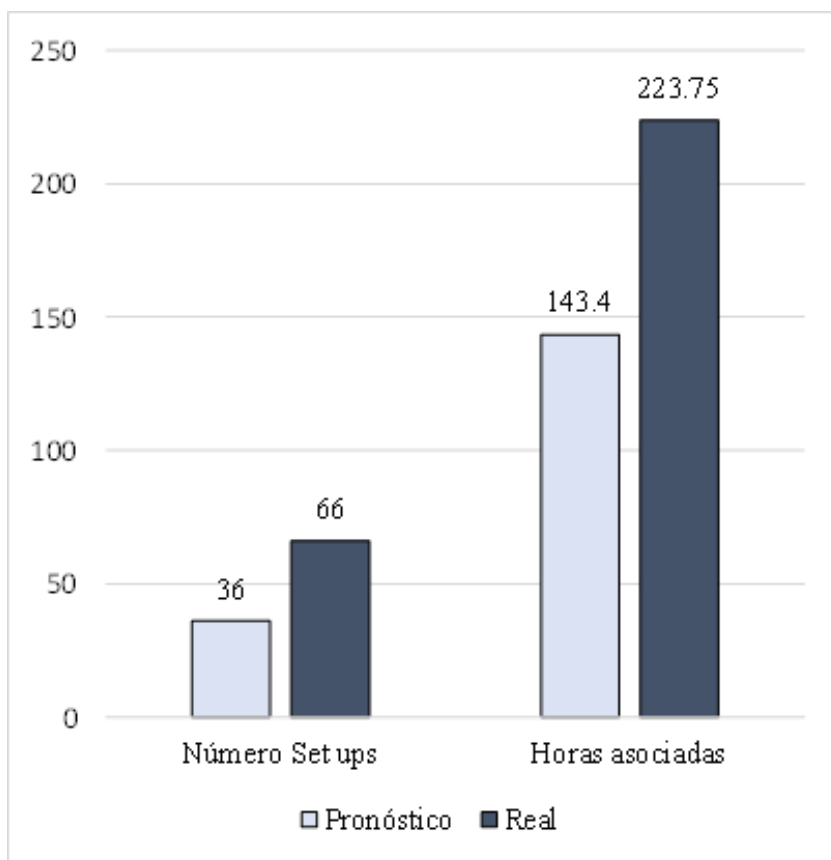
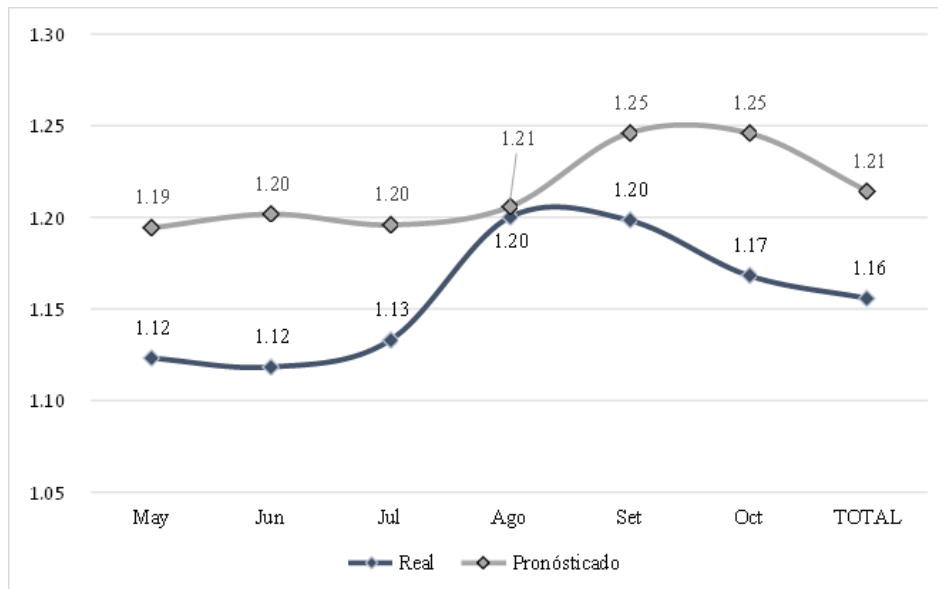


Figura 18

Comparativo de la productividad generada por el modelo de SARIMA y el real alcanzado



4.3.3. Reducción de costos de Materia Prima

Tabla 16

Costos de Materia Prima Directa


TIPO	DESCRIPCION	CANT	U.M	COSTO
Tubos	Tubo ac cua laf 1 x 1.2 x 6000mm	0.73	Unid	\$ 4.51
Planchas	Plancha ac laf 1.0 x 1200 x 2400mm	0.11	Unid	\$ 2.01
Triplay	Triplay 12mm x 1220 x 2440mm	0.09	Unid	\$ 1.88
Tapiz	Tapiz liso ultracuero negro 1.40mt	0.44	Mtr	\$ 1.82
Pintura	Pintura en polvo marfil cja x 20kg	0.15	Kgm	\$ 0.75
Espuma	Espuma 18kg/m3 2" x 1mt x 2mt	0.06	Unid	\$ 0.54
Pernería	Sto bol 3/16 x 3/4 c/red zn	4	Unid	\$ 0.52
Pernería	Sto bol 3/16 x 1.1/2 c/red unc zn	3	Unid	\$ 0.27
Plásticos	Tope plast red 3/8 gris (mpm-11g)	4	Unid	\$ 0.20
Pernería	Tuerca tipo uña 3/16 zincado	7	Unid	\$ 0.14
Plásticos	Tapon plast cua 1" acab. Semicilindro gris	2	Unid	\$ 0.10
Plásticos	Tapon plast cua 1" c/logo gris	4	Unid	\$ 0.04
COSTO DE MATERIA PRIMA				\$ 12.78

Nota. La tabla muestra la materia prima empleada en la fabricación de una silla apilable

tapizada, las cantidades y su unidad adicional se muestra el costo actual al 31 de octubre del 2024.

Figura 19

Sectorización ABC de Costos de Materia Prima de la producción de sillas apilables tapizadas.



En función a la Figura 19 Se obtiene que las familias que tienen un mayor impacto en el costo son los tubos (Sector A), planchas y triplay (Sector B) de los cuales haremos el análisis comparativo en compras y costos.

Tabla 17

Costos de las compras de los materiales ABC

Mes	May	Jun	Jul	Ago	Set	Oct	TOTAL
Costos de compra	\$6,180	\$1,545	\$11,124	\$7,725	\$9,270	\$3,399	\$39,243
Sobrecostos de Almacenaje	\$216	\$26	\$162	\$201	\$335	\$133	\$1,074
Costos Totales	\$6,396	\$1,571	\$11,286	\$7,926	\$9,605	\$3,532	\$40,317

Nota. La tabla muestra los costos asociados a las compras mensuales de los tubos, planchas y triplay clasificados como materiales A y B en la producción de las sillas apilables tapizadas, teniendo en cuenta que para mayo quedaron como stock final 832 unidades de tubos, 200

unidades de planchas y 250 unidades de triplay con un costo total de \$7,923.

Tabla 18

Costos de las compras de la materia prima ABC del pronóstico

MES	May	Jun	Jul	Ago	Set	Oct	TOTAL
Costos de compra		\$5,099	\$5,717	\$6,644	\$5,871	\$6,489	\$29,819
Sobrecostos de Almacenaje	\$28	\$3	\$2	\$4	\$2	\$6	\$45
Costos por compras de faltantes	\$473	\$93	\$185	\$1,202	-	-	\$1,953
Costos Totales	\$501	\$5,194	\$5,903	\$7,850	\$5,873	\$6,495	\$31,817

Nota. La tabla muestra los costos asociados a las compras mensuales de los tubos, planchas y triplay clasificados como materiales A y B del pronóstico SARIMA de la producción de las sillas apilables tapizadas, teniendo en cuenta que para mayo quedaron como stock final 832 unidades de tubos, 200 unidades de planchas y 250 unidades de triplay con un costo total de \$7,923.

Figura 20

Comparativa por mes del costo real de M.P de la producción de sillas tapizadas apiladas y de la proyección




Tabla 19

Comparativo total del periodo de mayo a octubre de los costos del pronóstico SARIMA y el real

Descripción	Costo Real	Costo del Pronóstico	%
Costos de compra	\$39,243	\$29,819	24%
Sobrecostos de Almacenaje	\$1,074	\$45	96%
Costos por compras de faltantes	0	\$1,953	-
Costos Totales	\$40,317	\$31,817	21%

4.3.4. Reducción de desperdicio de Metales

Para el análisis de la reducción del desperdicio, se ha considerado que se calculará en base a el peso más representativo en kilos debido a que el % desperdicio o %SCRAP es calculado a partir de los kilos de merma generados de la producción total de sillas. La tabla 20 nos muestra por tipo de material el peso que se utiliza para la fabricación de una silla.

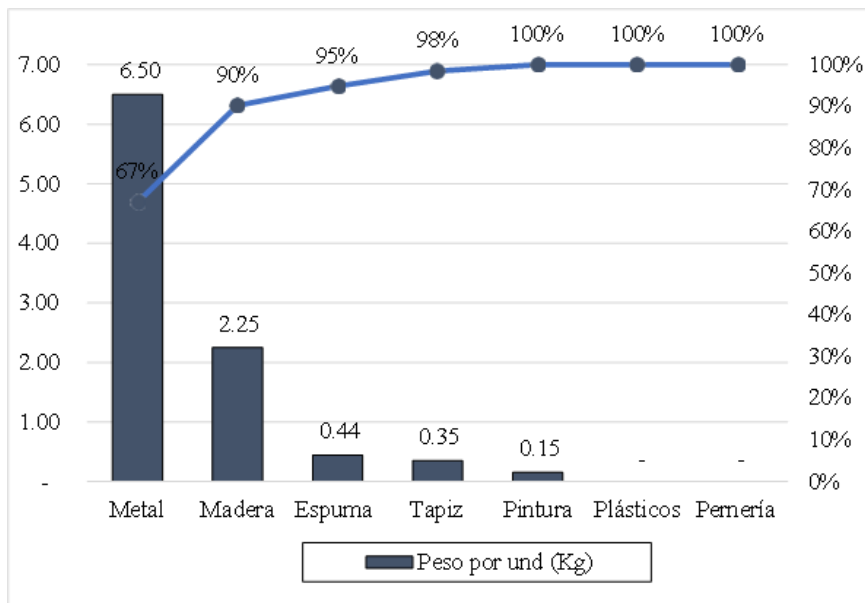
Tabla 20

Peso de materia prima usada por tipo de material

Tipo de Materia	Peso por und (Kg)
Metal	6.5
Madera	2.25
Espuma	0.44
Tapiz	0.35
Pintura	0.15
Plásticos	-
Pernería	-
Peso de Silla Metálica apilada (KG)	9.69

Figura 21

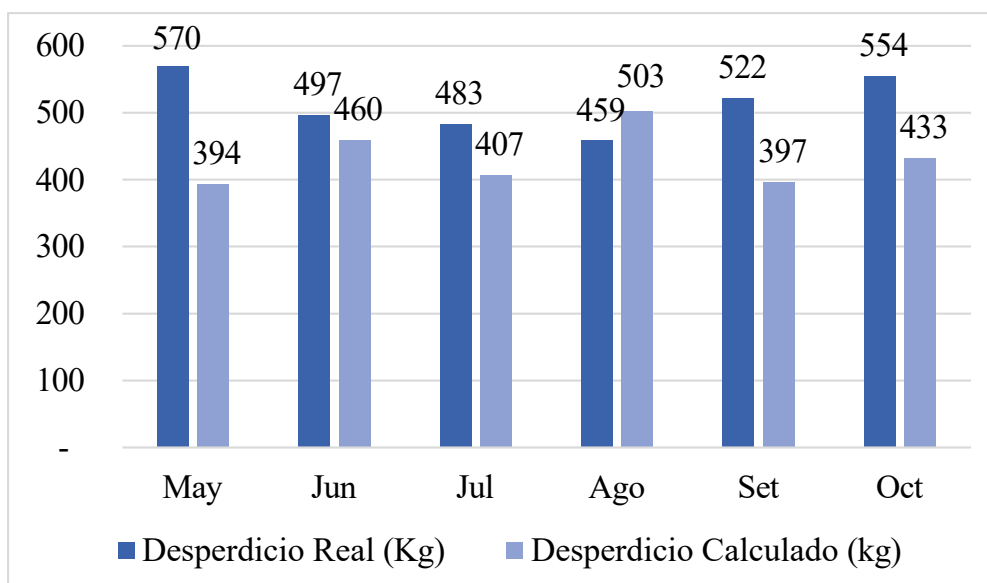
Pareto de Peso por material usado en la fabricación de sillas apilables



Nota. El Pareto muestra al tipo de material Metal (Planchas y tubos) como mayor representación en el peso siendo seguido por madera (Tripley), espuma, Tapiz, pintura, plásticos y pernería.

Figura 22

Merma total en kilos por mes de la producción de sillas apilables tapizadas y el peso calculado de la merma del pronóstico SARIMA

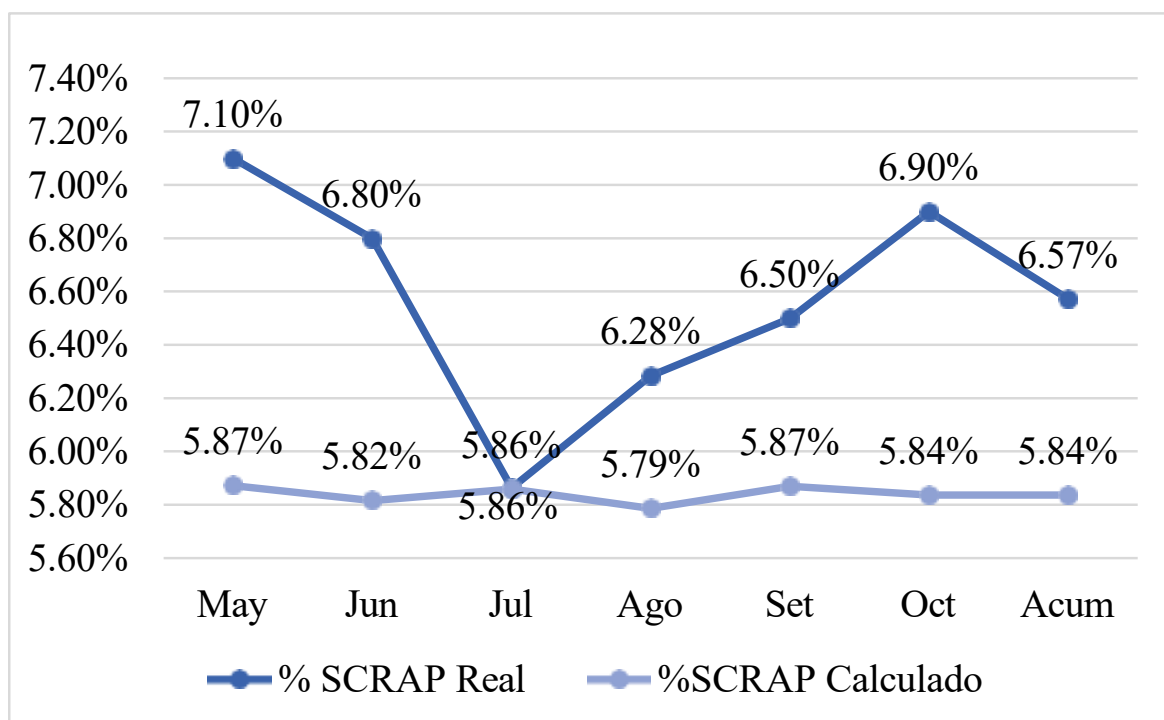


La Figura 22 muestra los kilos de merma por mes de la producción de sillas apilables tapizadas en el periodo mayo a octubre versus los kilos de merma generados a partir del cálculo de la aplicación del pronóstico en SARIMA teniendo en cuenta que como merma propia del proceso es 5.5% y el cálculo diferencial se debe a la merma generada por el ajuste máquina y la primera unidad de muestra. Si comparamos estos dos resultados es evidente que el desperdicio calculado es menor, esto se debe a que en el pronóstico se han considerado menos unidades de producción a comparación de la producción real, por lo cual en la Figura 23 se hace una comparación del porcentaje de desperdicio generado (%SCRAP) para evidenciar la mejora con un solo criterio, la fórmula aplicada es la siguiente:

$$\%SCRAP = \frac{\text{Kilos de merma}}{\text{Kilos buenos de producción} + \text{Kilos de merma}} \times 100$$

Figura 23

%SCRAP real de la producción de sillas apilables tapizadas versus %SCRAP calculado a partir del pronóstico SARIMA



4.3.5. Aumento de Ontime

Para la evaluación de las entregas a tiempo de los pedidos, se toma en cuenta el KPI de On time real del periodo evaluado (Mayo -2024 a Octubre-2024) en contraposición con el calculado en el periodo con el modelo SARIMA.

Figura 24

% On time del despacho de sillas apilables del periodo Mayo a octubre 2024




Figura 25

%On time de la aplicación del modelo SARIMA de la producción de sillas apilables tapizadas del periodo Mayo a Octubre 2024





Figura 26

Comparación del %On time real y del pronóstico



V. DISCUSIÓN DE RESULTADOS

El análisis de data histórica de la demanda de las sillas metálicas apilables tapizadas desde el año 2022 ha permitido graficar y determinar una tendencia con picos estacionales para poder realizar un modelo de pronóstico adecuado y utilizando machine learning para que se cree un algoritmo en torno de pruebas que pueda ser ajustado con nueva data ingresada mes a mes. El modelo usado fue el SARIMA que en un inicio nos dio un MAPE porcentual de 15% ver Figura 9, en un ambiente de pruebas de 80% dato y 20% prueba ver Figura 10, adicional para poder determinar el impacto de su aplicación se hizo una prueba 70%/30% reduciéndose el MAPE de 10%. Ahora bien, se pudo establecer que de los sobrecostos mas importantes en nuestra investigación cuasi- experimental se reduce considerablemente, la tabla 11 indica en cantidades de dólares los sobrecostos generados al seguir con la producción opinada, y la Tabla 12 los generados por la aplicación del modelo. En la comparativa de ambas la Tabla 13 indica que en términos porcentuales los costos de inventarios se reducen en un 98.3%, los costos de producción en un 70.2% y se incrementa el costo de sobretiempos, sin embargo, queda demostrado que a pesar de que se pueda generar un sobretiempos la implementación del modelo reduce los sobrecostos en un 69.5%.

En cuanto a la productividad, el pronóstico impacta directamente a la productividad global ya que se necesitan menos horas de set up lo cual tiene una incidencia en la disminución de la productividad global promedio del periodo de 1.16 a 1.21und/horas arrojadas por la aplicación del pronóstico.

Adicional a comparación con el flujo normal se disminuye los costos de materia prima representando en el periodo de prueba una reducción de costos del 21%.

Al haber un flujo constante productivo se reduce el desperdicio de un promedio de 6.57% en el periodo mayo a octubre a 5.84%, esta reducción de 0.73% es debido a la disminución de arranques de máquina y programas de corte que pueden ser mejor optimizados.

El impacto de este modelo aumenta nuestro % de cumplimiento de entregas en un 4%, siendo un %On time de 88% en el periodo y por la aplicación del modelo SARIMA este aumenta en un 92%.

Es factible para la empresa reducir su precio, ya que los costos se mantienen los mínimos posibles, sin embargo, esta decisión es de campo gerencial debido a que mantener los precios significaría tener un margen de ganancia mayor.

VI. CONCLUSIONES

- 6.1. Es factible la aplicación de Machine Learning en el pronóstico de la demanda para reducir los costos de producción en una empresa metalmecánica.
- 6.2. Es factible la aplicación de Machine Learning en el pronóstico de la demanda para optimizar los recursos productivos de una empresa metalmecánica.
- 6.3. Es factible la aplicación de Machine Learning en el pronóstico de la demanda para mejorar la productividad de una empresa metalmecánica.
- 6.4. Es factible la aplicación de Machine Learning en el pronóstico de la demanda para garantizar el cumplimiento de los plazos de fabricación de una empresa metalmecánica.
- 6.5. Es factible la aplicación de Machine Learning en el pronóstico de la demanda para mejorar la competitividad de los precios de una empresa metalmecánica.
- 6.6. Es factible la aplicación de Machine Learning en el pronóstico de la demanda para mejorar los márgenes de ganancia de una empresa metalmecánica.

En resumen, el modelo SARIMA no solo optimiza los procesos productivos y logísticos, sino que también tiene un impacto positivo en la reducción de costos, la mejora de la productividad y el cumplimiento de los tiempos de entrega, lo que lo hace altamente factible para la empresa. Esto posiciona a la empresa en una mejor situación para competir en el mercado y gestionar sus recursos de manera más eficiente.

VII. RECOMENDACIONES

- 7.1. Se recomienda implementar modelos de Machine Learning basados en datos históricos de la empresa, con la finalidad de mejorar la precisión del pronóstico de la demanda y contribuir a la reducción de costos asociados a la producción actualizando periódicamente el modelo con nueva data para mantener su precisión frente a cambios en patrones de demanda.
- 7.2. Se recomienda incorporar herramientas de Machine Learning en los procesos de planificación de la producción, a fin de optimizar la asignación de los recursos productivos de la empresa metalmeccánica.
- 7.3. Se recomienda capacitar al personal en el uso e interpretación de modelos de Machine Learning, con el propósito de fortalecer la toma de decisiones orientadas a la mejora de la productividad.
- 7.4. Se recomienda integrar los modelos de pronóstico de demanda basados en Machine Learning con los sistemas de planificación de la producción, con el objetivo de mejorar la programación y garantizar el cumplimiento de los plazos de fabricación.
- 7.5. Se recomienda utilizar los resultados obtenidos de los modelos de Machine Learning para establecer estrategias de precios más competitivas, sustentadas en una mejor estimación de la demanda.
- 7.6. Se recomienda realizar un seguimiento continuo de los indicadores financieros y productivos tras la implementación de modelos de Machine Learning, con el fin de mejorar los márgenes de ganancia de la empresa.

VIII. REFERENCIAS

- Alpaydin, E. (2020). *Introduction to machine learning* (4th ed.). MIT Press.
- Barcelli, G. (2013). *Gestión, planificación y control de la producción*. Ingeniería Industrial, (24), 13-26.
http://revistas.ulima.edu.pe/index.php/Ingenieria_industrial/article/view/523/486
- Bishop, C. (2006). *Pattern recognition and machine learning*. Springer.
- Box, G., Jenkins, G., Reinsel, G., y Ljung, G. (2015). *Time series analysis: Forecasting and control* (5th ed.). Wiley.
- Chang, L. Alba M., González N., López P., Moreno, M. Myurna (2012). *La Importancia De La Contabilidad De Costos*. [Material de clase]. Instituto Tecnológico de Sonora.
<https://altior-edunube.com/wp-content/uploads/2022/04/Lec-2-Contabilidad-Admva.pdf>
- Chapman N. (2006). *Planificación y control de la producción*. Pearson Educación.
- Chase, R., Jacobs, F., y Aquilano, N. (2020). *Operations Management for Competitive Advantage*. McGraw-Hill Education.
- Chopra, S., y Meindl, P. (2016). *Supply chain management: Strategy, planning, and operation* (6th ed.). Prentice Hall.
- Christopher, M. (2016). *Logistics and Supply Chain Management* (5th ed.). Pearson.
- Flint, P. (2006). ¿Por qué fracasan las empresas? Reatrincheramiento, reflatamiento y recuperación en entornos depresivos. *Cuadernos Latinoamericanos de Administración (Colombia)*, 2 (2), 53-68. <https://www.redalyc.org/pdf/4096/409634344004.pdf>
- Gamarra, A. (2020). *Desarrollo de un modelo para la predicción del precio del cobre empleando herramientas de Machine Learning*. [Tesis de pregrado, Pontificia Universidad Católica del Perú]. Repositorio institucional PUCP.
<https://tesis.pucp.edu.pe/repositorio/handle/20.500.12404/17730>

- Guirguis, D. (2024). *Machine learning-Enabled Multi-scale Process Monitoring and Development for Metal Additive Manufacturing*. [Tesis de pregrado, Carnegie Mellon University]. Repositorio Institucional CMU. <https://doi.org/10.1184/R1/25029503.v1>
- Heizer, J., Render, B., y Munson, C. (2020). *Operations Management: Sustainability and Supply Chain Management* (12th ed.). Pearson.
- Kajander, E. (2020). *Predicting product cost development throughout production life cycle*. [Tesis de postgrado, Lappeenranta-Lahti University of Technology]. Repositorio institucional LUT. https://lutpub.lut.fi/bitstream/handle/10024/159217/Thesis_Kajander.pdf;jsessionid=0A1CD8813737E69CCAD6355C4B0625FA?sequence=1
- Krajewski, L., Malhotra, M., y Ritzman, L. (2018). *Operations Management: Processes and Supply Chains* (12th ed.). Pearson.
- Lee, J., Bagheri, B., y Kao, H.-A. (2015). A cyber-physical systems architecture for industry 4.0-based manufacturing systems. *Manufacturing Letters (Estados Unidos)*, 3(3), 18-23. https://www.researchgate.net/publication/269709304_A_Cyber-Physical_Systems_architecture_for_Industry_40-based_manufacturing_systems
- Mula, J., Poler, R., Garcia-Sabater, J., y Lario, F. (2006). *Models and Methods in Multiple Criteria Decision Making for Production Planning and Scheduling*. Springer
- Oficina General de Evaluación de Impacto y Estudios Económicos (OGEIEE). (31 abril del 2024). *Análisis Sectorial: Desempeño e importancia de la Industria de Metalmecánica*. https://www.producesempresarial.pe/wp-content/uploads/2024/04/8-PPT-METALMECANICA-2017_2024_30042024-.pdf
- Quiñonez, J. (2020). *Diseño de un sistema de planificación de producción basado en la teoría de pronósticos de ventas para reducir costos de producción en MYPE Favyssem* [Tesis de licenciatura, Universidad Privada del Norte]. Repositorio institucional UPN.

<https://repositorio.upn.edu.pe/handle/11537/24012>

Quispe, M. (2019). *Forecast of demand for pre-orders and orders of campaign for costume jewelry in DML* [Tesis de licenciatura, Universidad de Ingeniería y Tecnología].

Repositorio

institucional

UTEC.

<https://repositorio.utec.edu.pe/handle/20.500.12815/1257>

Rodríguez, J. y Prada, J. (2017). *Análisis y propuesta de implementación de un sistema de planificación de producción y gestión de inventarios y almacenes aplicado a una empresa de fabricación de perfiles de plásticos de PVC*. [Tesis de licenciatura, Pontificia Universidad Católica del Perú (PUCP)]. Repositorio institucional (PUCP).

<http://hdl.handle.net/20.500.12404/7951>

Ruiz, C. (2019). *Relación entre los pronósticos de la demanda y la gestión de inventarios en la empresa Cuponium SAC* [Tesis de licenciatura, Universidad Ricardo Palma].

Repositorio

Institucional

URP.

<https://repositorio.urp.edu.pe/entities/publication/149d0677-d17b-4e70-a8cb-ad2a161ec680>

Slack, N., Brandon-Jones, A., y Johnston, R. (2016). *Operations Management* (8th ed.). Pearson.

Sungbum, J. (2020). *Investigation scheduling and control with machine learning in manufacturingsystems*. [Tesis de PH D., Purdue University]. Repositorio Institucional

Purdue University. <https://docs.lib.purdue.edu/dissertations/AAI30503597/>

Triadó, J. (2018). *Planificación de la producción y plan maestro de producción*. Universidad Politécnica de Cataluña (UOC).

<https://openaccess.uoc.edu/server/api/core/bitstreams/c6b06416-ef50-4eda-93fc-9b9f9ef5e387/content>

Velásquez, M. (2003). *Administración de los sistemas de producción*. Editorial Limusa.

Vollmann, T. E., Berry, W. L., Whybark, D. C., y Jacobs, F. R. (2017). *Manufacturing Planning and Control for Supply Chain Management*. McGraw-Hill Education.

Zeeshan, R. (2024). *Demand Drivers' Analysis and Forecasting for Production Planning*. [Tesis de maestría, Iowa State University]. Repositorio institucional LUT University. https://lutpub.lut.fi/bitstream/handle/10024/167926/masterthesis_Zeeshan_Rafay.pdf?sequence=3

Zhang, M. (2022), *Demand forecasting and decision making under uncertainty for long-term production planning in aviation industry*. [Tesis de maestría, Iowa State University]. Repositorio institucional Iowa State University. <https://www.imse.iastate.edu/files/2014/03/ZhangMinxiang-thesis.pdf>

Zhi-Hua, Z. (2021). *Machine Learning*. Springer.

Zugarramurdi, M. (1998). Ingeniería de la producción. En N. Zugarramurdi (Ed.), *Ingeniería económica aplicada a la industria pesquera* (pp. 38–42).

IX. ANEXOS

Anexo A: Matriz operacional de variables

Variable	Definición conceptual	Definición operacional	Dimensiones	Indicadores
Machine Learning	Es la parte de la inteligencia artificial que construye a través del aprendizaje con algoritmos y modelos estadísticos (Ramon, 2014).	Variable medida en torno a la precisión de los datos obtenidos.	Tipo de aprendizaje	Tasa de éxito
			Algoritmo	precisión 80/20 y 70/30
			Manejo de Datos	datos incluidos sobre el total de datos
Pronóstico de la demanda	Es a base para las decisiones de planificación y control de la cadena de suministro, ya que permite alinear la oferta con la demanda esperada (Chopra y Meindl, 2020)	Variable medida en torno en el mínimo porcentaje de error de la proyección.	Temporalidad	frecuencia de los pronósticos
			Método	Método cuantitativo
			Precisión	Porcentaje de error absoluto medio (MAPE)
Costos de Producción	Son todos los costos que un ente económico emplea para la fabricación o la prestación de un servicio estos incluyen todos los costos indirectos y directos. (Gnosis, 2010)	Variable medida en torno a los costos directos e indirectos de fabricación.	Costos Directos	Control de los costos Directos.
			Costos Indirectos	Control de los costos Indirectos
			Costos globales de fabricación	Variación de Sobrecostos y %SCRAP

Anexo B: Matriz de consistencia

APLICACIÓN DE MACHINE LEARNING EN EL PRONÓSTICO DE LA DEMANDA PARA REDUCIR COSTOS DE PRODUCCIÓN EN UNA EMPRESA METALMECÁNICA

Título: Aplicación de machine learning en el pronóstico de la demanda para reducir costos de producción en una empresa metalmecánica						
Problema General	Objetivo General	Hipótesis General	Variables	Dimensiones	Sujetos de estudio	Recolección de información
¿La aplicación de Machine Learning en el pronóstico de la demanda podrá reducir los costos de producción en una empresa metalmecánica?	Determinar si la aplicación de Machine Learning en el pronóstico de la demanda reducirá los costos de producción de una empresa metalmecánica.	Es factible la aplicación de Machine Learning en el pronóstico de la demanda para reducir los costos de producción en una empresa metalmecánica.	Machine Learning	Tipo de aprendizaje	Información sobre la demanda de productos, costos de producción, plazos de fabricación y márgenes de ganancia, métodos actuales utilizados para la gestión de la demanda, optimización de recursos y cumplimiento de plazos.	Tipo de investigación: Aplicada Nivel de investigación: Explicativo Método: Cuantitativo Diseño: Cuasi-experimental Técnica: Base de datos – Análisis Documental Instrumento: Software de análisis y modelado. Población/Muestra: 0 Estadística: Ninguno
Problema Específico	Objetivos Específicos	Hipótesis Específicas		Algoritmo		
¿La aplicación de Machine Learning en el pronóstico de la demanda podrá optimizar el uso de los recursos productivos de una empresa metalmecánica?	Determinar si la aplicación de Machine Learning en el pronóstico de la demanda de una empresa metalmecánica optimizará el uso los recursos productivos de una	Es factible la aplicación de Machine Learning en el pronóstico de la demanda para optimizar los recursos productivos de una empresa metalmecánica		cesamiento de Datos		

	empresa metalmecánica.					Análisis Estadístico: Ninguno
¿La aplicación de Machine Learning en el pronóstico de la demanda podrá mejorar la productividad de una empresa metalmecánica?	Determinar si la aplicación de Machine Learning en el pronóstico de la demanda mejorará la productividad de una empresa metalmecánica.	Es factible la aplicación de Machine Learning en el pronóstico de la demanda para mejorar la productividad de una empresa metalmecánica.	Pronóstico de la demanda	Temporalidad		
				Método		
¿La aplicación de Machine Learning en el pronóstico de la demanda podrá garantizar el cumplimiento de los plazos de fabricación de una empresa metalmecánica?	Determinar si la aplicación de Machine Learning en el pronóstico de la demanda garantizará la entrega a tiempo de los pedidos de una empresa metalmecánica.	Es factible la aplicación de Machine Learning en el pronóstico de la demanda para garantizar la entrega a tiempo de los pedidos de una empresa metalmecánica.		Precisión		
¿La aplicación de Machine Learning en el pronóstico de la	Determinar si la aplicación de Machine Learning en	Es factible la aplicación de Machine Learning en	Costos de Producción	Costos Directos		

demanda podrá mejorar la competitividad de los precios de una empresa metalmecánica?	el pronóstico de la demanda mejorará la competitividad de los precios de una empresa metalmecánica.	el pronóstico de la demanda para mejorar la competitividad de los precios de una empresa metalmecánica.		Costos Indirectos		
¿La aplicación de Machine Learning en el pronóstico de la demanda mejorará los márgenes de ganancia de una empresa metalmecánica?	Determinar si la aplicación de Machine Learning en el pronóstico de la demanda mejorará los márgenes de ganancia de una empresa metalmecánica.	Es factible la aplicación de Machine Learning en el pronóstico de la demanda para mejorar los márgenes de ganancia de una empresa metalmecánica.		Costos de Producción		