

## **Aplicación de analítica de datos para la mejora del cumplimiento de entregas en la planeación de producción por proyecto en una Pequeña y Mediana Empresa (PyME) metalmecánica dedicada a la fabricación de silos industriales**

**Application of data analytics to improve on-time delivery in project-based production planning in a Small and Medium-Sized Enterprise (SME) in the metal-mechanical industry dedicated to the manufacturing of industrial silos**

**Aplicação de análise de dados para a melhoria do cumprimento de entregas no planejamento da produção por projeto em uma Pequena e Média Empresa (PME) metal-mecânica dedicada à fabricação de silos industriais**

Recibido: 10/04/2026 | Aceptado: 20/04/2026 | Publicado: 21/04/2026

**Andrik Erick Castillo Leyva**

ORCID: <https://orcid.org/0000-0002-6416-8481>

Escuela Superior de Ciudad Sahagún, Universidad Autónoma del Estado de Hidalgo, México

E-mail: [ca434649@uaeh.edu.mx](mailto:ca434649@uaeh.edu.mx)

**Francisca Santana Robles**

ORCID: <https://orcid.org/0000-0002-3301-9790>

Escuela Superior de Ciudad Sahagún, Universidad Autónoma del Estado de Hidalgo, México

E-mail: [profe\\_7739@uaeh.edu.mx](mailto:profe_7739@uaeh.edu.mx)

### **Resumen**

La transformación digital se ha convertido en un factor clave para mejorar la competitividad de las pequeñas y medianas empresas (PyMEs) del sector metalmeccánico. En este estudio se presenta la aplicación de un modelo de analítica de datos orientado a la planeación de producción por proyecto en una PyME dedicada a la fabricación de silos industriales y componentes complementarios. El objetivo principal fue mejorar el porcentaje de cumplimiento de entregas (On-Time Delivery, OTD) mediante el uso de herramientas digitales accesibles. La metodología empleada se basó en el análisis de datos operativos simulados correspondientes a un periodo de seis meses, los cuales incluyeron variables relacionadas con volumen de producción, carga de trabajo, retrabajos, logística y disponibilidad de transporte. El modelo predictivo fue implementado en Google Colab utilizando técnicas de regresión para estimar el desempeño mensual del sistema productivo. Los resultados obtenidos muestran que el modelo de regresión lineal múltiple presentó un coeficiente de determinación  $R^2 = 0.862$ , lo que indica una alta capacidad explicativa del comportamiento del indicador On-Time Delivery (OTD). El análisis histórico evidenció un cumplimiento promedio de 69.36%, mientras que, bajo un escenario de optimización operativa caracterizado por reducción de retrabajos, disminución de días en producto terminado y mejora en la disponibilidad de transporte, el modelo proyectó un incremento hasta 81.92%, representando una mejora de 12.56 puntos porcentuales. Estos resultados evidencian el potencial de la analítica de datos como herramienta de apoyo para la planeación productiva en PyMEs metalmeccánicas.

**Palabras clave:** Digitalización; Big Data; Planeación de producción; PyMEs metalmeccánicas; Cumplimiento de entregas; Ingeniería Industrial.

### **Abstract**

Digital transformation has become a key factor in improving the competitiveness of small and medium-sized enterprises (SMEs) in the metal-mechanical sector. This study presents the application of a data analytics model focused on project-based production planning in an SME dedicated to the manufacturing of industrial silos and complementary components. The main objective was to improve the On-Time Delivery (OTD) rate through the use of accessible digital tools. The methodology was based on the analysis of simulated operational data corresponding to a six-month period, including variables related to production volume, workload, rework, logistics, and transportation availability. The predictive model was implemented in Google Colab using regression techniques to estimate the monthly performance of the production system. The results show that the multiple linear regression model achieved a coefficient of determination  $R^2 = 0.862$ , indicating strong explanatory capacity for the On-Time Delivery (OTD)

indicator. The historical analysis showed an average compliance rate of 69.36%, while under an operational optimization scenario characterized by reduced rework, decreased finished goods accumulation, and improved transportation availability the projected OTD increased to 81.92%, representing an improvement of 12.56 percentage points. These findings highlight the potential of data analytics as a decision-support tool for production planning in metal-mechanical SMEs.

**Keywords:** Digitalization; Big Data; Production planning; Metal-mechanical SMEs; On-time delivery; Industrial Engineering.

### Resumo

A transformação digital tornou-se um fator estratégico para melhorar a competitividade das pequenas e médias empresas (PMÉs) do setor metal-mecânico. O presente estudo tem como objetivo melhorar o indicador de cumprimento de entregas (On-Time Delivery, OTD) por meio da aplicação de um modelo de análise de dados na planeação da produção por projeto. A metodologia baseou-se na análise de dados operacionais (anonimizados e estruturados) correspondentes a um período de seis meses, incluindo variáveis como volume de produção, retrabalhos, carga de trabalho, logística e disponibilidade de transporte. O modelo preditivo foi desenvolvido por regressão linear múltipla em ambiente Google Colab (Python/Scikit-learn). Os resultados indicam coeficiente de determinação  $R^2 = 0.862$ , evidenciando elevada capacidade explicativa. O OTD médio histórico foi de 69.36%, enquanto em um cenário otimizado projetou-se 81.92% (melhoria de 12.56 p.p.). Conclui-se que a análise de dados é eficaz para apoiar decisões e melhorar o desempenho operacional em PMÉs industriais.

**Palavras-chave:** Digitalização; Big Data; Planejamento da produção; PME metal-mecânica; On-Time Delivery; Engenharia Industrial.

## 1. Introducción

### 1.1 Planteamiento del problema

En los últimos años, la transformación digital ha adquirido un papel estratégico en el desarrollo y competitividad de las pequeñas y medianas empresas (PyMÉs), particularmente en sectores industriales caracterizados por alta variabilidad operativa y producción bajo pedido, como el sector metalmecánico. La integración de herramientas de analítica de datos y tecnologías digitales permite optimizar procesos productivos, mejorar la toma de decisiones y fortalecer el control del desempeño operativo.

En el contexto de la producción por proyecto, común en la fabricación de silos industriales y estructuras asociadas, las empresas enfrentan retos relacionados con la planeación de la producción, la coordinación logística y el cumplimiento de fechas de entrega. Estos problemas suelen derivarse de métodos tradicionales de programación, limitaciones en el uso de datos históricos y una baja digitalización de los procesos operativos, lo cual impacta directamente en indicadores clave de desempeño como el cumplimiento de entregas (On-Time Delivery, OTD).

Diversos estudios han demostrado que la aplicación de modelos de analítica de datos en entornos industriales contribuye a reducir la variabilidad del sistema productivo, mejorar la eficiencia operativa y fortalecer la competitividad organizacional (Waller & Fawcett, 2013; Choi et al., 2018; Ivanov et al., 2019; Gunasekaran et al., 2017; Zhong et al., 2016). La incorporación de modelos predictivos y técnicas de minería de datos permite anticipar desviaciones en procesos productivos, optimizar la asignación de recursos y mejorar la toma de decisiones basada en evidencia cuantitativa. Sin embargo, gran parte de estas aplicaciones se concentran en grandes empresas con altos niveles de automatización y digitalización avanzada, mientras que, en la empresa metalmecánica analizada, que opera bajo un esquema de producción por proyecto, se presentan dificultades significativas asociadas a limitaciones tecnológicas y estructurales.

Ante este escenario, surge la necesidad de evaluar alternativas accesibles que permitan a las PyMÉs implementar soluciones digitales orientadas a la mejora de su desempeño operativo. En este sentido, el presente estudio propone la aplicación de un modelo de analítica de datos enfocado en la planeación de producción por proyecto, utilizando herramientas de libre acceso como Google Colab, con el objetivo de mejorar el cumplimiento de entregas en una empresa metalmecánica dedicada a la fabricación de silos industriales y componentes complementarios.

Desde la perspectiva de la Ingeniería Industrial, este trabajo integra conceptos de planeación de la producción, gestión de operaciones, análisis de datos y mejora continua, aportando evidencia práctica sobre el uso de herramientas digitales en entornos productivos de pequeña y mediana escala.

## **1.2 Descripción del Problema**

Las PyMEs del sector metalmeccánico que operan bajo esquemas de producción por proyecto enfrentan dificultades significativas en la planeación de la producción y en el cumplimiento de fechas de entrega, debido a la alta variabilidad en los procesos productivos, la personalización de los pedidos y las limitaciones en la coordinación logística. En el caso de la fabricación de silos industriales y componentes complementarios, estas problemáticas se intensifican debido a la complejidad de los procesos involucrados, tales como doblado, soldadura, ensamble y pintura, así como a la dependencia de factores externos como la disponibilidad de transporte.

En la empresa analizada, se ha identificado que los retrasos en las entregas se asocian principalmente a una planeación basada en métodos tradicionales, la falta de integración de datos históricos para la toma de decisiones, retrabajos finales en procesos de acabado y acumulación temporal de producto terminado. Estas condiciones generan incumplimientos en los compromisos con los clientes, afectando la eficiencia operativa y la competitividad de la organización.

A pesar de que existen herramientas digitales y modelos de analítica de datos capaces de apoyar la planeación productiva, su adopción en PyMEs metalmeccánicas sigue siendo limitada debido a restricciones tecnológicas y de conocimiento técnico. Por lo tanto, surge la necesidad de evaluar la viabilidad de implementar soluciones accesibles que permitan mejorar el desempeño operativo sin requerir inversiones elevadas.

Ante este contexto, el problema central de esta investigación se enfoca en determinar cómo la aplicación de un modelo de analítica de datos puede contribuir a mejorar el cumplimiento de entregas en la planeación de producción por proyecto en una PyME metalmeccánica dedicada a la fabricación de silos industriales. En este sentido, el estudio tiene como objetivo mejorar el porcentaje de cumplimiento de entregas (On-Time Delivery, OTD) mediante el uso de herramientas digitales accesibles aplicadas a la planeación de la producción.

## **1.3 Fundamentos teóricos de la analítica de datos y la planeación de producción**

La digitalización industrial se ha consolidado como un elemento estratégico para mejorar la eficiencia operativa y la competitividad de las empresas manufactureras (Kagermann et al., 2013). En PyMEs metalmeccánicas, el uso de herramientas digitales accesibles permite mejorar el control de procesos productivos sin requerir inversiones elevadas en infraestructura tecnológica (OECD, 2019).

## **1.4 Big Data y analítica de datos en entornos industriales**

El Big Data permite analizar grandes volúmenes de información para generar valor organizacional (Mayer-Schönberger & Cukier, 2013). En operaciones industriales, la analítica predictiva facilita la anticipación de problemas productivos y logísticos, así como la optimización de la asignación de recursos (Waller & Fawcett, 2013).

## **1.5 Planeación de producción por proyecto**

La producción por proyecto requiere una planeación flexible debido a la variabilidad en tiempos de proceso y requerimientos del cliente (Slack et al., 2016). En la fabricación de silos industriales, esta variabilidad impacta directamente en los tiempos de entrega y en la coordinación entre áreas productivas.

### 1.6 Indicadores de desempeño industrial

El indicador On-Time Delivery (OTD) mide el porcentaje de órdenes entregadas dentro del plazo comprometido y es ampliamente utilizado para evaluar el desempeño logístico-operativo en sistemas productivos (APICS, 2018).

### 1.7 Relación teoría–caso de estudio

La integración de digitalización, analítica de datos y planeación productiva constituye la base teórica del modelo aplicado en el presente estudio para mejorar el cumplimiento de entregas en una PyME metalmecánica.

## 2. Metodología

El estudio se desarrolló bajo un enfoque cuantitativo aplicado, orientado al análisis de datos operativos y al desarrollo de un modelo predictivo para apoyar la planeación de producción (Risemberg et al., 2026; Pereira et al., 2018).

**Tabla 1** - Etapas metodológicas del estudio.

<b>Etapas</b>	<b>Actividad principal</b>	<b>Resultado esperado</b>
Recolección de datos	Generación de base simulada realista	Base estructurada
Digitalización	Limpieza y organización en Google Colab	Datos procesables
Modelado	Entrenamiento regresión	Modelo predictivo
Evaluación	Comparación OTD	Medición impacto

Fuente: Elaboración propia.

### 2.1 Indicador de desempeño operativo

El indicador utilizado fue el On-Time Delivery (OTD), calculado mediante la siguiente expresión:

$$\text{OTD (\%)} = (\text{Proyectos entregados a tiempo} / \text{Proyectos programados}) \times 100$$

### 2.2 Evidencia de las etapas metodológicas

#### *Etapa 1 Recolección de datos:*

Se utilizaron registros reales correspondientes a la operación de la empresa durante el periodo analizado. La información fue anonimizada y estructurada con fines académicos, preservando la confidencialidad organizacional. Con el objetivo de garantizar la trazabilidad de la información utilizada en el estudio, en el apartado de resultados se presenta un extracto de la base de datos empleada para el modelado. Esta base contiene variables operativas relevantes del proceso productivo y logístico. Asimismo, se incluye un resumen estadístico que permite identificar la distribución de los datos y validar su consistencia para el análisis. Estas evidencias permiten validar la consistencia de los datos y comprobar la aplicación del proceso de analítica dentro del entorno de Google Colab.

#### *Etapa 2 Digitalización y preparación:*

Los datos fueron procesados en Google Colab mediante la biblioteca Pandas. Se realizó limpieza, estructuración de variables y validación de consistencia estadística. Se utilizó una semilla aleatoria controlada para garantizar reproducibilidad del modelo.

### **Etapa 3 Modelado predictivo:**

Se aplicó regresión lineal múltiple utilizando la biblioteca Scikit-learn en Python. El conjunto de datos fue dividido en 80% para entrenamiento y 20% para validación.

### **Etapa 4 Evaluación del desempeño:**

Se evaluó la capacidad predictiva mediante el coeficiente de determinación ( $R^2$ ), error absoluto medio (MAE) y análisis gráfico de dispersión entre valores reales y predichos.

**Tabla 2** - Variables operativas del modelo predictivo.

<b>Variable</b>	<b>Tipo</b>	<b>Descripción</b>
Silos fabricados	Independiente	Número de silos producidos por mes
Accesorios fabricados	Independiente	Cantidad de componentes complementarios
Horas de producción	Independiente	Horas totales utilizadas en producción
Retrabajos	Independiente	Número de reprocesos finales
Días en producto terminado	Independiente	Permanencia promedio en almacén
Disponibilidad de transporte	Independiente	Porcentaje mensual de disponibilidad logística
OTD (%)	Dependiente	Indicador de cumplimiento de entregas

Fuente: Elaboración propia.

## **2.3 Base de datos**

Para el desarrollo del modelo predictivo se utilizaron datos reales anonimizados correspondientes al periodo de enero a junio. Con fines académicos y de confidencialidad, los datos fueron estructurados y adaptados para su procesamiento estadístico, manteniendo coherencia operativa y consistencia industrial. Los datos se basaron en la capacidad productiva promedio de la empresa, el volumen mensual de silos fabricados, la cantidad de componentes complementarios producidos, las horas de producción, los retrabajos finales, el tiempo de permanencia en producto terminado y la disponibilidad de transporte para embarques.

La generación de datos simulados permitió representar escenarios reales de operación sin comprometer información confidencial de la empresa, manteniendo coherencia industrial y consistencia estadística para el análisis.

## **2.4 Modelo predictivo**

El modelo predictivo fue desarrollado mediante regresión lineal múltiple, considerando como variable dependiente el indicador On-Time Delivery (OTD). Las variables independientes incluyeron: silos fabricados, accesorios fabricados, horas de producción, retrabajos, días en producto terminado y disponibilidad de transporte.

La estructura general del modelo se representa mediante la siguiente expresión:

$$\text{OTD} = \beta_0 + \beta_1(\text{Silos fabricados}) + \beta_2(\text{Accesorios fabricados}) + \beta_3(\text{Horas de producción}) - \beta_4(\text{Retrabajos}) - \beta_5(\text{Días en producto terminado}) + \beta_6(\text{Disponibilidad de transporte})$$

$$\text{OTD} = 74.363 - 0.729 (\text{Silos fabricados}) - 0.020 (\text{Accesorios fabricados}) + 0.002 (\text{Horas producción}) - 2.292 (\text{Retrabajos}) - 1.263 (\text{Días producto terminado}) + 0.203 (\text{Disponibilidad transporte})$$

El modelo obtuvo un coeficiente de determinación  $R^2 = 0.862$ , lo que indica que el 86.2% de la variabilidad del OTD es explicada por las variables operativas consideradas. Este resultado confirma la adecuada capacidad predictiva del modelo dentro del contexto analizado.

## 2.5 Caso de estudio

### *Aplicación del modelo en producción por proyecto.*

La empresa analizada es una PyME metalmecánica dedicada a la fabricación de silos industriales y componentes complementarios. Opera bajo producción por proyecto, con una capacidad promedio de seis silos mensuales.

Los principales problemas detectados fueron retrasos por mala coordinación logística, retrabajos en pintura y limpieza de acero inoxidable, acumulación de producto terminado y variabilidad en el transporte.

**Tabla 3** - Características operativas de la empresa analizada.

Característica	Descripción
Tipo de producción	Producción por proyecto
Producto principal	Silos industriales
Productos complementarios	Escaleras, estructuras, plataformas, accesorios
Procesos principales	Doblado, soldadura, ensamble, pintura
Capacidad promedio	6 silos mensuales
Periodo analizado	Enero-Junio

Fuente: Elaboración propia.

**Tabla 4** - Beneficios esperados del modelo propuesto. Los beneficios se presentan como resultados potenciales derivados de la aplicación del modelo.

Aspecto	Beneficio
Eficiencia operativa	Al utilizar Análisis de Datos con Machine Learning en monitoreo en tiempo real de la cadena de suministro optimizará los procesos logísticos reduciendo tiempo muerto y desperdicios
Optimización de inventario	El uso de modelos predictivos permite mantener un equilibrio adecuado entre la producción y las necesidades del mercado, previniendo acumulaciones o faltantes de productos y favoreciendo una mejor gestión de la cadena de suministro
Decisiones basadas en el análisis de datos	El uso de Big Data permite al liderazgo la posibilidad de fundamentar sus decisiones en datos actualizados y confiables, lo que fortalece la toma de decisiones y hace más efectiva la planificación estratégica en su cadena de suministro
Reducción de Costos	Mediante la mejora y automatización de sus procesos, las PyMEs metalmecánicas tienen la oportunidad de disminuir y optimizar considerablemente los gastos
Mayor visibilidad en la cadena de suministro	Al conectar e integrar la información entre proveedores y distribuidores, las PyMEs lograrán una cadena de suministro más clara y controlada, donde es posible coordinar de manera más eficiente cada etapa.
Competitividad y sostenibilidad	Un uso más responsable y eficiente de los recursos no solo apoya las metas de sostenibilidad, sino que también fortalece la posición competitiva de las empresas.

Fuente: Elaboración propia.

### 3. Resultados

El análisis histórico de los datos mostró un cumplimiento promedio del indicador OTD de 69.36%. Se identificó que los principales factores asociados a los retrasos fueron el número de retrabajos finales y la acumulación de producto terminado previo al embarque.

Tras la aplicación del modelo de regresión lineal múltiple y la simulación de un escenario de optimización operativa, caracterizado por una reducción significativa de retrabajos, disminución en los días de permanencia en producto terminado y mejora en la disponibilidad de transporte, el OTD proyectado alcanzó un promedio de 81.92%.

La mejora obtenida representa un incremento de 12.56 puntos porcentuales en el cumplimiento de entregas. La comparación entre valores reales y predichos mostró una alta correlación, consistente con el valor  $R^2 = 0.862$ , lo cual valida la pertinencia del modelo como herramienta de apoyo para la toma de decisiones en la planeación productiva.

Figura 1 - Implementación del modelo en Google Colab mediante Python.

```
# 2. MODELO DE REGRESIÓN
# =====

X = data.drop('OTD', axis=1)
y = data['OTD']

X_train, X_test, y_train, y_test = train_test_split(
    X, y, test_size=0.2, random_state=25
)

modelo = LinearRegression()
modelo.fit(X_train, y_train)

y_pred = modelo.predict(X_test)

# =====
```

Fuente: Elaboración propia.

Figura 2 - Extracto de la base de datos utilizada para el modelado.

Silos_fabricados	Accesorios_fabricados	Horas_produccion	Retrabajos	Dias_producto_terminado	Disponibilidad_transporte	OTD
0	5	25	1089	4	6	81.522004 70.169975
1	7	29	1115	3	6	76.098523 69.934405
2	7	42	1133	3	9	79.493581 67.937397
3	6	36	967	5	8	82.368194 66.940735
4	7	31	1164	5	7	85.163611 65.322342

===== RESUMEN ESTADÍSTICO =====							
	Silos_fabricados	Accesorios_fabricados	Horas_produccion	Retrabajos	Dias_producto_terminado	Disponibilidad_transporte	OTD
count	48.000000	48.000000	48.000000	48.000000	48.000000	48.000000	48.000000
mean	5.895833	33.083333	1092.250000	4.437500	7.229167	82.734011	69.359030
std	0.831292	6.655132	89.219905	1.109078	1.574255	3.903911	4.109159
min	5.000000	20.000000	958.000000	3.000000	5.000000	76.098523	60.000000
25%	5.000000	28.500000	1004.750000	3.000000	6.000000	79.450883	66.186338
50%	6.000000	34.000000	1098.500000	4.500000	7.000000	82.546166	69.767316
75%	7.000000	39.000000	1171.500000	5.000000	8.000000	85.607868	71.760698
max	7.000000	44.000000	1239.000000	6.000000	10.000000	89.374790	78.022139

Promedio OTD histórico: 69.36

===== MÉTRICAS DEL MODELO =====

$R^2$ : 0.862  
MAE: 1.684  
RMSE: 1.849

Fuente: Elaboración propia.

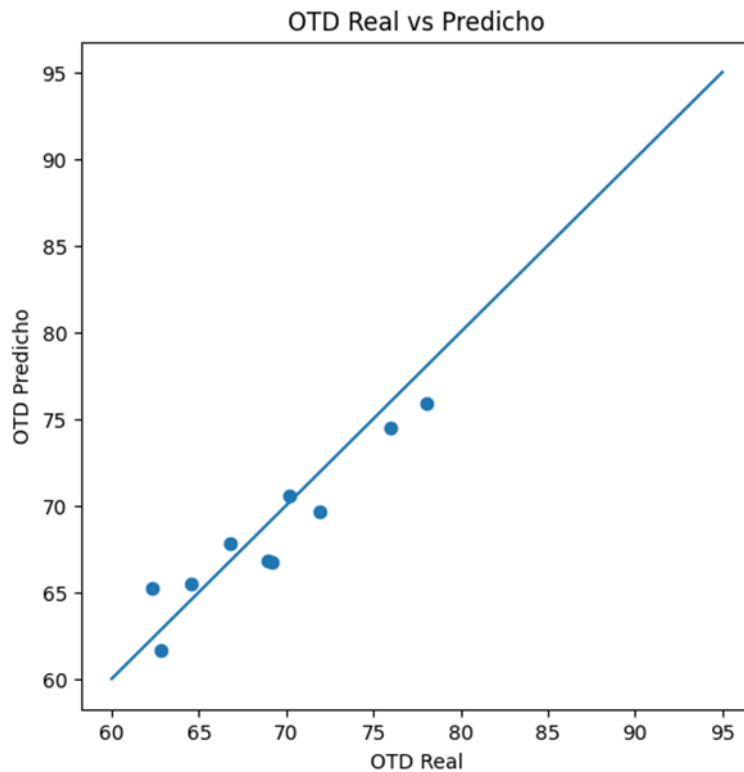
**Figura 3** - Coeficientes del modelo de regresión lineal múltiple obtenidos en Python.

```
===== COEFICIENTES DEL MODELO =====
```

	Variable	Coefficiente
0	Intercepto	74.362537
1	Silos_fabricados	-0.729359
2	Accesorios_fabricados	-0.019842
3	Horas_produccion	0.002121
4	Retrabajos	-2.291605
5	Dias_producto_terminado	-1.263324
6	Disponibilidad_transporte	0.203105

Fuente: Elaboración propia.

**Figura 4** - Gráfica Real vs Predicho.



Fuente: Elaboración propia.

En la Figura 4 se presenta la comparación entre los valores reales y los valores predichos del indicador OTD. Se observa una adecuada alineación respecto a la línea de identidad, lo cual indica un buen nivel de ajuste del modelo. El modelo obtuvo un coeficiente de determinación  $R^2 = [0.862]$ , lo que indica que explica un alto porcentaje de la variabilidad del indicador.

**Tabla 5** - Revisión y selección de artículos de digitalización y el uso de BIG DATA en la cadena de suministro.

Título del Artículo	Autor (es)	Fecha de Publicación	Resumen de contenido
Big Data y Análítica Predictiva en la Toma de Decisiones Empresariales.	Cevallos Guamán, E. J., Jacho Gallo, A. K., & Córdova Vaca, A. M. (2024). Revista Ingenio Global,	2024	Implementación del Big Data y Análítica Predictiva en “Or Importaciones”, una empresa minorista en Ecuador que enfrentaba desafíos en la gestión de inventarios y predicción de sus ventas. Para la solución del problema se utilizó un modelo en Python y Google Colab
Big Data en la cadena de suministro	Vailos	2023	Concepto, importancia, beneficios, casos prácticos, desafíos y herramientas que apoyan en la digitalización y la implementación del Big Data en las empresas.
Influencia de Big Data y economía circular en el desempeño operacional de la cadena de suministro del sector de manufactura Peruano	Olivera Flores, Hugo Martinez Toledo, Ilich Daniel Obispo Oscco, Juan Carlos Pontificia Universidad Católica del Perú	2023	Analiza el vínculo entre Big Data, cadena de suministro de la economía circular y el desempeño operativo de la cadena de suministro del sector manufacturero peruano, variables que afectan positiva y negativamente al Big Data y el análisis de datos de la empresa.
Impacto y Evolución de Big Data en la logística: una revisión exhaustiva de tendencias y prácticas actuales	Cordoves Mustelier, Dicsiel, Frutos, Mariano	2024	Analiza el impacto del Big Data en la Logística y explora sus aplicaciones, beneficios y desafíos. Las aplicaciones más destacadas incluyen la optimización de rutas y entregas, la predicción de la demanda mediante algoritmos de Machine Learning y el mantenimiento predictivo
Desbloqueando valor: cómo la analítica y la big data refuerzan la cadena de suministro	Patricia M. Suárez Alemán	2023	Este artículo examina el valor de la analítica y Big Data, explora el análisis de datos desde la perspectiva del modelo de Referencia de Operaciones de la Cadena de Suministro (SCOR), así como la calidad y visualización de los datos. También destaca su aplicación exitosa de la experiencia del cliente y la transformación sostenible de las cadenas de suministro.

Fuente: Elaboración propia.

#### 4. Discusión

Los resultados obtenidos en el presente estudio evidencian la viabilidad de la digitalización y el uso de analítica de datos como herramienta de apoyo para la planeación de la producción en PyMEs metalmecánicas que operan bajo un esquema de fabricación por proyecto. Esta afirmación se sustenta en la capacidad explicativa del modelo de regresión lineal múltiple, el cual alcanzó un coeficiente de determinación  $R^2 = 0.862$ , indicando que el 86.2% de la variabilidad del indicador On-Time Delivery (OTD) puede explicarse a partir de las variables operativas consideradas. Asimismo, la simulación de un escenario de mejora operativa permitió proyectar un incremento del OTD de 69.36% a 81.92%, representando una mejora cuantificable de 12.56 puntos porcentuales. Estos resultados muestran que el análisis sistemático de datos históricos permite identificar factores críticos y estimar su impacto en el desempeño del sistema productivo.

El análisis mensual del OTD permitió identificar periodos con bajo nivel de cumplimiento, asociados principalmente a factores logísticos y de coordinación en las etapas finales del proceso productivo, más que a fallas directas en los procesos de fabricación. Aspectos como la disponibilidad de transporte, la acumulación de producto terminado y las modificaciones de último momento influyen de manera significativa en los retrasos, tal como se planteó en el problema de investigación, estos factores fueron identificados durante la revisión de órdenes de trabajo y el análisis de la operación real de la empresa.

Estos resultados coinciden con la literatura reciente, la cual señala que en entornos de producción bajo pedido la variabilidad operativa incrementa el riesgo de incumplimientos si no se cuenta con herramientas de apoyo a la toma de decisiones basadas en datos y modelos predictivos accesibles ((Cevallos Guamán et al., 2024; Cordoves Mustelier & Frutos, 2024); Chávez & Rodríguez, 2022). Asimismo, el uso de datos simulados realistas y herramientas accesibles como Google Colab demuestra la viabilidad de implementar modelos de analítica de datos sin requerir inversiones elevadas.

En conjunto, el estudio evidencia que la analítica de datos puede mejorar la visibilidad del desempeño operativo y apoyar una planeación más alineada a la realidad productiva y logística de las PyMEs metalmecánicas.

Con base en los coeficientes obtenidos del modelo de regresión lineal múltiple (Figura 3), se identifica que los retrabajos y los días en producto terminado son las variables con mayor impacto negativo en el OTD, mientras que la disponibilidad de transporte presenta una influencia positiva significativa.

## 5. Conclusión

El modelo desarrollado demostró que es posible explicar el comportamiento del indicador OTD mediante variables operativas clave, alcanzando un  $R^2$  de 0.862. Asimismo, la simulación de mejoras operativas permitió proyectar un incremento de 12.56 puntos porcentuales en el cumplimiento de entregas, evidenciando que la gestión de retrabajos y la optimización logística constituyen áreas estratégicas para la mejora del desempeño en PyMEs metalmecánicas.

A partir de los resultados obtenidos, se concluye que la digitalización de la información operativa y el uso sistemático de datos históricos constituyen herramientas clave para fortalecer la planeación de la producción y la toma de decisiones.

Se concluye que el indicador On-Time Delivery (OTD) resulta adecuado para evaluar el desempeño del sistema productivo, ya que permite identificar de manera clara los periodos con mayor riesgo de retraso y relacionarlos con factores operativos específicos, tales como la carga de trabajo mensual, la cantidad de accesorios por proyecto y los procesos logísticos asociados al embarque y entrega del producto final.

Asimismo, se comprobó que los retrasos en la entrega no obedecen exclusivamente a fallas en los procesos de fabricación, sino que están estrechamente vinculados a la falta de coordinación en las actividades finales de preparación, transporte y modificaciones de último momento. Esto resalta la necesidad de considerar la cadena de suministro de manera integral y no únicamente desde la perspectiva productiva.

Desde el enfoque de Ingeniería Industrial, el modelo propuesto demuestra que es posible implementar soluciones basadas en analítica de datos utilizando herramientas accesibles, como Google Colab y hojas de cálculo, lo cual resulta especialmente relevante para PyMEs que enfrentan restricciones presupuestales y tecnológicas. La metodología desarrollada puede ser replicada o adaptada en empresas con características similares, contribuyendo a la mejora de la productividad y al fortalecimiento de la competitividad organizacional.

Finalmente, se recomienda que trabajos futuros amplíen el modelo incorporando datos reales, así como variables adicionales relacionadas con costos, calidad y satisfacción del cliente, con el fin de enriquecer el análisis y generar modelos predictivos más robustos. De esta manera, la analítica de datos puede consolidarse como una herramienta estratégica para la gestión eficiente de la producción por proyecto en el sector metalmecánico.

## Referencias

APICS. (2018). *Supply chain operations reference model (SCOR)*. APICS.

Benítez Torres, S. G., & Barrezueta Avellán, F. F. (2023). Big Data y analítica predictiva en la toma de decisiones empresariales. *Revista de Investigación y Gestión*, 7(1), 35–46. <https://editorialinnova.com/index.php/rig/article/view/103/314>

- Cevallos Guamán, E. J., Jacho Gallo, A. K., & Córdova Vaca, A. M. (2024). Big data y analítica predictiva en la toma de decisiones empresariales. *Revista Ingenio Global*, 4(1), 45–58.
- Chávez, J. A., & Rodríguez, M. E. (2022). Big Data y su incidencia en la gestión de la cadena de suministro. *Innovare: Revista de Ciencia y Tecnología*, 11(1), 89–101. <https://portalderevistas.uam.edu.ni/index.php/iyA/article/view/158/132>
- Choi, T. M., Wallace, S. W., & Wang, Y. (2018). Big data analytics in operations management. *Production and Operations Management*, 27(10), 1868–1883.
- Cordoves Mustelier, D., & Frutos, M. (2024). Impacto y evolución del big data en la logística: Una revisión exhaustiva de tendencias y prácticas actuales. *Revista Científica de Logística y Transporte*, 6(2), 112–128.
- Gómez, M. A., & Herrera, D. J. (2023). El uso del Big Data en la gestión de la cadena de suministro: Ventajas competitivas y desafíos para las organizaciones. *Innovación y Argumentación*, 4(2), 45–59. <https://portalderevistas.uam.edu.ni/index.php/iyA/article/view/158/132>
- González-Morales, A., & Hernández-Ramírez, C. (2022). Transformación digital en PyMEs manufactureras mexicanas: Desafíos y oportunidades. *Revista de Innovación y Tecnología*, 8(2), 45–59.
- Gunasekaran, A., Papadopoulos, T., Dubey, R., Wamba, S., Childe, S., Hazen, B., & Akter, S. (2017). Big data and predictive analytics for supply chain and organizational performance. *Journal of Business Research*, 70, 308–317.
- Instituto Nacional de Estadística y Geografía (INEGI). (2023). *Censos Económicos 2023*. Gobierno de México.
- Ivanov, D., Dolgui, A., & Sokolov, B. (2019). The impact of digital technology and Industry 4.0 on supply chain resilience. *International Journal of Production Research*, 57(3), 829–846.
- Kagermann, H., Wahlster, W., & Helbig, J. (2013). *Recommendations for implementing the strategic initiative Industrie 4.0*. Acatech.
- Marín, F., & Sciolla, M. (2023). *Big Data como herramienta de mejora de la cadena de suministro*. Universidad Nacional de La Plata. [https://sedici.unlp.edu.ar/bitstream/handle/10915/177360/Documento\\_completo.pdf](https://sedici.unlp.edu.ar/bitstream/handle/10915/177360/Documento_completo.pdf)
- Mayer-Schönberger, V., & Cukier, K. (2013). *Big data: A revolution that will transform how we live, work, and think*. Houghton Mifflin Harcourt.
- OECD. (2019). *OECD SME and entrepreneurship outlook 2019*. OECD Publishing.
- Pereira, A. S., Shitsuka, D. M., Parreira, F. J., & Shitsuka, R. (2018). Metodología da pesquisa científica. Santa Maria: UAB/NTE/UFSM.
- Ramírez-Treviño, J., & Soto-López, D. (2023). Adopción de Big Data y digitalización en el sector metalmeccánico mexicano. *Revista de Ingeniería Industrial Latinoamericana*, 12(1), 112–130.
- Risemberg, R. I. C., Wakin, M., & Shitsuka, R. (2026). A importância da metodologia científica no desenvolvimento de artigos científicos. *E-Acadêmica*, 7(1), e0171675. <https://doi.org/10.52076/eacad-v7i1.675>
- Romero, L. A. (2023). *Big Data y transformación digital en la gestión de la cadena de suministro: Análisis de tendencias y aplicaciones en América Latina* [Trabajo final de grado, Universidad Nacional de La Plata].
- Salazar López, C. A. (2022). *Implementación de analítica de datos y Big Data en la cadena de suministro para la optimización logística en empresas manufactureras peruanas* [Tesis de maestría, Pontificia Universidad Católica del Perú]. Repositorio Institucional PUCP. <https://tesis.pucp.edu.pe/server/api/core/bitstreams/9f855091-750e-422d-be5c-7ba08a0d8481/content>
- Slack, N., Brandon-Jones, A., & Johnston, R. (2016). *Operations management* (8th ed.). Pearson.
- Vailos. (2023). *Big Data en la cadena de suministro*. <https://www.vailos.com/big-data-en-la-cadena-de-suministro/>
- Waller, M. A., & Fawcett, S. E. (2013). Data science, predictive analytics, and big data: A revolution that will transform supply chain design and management. *Journal of Business Logistics*, 34(2), 77–84.
- Zhong, R. Y., Newman, S. T., Huang, G. Q., & Lan, S. (2016). Big data for supply chain management in the service and manufacturing sectors. *Computers & Industrial Engineering*, 101, 572–591.