



Escuela de Administración
Escuela de Ingeniería, Ciencia y Tecnología

Maestría en Business Analytics

Implementación de un Modelo Analítico para la Medición y Seguimiento de la
Productividad En Comercio Exterior: Caso de Estudio en la Empresa A

Presentado por:

Juan Carlos Medina Hernandez y Harol Mauricio Torres Quiroga

Título a obtener: Magíster en Business Analytics

Bogotá, D.C. 26 de enero de 2026



Escuela de Administración

Escuela de Ingeniería, Ciencia y Tecnología

Maestría en Business Analytics

Implementación de un Modelo Analítico para la Medición y Seguimiento de la
Productividad En Comercio Exterior: Caso de Estudio en la Empresa A

Presentado por:

Juan Carlos Medina Hernandez y Harol Mauricio Torres Quiroga

Bajo la dirección de:

Daniel Leonardo Cruz

Bogotá, D.C. 26 de enero de 2026

Tabla de contenido

Declaración de originalidad y autonomía	6
Declaración de exoneración de responsabilidad	7
Lista de figuras.....	8
Lista de tablas	10
Resumen ejecutivo	11
Abstract	13
1. Introducción	14
2. Objetivos	16
2.1. General.....	16
2.2. Específicos.....	16
3. Alcance del proyecto aplicado	17
4. Descripción de las fuentes de información	19
5. Marco Teórico	20
5.1. Gestión Cadena de suministró	20
5.2. KPI's y Score.....	21
5.3. Inteligencia de negocios	23
5.4. Minería de datos	24
5.5. Metodología CRISP-DM.....	24

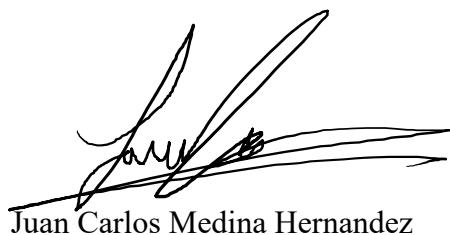
5.6.	Aprendizaje supervisado.....	25
5.7.	Modelos de ensamble	26
5.8.	Random Forest.....	26
5.9.	Modelos Gradient Boosting.....	27
5.10.	XGBoost (Extreme Gradient Boosting)	27
5.11.	LightGBM (Light Gradient Boosting Machine):	27
5.12.	Fundamentación elección del modelo	28
5.13.	Accuracy.....	28
5.14.	Matriz de confusión.....	28
5.15.	Precisión vs. Recall	29
5.16.	Análisis Curva ROC y AUC.....	30
5.17.	Interpretación de Modelos y Analítica Explicable	31
5.18.	Necesidad crítica de la confianza para el negocio	31
5.19.	Analítica Explicable (Explainable AI - XAI	31
5.20.	Métodos de interpretación global: Importancia de variables (Feature Importance). 33	
6.	Metodología CRISP-DM.....	34
6.1	FASE 1 - Comprensión del Negocio	36
6.2	FASE 2 - Comprensión de los Datos.....	38
6.3	FASE 3 - Preparación de los Datos	58
6.4	FASE 4 – Modelado	62

6.5	FASE 5 - Evaluación	67
6.6	FASE 6 – Despliegue	73
7.	Conclusiones	86
8.	Recomendaciones.....	88
9.	Limitaciones.....	91
10.	Referencias bibliográficas	93
11.	Anexos.....	97

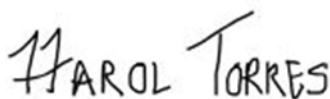
Declaración de originalidad y autonomía

Declaro(amos) bajo la gravedad del juramento, que he(mos) escrito el presente Proyecto Aplicado Empresarial (PAE), en la propuesta de solución a una problemática en el campo de conocimientos del programa de Maestría por mi(nuestra) propia cuenta y que, por lo tanto, su contenido es original.

Declaro(amos) que he(mos) indicado clara y precisamente todas las fuentes directas e indirectas de información y que este PAE no ha sido entregado a ninguna otra institución con fines de calificación o publicación.

A handwritten signature in black ink, appearing to read 'Juan Carlos Medina Hernandez', with a long horizontal stroke extending to the right.

Juan Carlos Medina Hernandez

A handwritten signature in black ink, appearing to read 'HAROL TORRES', with a stylized 'H' and 'T'.

Harol Mauricio Torres Quiroga

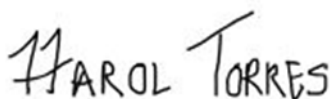
Firmado en Bogotá, D.C. el 01 de diciembre de 2025

Declaración de exoneración de responsabilidad

Declaro(amos) que la responsabilidad intelectual del presente trabajo es exclusivamente de su(s) autor(es). La Universidad del Rosario no se hace responsable de contenidos, opiniones o ideologías expresadas total o parcialmente en él.



Juan Carlos Medina Hernandez



HAROL TORRES

Harol Mauricio Torres Quiroga

Firmado en Bogotá, D.C. el 01 de diciembre de 2025

Lista de figuras

Figura 1 <i>Lego Serious Play</i>	34
Figura 2 <i>Estructura del dataframe de la BASE_IMPORTACIONES.</i>	39
Figura 3 <i>Estructura del dataframe de BASE_COLABORADORES_COMEX</i>	40
Figura 4 <i>Cantidad de OC por responsable Comex</i>	42
Figura 5 <i>Análisis del Lead Time</i>	43
Figura 6 <i>Distribución de grupo de artículos</i>	44
Figura 7 <i>Distribución de ordenes por unidad de negocio</i>	45
Figura 8 <i>Distribución de colaboradores por nivel académico.</i>	46
Figura 9 <i>Distribución años de antigüedad</i>	47
Figura 10 <i>Top 10 rutas origen - destino</i>	48
Figura 11 <i>Distribución carga por responsable Comex</i>	49
Figura 12 <i>Gráfico boxplot de Lead Time por cargo.</i>	50
Figura 13 <i>Distribución lead time por responsable Comex.</i>	52
Figura 14 <i>Distribución años de antigüedad</i>	54
Figura 15 <i>ETL del proceso de preparación de datos</i>	58
Figura 16 <i>Porcentaje de cumplimiento área Comex</i>	61
Figura 17 <i>Hiperparámetro utilizados en el modelo</i>	66
Figura 18 <i>Comparación modelos utilizados.</i>	66
Figura 19 <i>Grafica comparación FI y AUC ROC.</i>	66
Figura 20 <i>Reporte de clasificación.</i>	70
Figura 21 <i>Matriz de confusión.</i>	72

Figura 22 <i>Modelo relacional del tablero en Power BI</i>	75
Figura 23 <i>Vista General Dashboard Comex</i>	76
Figura 24 <i>Pestaña 2 Vista Proceso Dashboard Comex</i>	77
Figura 25 <i>Pestaña 3 Vista People Dashboard Comex</i>	79

Lista de tablas

Tabla 1 <i>Descripción Proceso Crisp DM</i>	35
Tabla 2 <i>Calidad de los datos</i>	57
Tabla 3 <i>Metadatos Base BD Importaciones</i>	97
Tabla 4 <i>Metadatos Base Colaboradores COMEX</i>	100

Resumen ejecutivo

El presente proyecto de grado aborda la optimización de la gestión operativa en el área de Comercio Exterior (COMEX) de una empresa del sector real, identificando la carencia de un sistema objetivo y cuantitativo para medir la productividad de sus colaboradores. El objetivo principal fue desarrollar una solución de Inteligencia de Negocios capaz de calcular un score de productividad individual, fundamentado en la predicción del cumplimiento de los tiempos de entrega (*lead time*) de las órdenes de compra.

Para garantizar el rigor técnico y la alineación con el negocio, se aplicó la metodología estándar CRISP-DM. El estudio procesó un histórico transaccional de 7,661 órdenes de compra, ejecutando fases de limpieza de datos, ingeniería de características y la construcción de una variable objetivo dinámica ajustada por tipo de material. Se implementó y optimizó un modelo de aprendizaje automático supervisado utilizando el algoritmo LightGBM, el cual demostró una capacidad robusta para clasificar las órdenes según su probabilidad de éxito.

Los resultados del análisis revelaron que las variables intrínsecas de la orden (cantidad, valor y días de tránsito) tienen un peso predictivo superior a las características individuales del gestor. Asimismo, el análisis cruzado entre antigüedad y rendimiento desafió paradigmas tradicionales, evidenciando que la experiencia no garantiza menores tiempos de ejecución, sino que a menudo correlaciona con la gestión de casos de mayor complejidad. El entregable final es un modelo funcional y un sistema de puntuación que permite a la gerencia transitar de una evaluación subjetiva a una gestión del talento basada en datos, facilitando la identificación de cuellos de botella y la asignación eficiente de recursos.

Palabras clave: Inteligencia de Negocios, CRISP-DM, Comercio Exterior, LightGBM, Productividad, *Lead Time*, Minería de Datos.

Abstract

This project addresses the optimization of operational management within the Foreign Trade (COMEX) department of a real-sector company, identifying the lack of an objective and quantitative system to measure employee productivity. The main objective was to develop a Business Intelligence solution capable of calculating an individual productivity score, based on predicting the compliance of purchase order *lead times*.

To ensure technical rigor and business alignment, the CRISP-DM methodology was applied. The study processed a transactional history of 7,661 purchase orders, executing data cleaning, feature engineering, and the construction of a dynamic target variable adjusted by material type. A supervised machine learning model was implemented and optimized using the LightGBM algorithm, which demonstrated robust capability in classifying orders according to their probability of success.

The analysis results revealed that intrinsic order variables (quantity, value, and transit days) hold superior predictive weight compared to the manager's individual characteristics. Furthermore, a cross-analysis between seniority and performance challenged traditional paradigms, evidencing that experience does not guarantee shorter execution times but often correlates with managing higher-complexity cases. The final deliverable is a functional model and a scoring system that allows management to transition from subjective evaluation to data-driven talent management, facilitating the identification of bottlenecks and efficient resource allocation.

Keywords: Business Intelligence, CRISP-DM, Foreign Trade, LightGBM, Productivity, *Lead Time*, Data Mining.

1. Introducción

COMEX es fundamental tanto para el desarrollo socioeconómico de un país como de una organización. Esto permite tener un intercambio de bienes y servicios que a su vez generan ingresos y procesos transaccionales que hacen crecer y diversificar un negocio, también impulsa la competitividad, la innovación y demás aspectos económicos. (cmadrid, 2021)

A nivel empresarial nos permite acceder a nuevos mercados y crecer en estos mismos, también se tiene la posibilidad de expandirse a otros mercados internacionales logrando diversificar sus ingresos, esto a su vez implica retos para gestionar una eficiencia de costos de operaciones y conocimiento de las medidas regulatorias para la importación y comercialización de productos, en nuestro caso de materias primas para las industrias del país. (*Comercio exterior*, 2023)

En la actualidad, el área de COMEX atraviesa por varios desafíos. Primero, la complejidad de los procesos aduaneros, los cuales están en constante cambio y suelen ser diferentes en cada país. También, la fluctuación de las tasas de cambio lo que puede afectar la rentabilidad de una operación conllevando en pérdidas para el negocio, lo que obliga a optar por estrategias de gestión de riesgos para amortizar esas posibles pérdidas, otro aspecto de suma importancia es la cadena de suministro que tienen los diferentes países o proveedores con los que se hacen negociaciones, ya que se han visto afectados por tiempos de entrega más largos y sobrecostos logísticos, lo que implica en un impacto sobre el valor de los productos que se desean comercializar. (Rojas, 2023)

Este proyecto nace de la necesidad crítica de optimizar la gestión del área COMEX, transformando su vasto cúmulo de datos transaccionales en una herramienta estratégica. El objetivo principal es, por tanto, diseñar y desarrollar una solución de Inteligencia de

Negocios para calcular un F-Score de productividad individual, basado en un modelo predictivo que determine la probabilidad de que una orden de compra cumpla con su *lead time*. Con esto, se busca superar las evaluaciones cualitativas y dotar a la gerencia de una visión clara y cuantitativa del rendimiento.

Para garantizar la rigurosidad del proceso y la correcta alineación con los objetivos de negocio, el proyecto se ha estructurado siguiendo la metodología estándar de la industria, CRISP-DM (Cross-Industry Standard Process for Data Mining). Mediante la aplicación de sus fases, se ha construido un modelo de aprendizaje automático, específicamente un LightGBM (Light Gradient Boosting Machine). Este modelo es capaz de analizar múltiples variables de una orden de compra para predecir si esta se completará a tiempo, identificando además los factores más influyentes en el resultado.

El entregable final de este trabajo es un sistema de F-Score que traduce las predicciones del modelo en un indicador de productividad mensual por colaborador, ofreciendo una base empírica para la toma de decisiones. La contribución de este proyecto es doble: por un lado, proporciona una herramienta objetiva para la gestión del talento y la asignación de la carga de trabajo; por otro, genera conocimiento accionable al revelar qué factores operativos impactan de manera más significativa en la eficiencia del área.

El presente documento detalla el desarrollo completo del proyecto. El Capítulo 2 describe la metodología CRISP-DM. El Capítulo 3 aborda el proceso de preparación y análisis de los datos. Los Capítulos 4 y 5 presentan la construcción y evaluación del modelo predictivo. Finalmente, el Capítulo 6 expone las conclusiones del estudio y las recomendaciones de negocio derivadas del análisis.

2. Objetivos

2.1. General

Desarrollar un sistema de medición de la productividad para los colaboradores del área de COMEX, basado en un modelo predictivo de aprendizaje automático capaz de estimar la probabilidad de cumplimiento del *lead time* de las órdenes de compra, con el fin de dotar a la gerencia de una herramienta cuantitativa y objetiva para la optimización de procesos y la toma de decisiones.

2.2. Específicos

1. Construir el conjunto de datos analítico a partir de las fuentes transaccionales, realizando los procesos de limpieza, transformación de variables y cálculo del indicador cumplimiento_lead_time_ajustado, el cual servirá como variable objetivo para el modelado.

2. Desarrollar un modelo de clasificación predictiva utilizando un algoritmo como Random Forest, LightGBM, XGBoost, para estimar la probabilidad de que una orden de compra cumpla con el *lead time* establecido, optimizando sus hiperparámetros para maximizar el rendimiento predictivo.

3. Evaluar el desempeño técnico del modelo mediante métricas de clasificación estándar (Exactitud, Precisión, Recall, AUC ROC) e interpretar sus resultados para identificar las variables de negocio más influyentes en el cumplimiento de los plazos de entrega.

4. Diseñar e implementar un sistema de puntuación (*score*) de productividad mensual para cada colaborador del área COMEX, utilizando las probabilidades predichas por el modelo como base para generar un indicador de rendimiento objetivo.

3. Alcance del proyecto aplicado

Este proyecto está enfocado en un análisis a los datos operativos del área de COMEX de una empresa importadora de materias primas para los diferentes sectores industriales. Usaremos un histórico de importaciones por órdenes de compra, con el fin de identificar los factores que determinan el cumplimiento en los tiempos de entrega de los materiales. El análisis incluye la creación de variables objetivo para el negocio como lo es el *Lead Time* en días, los tiempos de nacionalización y la más importante el cumplimiento teniendo en cuenta parámetros estadísticos como la desviación estándar por cada uno de los materiales, lo que es fundamental para el modelo predictivo.

En el apartado técnico se realiza una programación en el lenguaje de Python con las librerías para ciencia de datos (Pandas, Scikit-learn, LightGBM). La metodología como tal no es realizar una clasificación es más desarrollar un modelo de clasificación supervisado. Se implementará y optimizará un algoritmo LightGBM para predecir si una orden de compra con un material en específico cumplirá con los plazos determinados, logrando validar el rendimiento de cada responsable de COMEX de una manera más rigurosa.

Para este proyecto se decide delimitar de la siguiente manera:

- El Proyecto se basa en datos históricos desde febrero de 2024 hasta julio de 2025, estos datos son proporcionados por la compañía y sin la inclusión de fuentes externas.
- Esta solución no tiene un sistema de alerta o monitoreo en tiempo real.
- No se está contemplando una modificación de procesos actuales en la captura de los datos.

- El entregable final es un modelo prototipo el cual no incluye un despliegue a nivel productivo bajo la metodología que implementa la empresa de MLOps, aunque es un proyecto que sienta las bases para el equipo de BI con el fin de escalarlo a un nivel productivo.

Se entregará con este trabajo lo siguiente:

- Documento Técnico y Metodológico: El presente trabajo de grado, que describe en detalle el problema de negocio, la metodología CRISP-DM aplicada, el proceso de preparación de datos y la construcción, evaluación e interpretación del modelo de clasificación predictiva.
- Activos Analíticos (Código Fuente): Los cuadernos de Google Colab con todo el código en Python utilizado para la limpieza de datos, el análisis exploratorio, el entrenamiento del modelo y la generación del score de productividad.
- Sistema de Puntuación de Productividad: Un archivo de salida (ej. archivo Excel) que contiene el score de productividad mensual calculado para cada colaborador del área COMEX, generado a partir de las predicciones del modelo. Este es el principal entregable cuantitativo para la gerencia.
- Recomendaciones de Negocio: Un conjunto de recomendaciones estratégicas y operativas, basadas en los hallazgos del modelo (especialmente en el análisis de importancia de variables), para la optimización de los procesos del área de COMEX.

4. Descripción de las fuentes de información

La empresa A es una empresa multilatina fundada en 1976, con presencia en 10 países DE América Latina. Su misión es contribuir al crecimiento y la sostenibilidad en la cadena de valor de la industria y el campo en Latinoamérica. Ofrecen una amplia gama de productos y servicios, incluyendo el suministro de materias primas, productos químicos, fertilizantes de alta calidad y soluciones innovadoras para diversas industrias.

La operación de la empresa A está fuertemente impulsada por la analítica de datos, utilizando herramientas como Power BI para analizar y tomar decisiones rápidas sobre las operaciones diarias de la compañía.

Los datos que se utilizarán en este proyecto serán proporcionados por la empresa A. No se utilizarán datos externos para realizar el análisis.

5. Marco Teórico

5.1. Gestión Cadena de suministro

La Gestión de la Cadena de Suministro (SCM, por sus siglas en inglés) se define como la integración y coordinación sistémica de los procesos de negocio, flujos de información y flujos de materiales que conectan a las organizaciones, desde los proveedores de materias primas hasta el consumidor final. El objetivo fundamental de la SCM es la entrega de valor al cliente de la manera más eficiente y sostenible posible, optimizando los recursos y minimizando las fricciones entre los distintos eslabones de la cadena. (Christopher, 2011)

El área de COMEX cumple con una tarea fundamental en el proceso de importación y no debe ser vista como un área aislada, si no como un punto crítico y estratégico para el negocio y toda la cadena de suministro. La responsabilidad es la gestión de las transacción entre fronteras, documentación aduanera y permisos requeridos para que un producto pueda ser traído de un lugar a otro sin incumplir reglas o decretos, la administración de aranceles también es fundamental en este proceso y tener en cuenta otros factores externos para asegurar que el flujo de bienes y servicios no se interrumpa garantizando la continuidad operativa.

En el contexto de la medición del rendimiento de la *SCM*, el *Lead Time* (Tiempo de Ciclo) es una variable de rendimiento fundamental.

El *Lead Time* se define como el tiempo total transcurrido desde que se inicia un proceso (como la colocación de una orden de compra) hasta su conclusión satisfactoria la recepción de la mercancía por parte del cliente. (Saleheen et al., 2018)

La importancia de esta métrica en la gestión de la SCM trasciende la simple medición de "días de entrega". Un *lead time* más bajo y, de manera crucial, más predecible

(es decir, con baja variabilidad), se correlaciona directamente con beneficios estratégicos tangibles:

1. Una menor necesidad de mantener costosos inventarios de seguridad
2. Una reducción en los costos financieros asociados al capital de trabajo inmovilizado.
3. Un incremento significativo en la capacidad de respuesta al cliente y, por ende, en su nivel de satisfacción.

5.2. Indicadores Claves de desempeño y F-Score

Un Indicador Clave de Desempeño (KPI) es una métrica cuantitativa y estratégica diseñada para evaluar la consecución de un objetivo de negocio. Sin embargo, una definición moderna de los KPIs debe entenderse en el contexto de la crítica a los sistemas de medición tradicionales.

Históricamente, las organizaciones medían su rendimiento casi exclusivamente a través de indicadores financieros retrospectivos (ej. rentabilidad, flujo de caja). El trabajo seminal de Kaplan y Norton (1992) expuso las limitaciones de este enfoque, argumentando que las métricas financieras por sí solas son insuficientes para guiar a una organización en la era de la información. (Kaplan & Norton, 1992)

Como solución, introdujeron el Cuadro de Mando Integral (Balanced Scorecard), una teoría seminal que revolucionó la medición del desempeño. Este marco propone que la gerencia debe tener una visión "equilibrada" que traduzca la estrategia en un conjunto coherente de indicadores, agrupados en cuatro perspectivas críticas:

Perspectiva Financiera: (¿Cómo nos ven nuestros accionistas?)

Perspectiva del Cliente: ¿Cómo nos perciben nuestros clientes?

Perspectiva de Procesos Internos: ¿En qué procesos debemos ser excelentes?

Perspectiva de Aprendizaje y Crecimiento: ¿Cómo podemos seguir mejorando y creando valor?

En este contexto, un KPI no es cualquier métrica, sino una herramienta de navegación que alinea la acción operativa (como la gestión de un analista de COMEX) con la estrategia global como la eficiencia de la cadena de suministro. Este proyecto, por tanto, se enfoca en definir y construir un KPI (el score de productividad) que se alinea directamente con la perspectiva de procesos internos.

El concepto tradicional de productividad, heredado de la era industrial, se basa en la medición de parámetros físicos y visibles ejemplo unidades producidas por hora. Este modelo es obsoleto para el contexto de este proyecto. Un analista de Comercio Exterior es un trabajador del conocimiento su labor es cognitiva, no manual, e implica la gestión de información, la resolución de problemas complejos y la coordinación.

Medir la productividad del trabajador del conocimiento es un desafío. Un analista que procesa 100 órdenes "fáciles" no es necesariamente más productivo que uno que resuelve 1 orden compleja que amenazaba con detener una cadena de suministro confiable.

Por lo tanto, este proyecto distingue dos conceptos clave:

- **Eficiencia (Hacer las cosas bien):** Se refiere a la optimización de recursos. En COMEX, sería la capacidad de procesar un alto volumen de órdenes en el menor tiempo posible.
- **Eficacia (Hacer las cosas correctas):** Se refiere a la consecución de objetivos. En COMEX, esto se traduce en asegurar el cumplimiento del *lead time*, priorizar órdenes críticas y gestionar la variabilidad.

El score de productividad desarrollado en este trabajo de grado trasciende la medición de eficiencia. Al estar basado en un modelo que predice la probabilidad de

cumplimiento, se enfoca primordialmente en medir la eficacia del colaborador en el contexto de la complejidad de su carga de trabajo.

5.3. Inteligencia de negocios

La Inteligencia de Negocios (BI) se define como un proceso integral y tecnológico que abarca la infraestructura, las herramientas y las mejores prácticas para transformar datos brutos en información significativa y accionable con el fin de mejorar la toma de decisiones empresariales.

Se definen el BI como un término sombrilla que combina arquitecturas, herramientas, bases de datos, aplicaciones y metodologías. Su objetivo principal es permitir el acceso interactivo a los datos, su manipulación y el análisis de estos, facilitando así que los tomadores de decisiones obtengan conocimiento valioso de ellos. En esencia, el BI se enfoca en proporcionar una visión clara de la situación actual y pasada del negocio para responder a preguntas como "¿Qué pasó?" y "¿Por qué pasó?".(Sharda et al., 2018)

El campo del BI ha experimentado una evolución significativa, transitando desde el reporte estático hacia la analítica predictiva. Como señalan Chen, Chiang y Storey en su artículo, el BI tradicional se centraba en la analítica descriptiva (reportes, *dashboards*, KPIs) para entender el rendimiento histórico.(Chen et al., 2012)

Sin embargo, el entorno empresarial moderno exige una visión proactiva, dando lugar a la Analítica Avanzada. Esta nueva etapa no se conforma con describir el pasado, sino que utiliza técnicas de minería de datos y aprendizaje automático para predecir el futuro y prescribir acciones. La analítica avanzada responde a preguntas más complejas como "¿Qué pasará?" y "¿Qué deberíamos hacer?" que no es más que la parte predictiva y prescriptiva.

El presente proyecto de grado se sitúa precisamente en esta transición. No se limita a describir el *lead time* pasado, sino que construye un modelo predictivo para anticipar la probabilidad de cumplimiento futuro, generando así un score de productividad que es lo que se requiere para poder determinar el funcionamiento del área en su global.

5.4. Minería de datos

La Minería de Datos, o Data Mining, es un campo interdisciplinario en el núcleo de la ciencia de datos. Se define como el proceso de descubrir patrones, correlaciones y conocimiento accionable a partir de grandes volúmenes de datos, utilizando técnicas de aprendizaje automático, estadística y sistemas de bases de datos.(Plotnikova et al., 2021)

El objetivo de la minería de datos no es simplemente extraer datos, sino extraer conocimiento útil que era previamente desconocido. En un contexto empresarial, este conocimiento se traduce en una ventaja competitiva, ya sea a través de la optimización de procesos, la identificación de riesgos o la comprensión del comportamiento. Este proyecto utiliza la minería de datos para descubrir los patrones que determinan el cumplimiento del *lead time*.

5.5. Metodología CRISP-DM

Para que un proyecto de minería de datos tenga éxito, no es suficiente aplicar algoritmos de forma aislada; se requiere un marco de trabajo estructurado. La metodología CRISP-DM es el estándar más adoptado y probado en la industria para guiar estos proyectos.(Plotnikova et al., 2021)

CRISP-DM no es una lista rígida de pasos, sino un modelo de proceso cíclico y flexible diseñado para asegurar que el esfuerzo técnico se mantenga permanentemente alineado con los objetivos de negocio. Como demuestran estudios sobre su aplicación la

fortaleza de CRISP-DM radica en su adaptabilidad a dominios específicos, como el financiero o, en este caso, el de la logística y el comercio exterior.

Su naturaleza iterativa es su característica más importante. El proceso (dividido en seis fases: Comprensión del Negocio, Comprensión de los Datos, Preparación de Datos, Modelado, Evaluación y Despliegue) no es lineal. Por el contrario, los bucles de retroalimentación son explícitos: los hallazgos en la fase de modelado, por ejemplo, pueden obligar a regresar a la preparación de datos para crear nuevas variables.

La adopción de CRISP-DM en este proyecto garantiza que la construcción del modelo predictivo no sea un mero ejercicio técnico, sino una solución robusta que responde directamente al problema y los objetivos del negocio.

5.6. Aprendizaje supervisado

El Aprendizaje Supervisado es un subcampo del Machine Learning que consiste en la tarea de inferir una función a partir de datos de entrenamiento etiquetados. El conjunto de datos de entrenamiento consiste en un conjunto de pares de entrada-salida (X, Y) , donde X es el vector de variables de entrada (predictoras) e Y es la variable de salida (objetivo) que se desea predecir.

Como describen Hastie, Tibshirani y Friedman en su artículo, el objetivo del algoritmo es aprender una función de mapeo general que sea capaz de predecir la salida Y para observaciones futuras X que no ha visto previamente. (R. Tibshirani et al., 2009)

En el contexto de este proyecto, se aplica un modelo de aprendizaje supervisado de clasificación. El vector X está compuesto por las características de una orden de compra como lo puede ser la cantidad pedido, responsable Comex, modo transporte, y la etiqueta Y es nuestra variable objetivo binaria cumplimiento *lead time* que lo tomamos como 1 o 0. El

modelo, por tanto, aprende la compleja relación entre las características de una orden y su probabilidad de éxito.

5.7. Modelos de ensamble

La práctica moderna del aprendizaje automático ha demostrado que, en lugar de depender de un único modelo, es preferible emplear métodos de ensamble. Estos métodos se basan en el principio de sabiduría colectiva combinan las predicciones de múltiples modelos más simples para generar una predicción final más robusta, precisa y con mejor capacidad de generalización. (R. Tibshirani et al., 2009)

Bagging: Entrena múltiples modelos en paralelo e independientes, y promedia sus resultados. Su principal objetivo es reducir la varianza.

Boosting (Refuerzo): Entrena modelos de forma secuencial, donde cada modelo se enfoca en corregir los errores del modelo anterior. Su principal objetivo es reducir el sesgo.

5.8. Random Forest

El algoritmo Random Forest es la implementación más popular y exitosa de la técnica de Bagging. Su método de construcción es el siguiente:

- Crea múltiples muestras bootstrap (muestras aleatorias con reemplazo) del conjunto de datos de entrenamiento.
- Entrena un árbol de decisión en cada muestra.
- Crucialmente, en cada división (split) de cada árbol, solo considera un subconjunto aleatorio de las variables predictoras.

La predicción final se toma por una votación mayoritaria de todos los árboles del bosque. Esta doble aleatorización (a nivel de filas y de columnas) lo hace extremadamente

robusto contra el sobreajuste (overfitting) y sirve como una base de alto rendimiento para problemas de clasificación.(Breiman, 2001)

5.9. Modelos Gradient Boosting

A diferencia de Random Forest, el Boosting es un proceso aditivo y secuencial. El concepto central es que el modelo aprende de sus errores:

Se entrena un primer modelo (generalmente un árbol simple).

Se calculan los errores (residuos) que este modelo comete.

Se entrena un segundo árbol, no para predecir la variable objetivo, sino para predecir los errores del árbol anterior.

El proceso se repite (ej. 100 veces), donde cada nuevo árbol se especializa en corregir los errores residuales del ensamble construido hasta ese momento.

5.10. XGBoost (Extreme Gradient Boosting)

El Gradient Boosting fue popularizado y optimizado por la implementación XGBoost. Su éxito masivo se debe a su escalabilidad y, fundamentalmente, a la incorporación de regularización (L1 y L2) en su función de optimización. Esto permite al modelo construir árboles secuenciales de forma agresiva, pero controlando el sobreajuste, lo que resulta en una precisión líder en la industria.(Chen & Guestrin, 2016)

5.11. LightGBM (Light Gradient Boosting Machine):

LightGBM, una implementación aún más eficiente. Mientras que XGBoost construye árboles por nivel (level-wise), LightGBM lo hace por hoja (leaf-wise). Esta innovación, junto con técnicas de muestreo de gradiente (GOSS), le permite alcanzar una velocidad de entrenamiento significativamente superior en conjuntos de datos grandes, sin sacrificar y a menudo mejorando la precisión de XGBoost.(Ke et al., 2017)

5.12. Fundamentación elección del modelo

La selección de un algoritmo de machine learning es solo una parte del proceso de modelado. Una etapa igualmente crítica es la evaluación de su rendimiento. Confiar únicamente en una métrica puede ser engañoso; por lo tanto, se requiere un marco de evaluación que permita diagnosticar el comportamiento del modelo, especialmente en un contexto de negocio donde los errores pueden implicar un costo monetario.

5.13. Accuracy

La **Exactitud** (*Accuracy*) definida como el porcentaje de predicciones correctas sobre el total de predicciones es la métrica más intuitiva. Sin embargo, su uso como única métrica de rendimiento es ampliamente reconocido como insuficiente e incluso engañoso, especialmente en conjuntos de datos que no están perfectamente balanceados. (S. Tibshirani & Friedman, s. f.)

Considere un escenario donde una clase es mayoritaria. Un modelo trivial que prediga siempre la clase mayoritaria Cumple obtendría una alta exactitud, pero sería completamente inútil para el negocio, ya que su objetivo es, precisamente, identificar la clase minoritaria: los "No Cumplimientos".

5.14. Matriz de confusión

Para superar las limitaciones de la exactitud, la evaluación de modelos de clasificación se basa en la **Matriz de Confusión**. Esta matriz es la herramienta de diagnóstico fundamental que desglosa el rendimiento del modelo al comparar las clases predichas con las clases reales. (S. Tibshirani & Friedman, s. f.)

Para un problema binario, la matriz se estructura en cuatro cuadrantes. Aplicado al contexto de este proyecto (donde la "Clase Positiva" es el evento de interés: 0 = No Cumple):

Verdadero Positivo (VP): El modelo predijo "No Cumple" (0) y la orden *realmente* "No Cumplió" (0). Este es un **acierto** o "detección exitosa"

Verdadero Negativo (VN): El modelo predijo "Cumple" (1) y la orden *realmente* "Cumplió" (1). Este es un acierto de la normalidad.

Falso Positivo (FP) - Error Tipo I: El modelo predijo "No Cumple" (0), pero la orden *realmente* "Cumplió" (1). Esta es una **"falsa alarma"** y tiene un costo de negocio (ej. recursos desperdiciados revisando una orden correcta).

Falso Negativo (FN) - Error Tipo II: El modelo predijo "Cumple" (1), pero la orden *realmente* "No Cumplió" (0). Este es un **"fallo oculto"** y es, con diferencia, **el error más costoso** para el negocio, ya que representa un riesgo no detectado.

5.15. Precisión vs. Recall

A partir de la matriz de confusión, se derivan métricas más significativas que la exactitud. Las dos más importantes son la Precisión y la Sensibilidad (Recall):

Precisión (Precisión):

$$\frac{VP}{(VP + FP)}$$

Responde a la pregunta: "De todas las órdenes que el modelo etiquetó como "No Cumple", ¿qué porcentaje era realmente un fallo?". Mide que tan certeras son las alarmas generadas por el modelo.

Sensibilidad (Recall): $VP / (VP + FN)$. Responde a la pregunta: "De todas las órdenes que *realmente* 'No Cumplieron', ¿qué porcentaje logró 'atrapar' el modelo?". Mide la exhaustividad o capacidad de detección del modelo.

Es fundamental entender que existe una compensación inherente entre estas dos métricas. Un modelo configurado para ser extremadamente "sensible" (alto Recall) tenderá

a generar más falsas alarmas (baja Precisión). Inversamente, un modelo configurado para ser extremadamente "preciso" (solo alarmas de alta certeza) tenderá a omitir muchos fallos reales (bajo Recall).(S. Tibshirani & Friedman, s. f.)

5.16. Análisis Curva ROC y AUC

Dada la compensación anterior, surge la pregunta: ¿cómo se mide el rendimiento de un modelo de forma global, independientemente del umbral de decisión, es decir, cuán seguro debe estar el modelo para emitir una predicción?

La respuesta es el análisis ROC por sus siglas en inglés (Receiver Operating Characteristic). Como describe Fawcett en su artículo seminal, la curva ROC es la herramienta más robusta para evaluar clasificadores.(Fawcett, 2006)

Curva ROC: Es una gráfica que representa la Tasa de Verdaderos Positivos en el eje Y, frente a la Tasa de Falsos Positivos en el eje X, para todos los umbrales de clasificación posibles.

AUC (Area Under the Curve): Es la métrica que resume toda la curva en un solo número: el Área Bajo la Curva. El AUC se puede interpretar como la probabilidad de que el modelo asigne una puntuación de riesgo más alta a un caso "Positivo" (No Cumple) elegido al azar que a un caso "Negativo" (Cumple) elegido al azar.(Fawcett, 2006)

Un AUC de 0.5 representa un modelo inútil (azar), mientras que un AUC de 1.0 representa un clasificador perfecto. El AUC es la métrica preferida en este proyecto por ser insensible al desbalance de clases y medir el poder de discriminación puro del modelo, lo que justifica la selección del LightGBM como la solución óptima.

5.17. Interpretación de Modelos y Analítica Explicable

En el desarrollo de modelos de *machine learning*, históricamente ha existido una tensión entre el rendimiento del modelo y su interpretabilidad. Esta tensión da lugar al desafío conocido como el problema de la "caja negra".

Los algoritmos que demostraron el más alto rendimiento en este proyecto como lo son el LightGBM y XGBoost son modelos de ensamble complejos. Su arquitectura interna, que combina secuencialmente los resultados de cientos de árboles de decisión, hace que su lógica de toma de decisiones sea compleja para la intuición humana. A esto se le conoce como el problema de la "caja negra".(Guidotti et al., 2019)

El modelo puede generar una predicción de altísima precisión ejemplo "Esta orden fallará con un 82% de probabilidad", pero no puede explicar por qué de forma nativa.

5.18. Necesidad crítica de la confianza para el negocio

Este problema técnico genera un déficit de confianza en el negocio. Para que un gerente de COMEX actúe basándose en el score de productividad o en una predicción del modelo, no es suficiente que el modelo sea preciso; debe ser comprensible y fiable.

La falta de explicabilidad es una barrera directa para la adopción de sistemas de IA. La gerencia necesita entender qué factores impulsan una predicción para poder confiar en ella y, lo que es más importante, para saber qué "palancas" operativas debe mover para mejorar el resultado.(Linardatos et al., 2021)

5.19. Analítica Explicable (Explainable AI – XAI)

Como respuesta a este desafío, ha surgido el campo de la Analítica Explicable (XAI). Se define XAI como el conjunto de técnicas y métodos que permiten a los usuarios humanos comprender y confiar en los resultados y salidas creados por los modelos de machine learning.(Guidotti et al., 2019)

El alcance predictivo del modelo se determina por las variables transaccionales y operativas internas, excluyendo eventos de fuerza mayor o disrupciones macroeconómicas impredecibles ejemplo crisis geopolíticas o desastres climáticos. Esta delimitación es consistente con la literatura reciente, en la gestión moderna de cadenas de suministro, el objetivo de la Inteligencia Artificial no es eliminar la incertidumbre estocástica del entorno, sino dotar a la organización de resiliencia y capacidad de explicación para reaccionar ágilmente ante desviaciones, priorizando la adaptabilidad sobre una precisión absoluta en escenarios volátiles.(Jauhar et al., 2025)

Mientras que la literatura previa a 2020 enfocaba el *People Analytics* casi exclusivamente en la gestión de recursos humanos (ausentismo, rotación), investigaciones recientes demuestran un giro hacia la integración de datos de talento con métricas operacionales. Las organizaciones líderes tienen cinco veces más probabilidades de integrar datos de RR.HH. con datos de negocio no relacionados con personas como finanzas u operaciones para tomar decisiones estratégicas.

En el contexto específico de la productividad, estudios recientes de 2024 señalan que el *People Analytics* actúa como un catalizador del comportamiento organizacional, permitiendo evaluar el Retorno de Inversión (ROI) del empleado no por su presencia, sino por su impacto directo en los KPIs del negocio. Esto valida el enfoque del presente proyecto, que no mide al analista de comercio exterior por sus "horas trabajadas", sino por su eficacia en el cumplimiento del *Lead Time*, esto se alinea sobre el uso de algoritmos para automatizar la detección de potencial y eficiencia en tareas complejas.(Zhu, 2024)

La aplicación de modelos de aprendizaje automático en la cadena de suministro ha evolucionado hacia la necesidad crítica de transparencia. Kosasih en su revisión sistemática

sobre XAI en *Supply Chain Management*, argumentan que la falta de es la principal barrera para la adopción de IA en entornos logísticos reales.(Kosasih et al., 2024)

El objetivo de XAI no es simplificar el modelo perdiendo precisión, sino construir un segundo modelo "explicativo" o aplicar técnicas que iluminen el comportamiento del modelo de caja negra. Estas técnicas se dividen generalmente en dos categorías:

Explicaciones Locales: Buscan explicar una predicción individual (ej. ¿Por qué esta orden específica de Andrea Ayala fue marcada como "No Cumple"?).

Explicaciones Globales: Buscan explicar el comportamiento general del modelo ejemplo ¿Qué factores considera el modelo, en general, como los más importantes para predecir un fallo?(Barredo Arrieta et al., 2020)

5.20. Métodos de interpretación global: Importancia de variables (Feature Importance)

Este proyecto aplica un método de interpretación global, que es la técnica más relevante para la generación de recomendaciones estratégicas. La Importancia de Variables (Feature Importance) es una técnica que cuantifica la contribución relativa de cada variable predictora al rendimiento total del modelo. (R. Tibshirani et al., 2009)

En los modelos basados en árboles como LightGBM, la importancia se calcula comúnmente midiendo la mejora total (o "ganancia") que aporta una variable al dividir los nodos. En términos simples, una variable es "importante" si el modelo la utiliza frecuentemente y con éxito para segmentar los datos y hacer predicciones más precisas. (Lundberg & Lee, 2017)

6. Metodología CRISP-DM

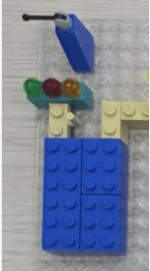
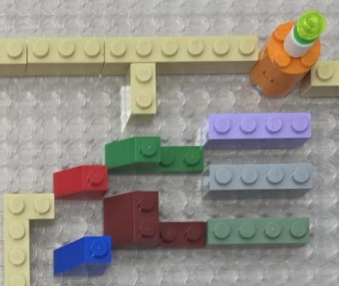
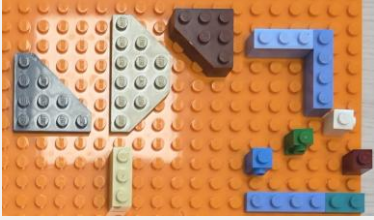

Para la metodología de CRISP-DM realizamos un ejercicio con LEGO SERIOUS PLAY donde determinamos las fases que debemos implementar, debido a que trabajando de una manera más grafica podemos explicar y entender de una mejor manera los procesos a realizar.


Figura 1 *Lego Serious Play (Construcción proyecto con legos)*



Fuente: Elaboración Propia 2025

Tabla 1 Descripción Proceso Crisp DM

FASE	IMAGEN	DESCRIPCION
Comprensión del negocio		En esta fase vamos a comprender como funciona y que herramientas presenta la empresa A para obtener la información y como opera el área de Comex.
Comprensión y preparación de los datos		Ya teniendo la comprensión de los datos que nos proporcionan debemos hacer algunos ajustes como estandarizaciones y creación de métricas como fechas, para poder pasar sin errores y con los datos suficientes al modelado.
Modelado y Evaluación		Para el modelado se realiza un LightGBM con el fin de predecir el cumplimiento de las órdenes de compra y con esto realizar un modelo score para medir la productividad.
Despliegue		Se entregarán un documento técnico y tableros en Power BI a las gerencias de Comex y Recursos Humanos. Estas herramientas les permitirán medir los KPIs propuestos y monitorear el desempeño de los colaboradores,

		<p>facilitando así la definición de un perfil de cargo optimizado para mejorar la productividad.</p>
--	---	--

Fuente: Elaboración propia 2025

6.1 FASE 1 - Comprensión del Negocio

El área de COMEX actualmente mide la productividad de manera general, sin diferenciar la naturaleza del trabajo de cada colaborador. Esto puede llevar a evaluaciones de desempeño imprecisas, una distribución de la carga de trabajo no óptima y dificultades para identificar cuellos de botella o necesidades de capacitación específicas. La principal dificultad del negocio se manifiesta a través de los siguientes puntos, que describen la situación actual:

Estándares Teóricos y Datos Maestros: La empresa posee datos maestros en SAP que definen los tiempos esperados para cada hito del proceso de importación. Sin embargo, estos datos no se encuentran actualizados y no reflejan las condiciones operativas actuales. Esto genera pérdidas por parte de una tardía gestión en los procesos que afecta costos y tiempos de entrega.

KPIs de Productividad: El área de COMEX no tiene Indicadores Clave de Rendimiento enfocados en la productividad individual o del equipo. La gestión se limita a medir resultados finales ejempló el número de importaciones completadas, pero carece de visibilidad sobre la eficiencia y el costo para alcanzar dichos resultados. Sin KPIs de

productividad, la gerencia opera "a ciegas", siendo incapaz de responder a preguntas fundamentales como:

- ¿Cuál es la capacidad real de nuestro equipo?
- ¿Quién es más eficiente gestionando qué tipo de embarque?
- ¿Estamos mejorando nuestra eficiencia con el tiempo?

Traducción del Problema: El objetivo de negocio se traduce técnicamente en un problema de aprendizaje supervisado de clasificación. En lugar de realizar evaluaciones basadas en promedios simples o criterios subjetivos, utilizaremos un algoritmo de LightGBM para aprender de los datos históricos los patrones complejos que determinan el éxito o el retraso de una operación. No buscamos agrupar a los colaboradores, sino estimar la probabilidad exacta de que cada orden de compra cumpla con su tiempo de entrega *lead time*. A partir de estas predicciones individuales, construiremos un indicador *score* agregado que permita medir objetivamente la productividad de cada colaborador en función de la complejidad y el éxito de sus gestiones.

Formulación del Proyecto: El objetivo de este proyecto es lograr que el área tenga un mayor eficiencia operativa, mediante un sistema de medición de desempeño que es el modelo score, todo basado en datos y capaz de identificar factores claves que influyen en el cumplimiento de los plazos de llegada de material.

Criterio de Éxito Técnico: Para este proyecto vamos a tomar como un éxito poder tener un rendimiento del modelo seleccionado superior al 75 % en el área bajo la curva ROC. Ya que con esta medición estamos tomando toda la capacidad del modelo de determinar correctamente los cumplimientos y los no cumplimientos.

6.2 FASE 2 - Comprensión de los Datos

La empresa A es una empresa multilatina fundada en 1976, con presencia en 10 países a lo largo de América Latina. Su misión es contribuir al crecimiento y la sostenibilidad en la cadena de valor de la industria y el campo en Latinoamérica. Ofrecen una amplia gama de productos y servicios, incluyendo el suministro de materias primas, productos químicos, fertilizantes de alta calidad y soluciones innovadoras para diversas industrias.

La operación de la empresa A está fuertemente impulsada por la analítica de datos, utilizando herramientas como Power BI para analizar y tomar decisiones rápidas sobre las operaciones diarias de la compañía.

Los datos que se utilizarán en este proyecto serán proporcionados por la empresa A, con el fin de asegurar que la información sea concreta y veraz para el estudio a realizar. No se utilizarán datos externos para realizar el análisis, ya que esto podría afectar el resultado.

El activo de datos principal para este proyecto consiste en un conjunto de datos transaccionales extraídos del sistema de planificación de recursos empresariales (SAP) de la compañía. Este conjunto de datos, consolidado en un archivo (referenciado como BD_LimpiaCOMEX.xlsx y posteriormente como BD_Final_Final_Cumplimiento.xlsx), representa el histórico de las órdenes de compra gestionadas por el área de COMEX.

De manera inicial se confirma la disponibilidad de las variables clave identificadas en la Fase 1, incluyendo identificadores de órdenes, fechas de creación, fechas de entrega, responsables, proveedores, modos de transporte y valores monetarios.

El conjunto de datos cargado para el análisis (como se documenta en el notebook de Colab análisis Univariado Final.ipynb) consta de **7,661 registros** (representando órdenes de compra individuales) y **46 variables** (columnas).

Estas variables se pueden clasificar en las siguientes tipologías:

- **Identificadores y Fechas:** Variables que sitúan la transacción (ej. doc. compra, Fecha/Hora creación, F. Entrega Disan).
- **Variables Categóricas (Nominales y Ordinales):** Describen atributos cualitativos de la orden (ej. responsable Comex, nombre proveedor, modo de transporte, país de origen).
- **Variables Numéricas (Continuas y Discretas):** Describen magnitudes cuantitativas (ej. cantidad pedido, valor cif, días transito).

A nivel de recopilación de los datos iniciales, se ha identificado una única fuente de datos primaria:

- **ERP - SAP:** Esta es la fuente principal. Se extraerá la información de la base de datos de importaciones a través de SQL.
- **Datos de Importaciones (SAP):**
- **Entidad:** BD Importaciones
- **Datos de Colaboradores (SAP):**
- **Entidad:** BD Colaboradores Comex

Figura 2 *Estructura del dataframe de la BASE_IMPORTACIONES.*

```
[INFO] Estructura del DataFrame de Importaciones:
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 29427 entries, 0 to 29426
Data columns (total 37 columns):
#   Column                               Non-Null Count  Dtype
---  -
0   SociedadId                           29427 non-null  int64
1   NumeroDocCompras                     29427 non-null  int64
2   NumeroPosDocCompras                  29427 non-null  int64
3   NumeroDocContable                    29427 non-null  int64
4   ProveedorId                          29427 non-null  int64
5   PROVEEDOR                            29427 non-null  object
6   GrupoComprasId                       29427 non-null  int64
7   GRUPO_COMPRAS                        29427 non-null  object
8   CentroDestinoId                      29427 non-null  int64
9   SociedadMaterialId                   29427 non-null  int64
10  MaterialId                            29427 non-null  int64
11  MATERIAL                              29427 non-null  object
12  PlaneadorId                           29427 non-null  int64
13  ResponsableComexId                   29427 non-null  int64
14  RESPONSABLE_COMEX                    29427 non-null  object
15  CompradorId                           29427 non-null  int64
16  COMPRADOR                             29427 non-null  object
17  PuertoOrigenId                       29427 non-null  int64
18  PuertoDestinoId                      29427 non-null  int64
19  ContenedorId                          29427 non-null  int64
20  CantidadConten                         29427 non-null  int64
21  IncotermId                            29427 non-null  int64
22  FechaSolicitud                        29427 non-null  datetime64[ns]
23  NumeroSolped                          29427 non-null  int64
24  FechaOrden                            29427 non-null  datetime64[ns]
25  FechaEntrega                          29427 non-null  object
26  FechaContable                         29427 non-null  datetime64[ns]
27  FechaBL                                29427 non-null  datetime64[ns]
28  TRM                                    29427 non-null  float64
29  Cantidad                               29427 non-null  float64
30  CantidadOc                             29427 non-null  float64
31  Valor                                  29427 non-null  float64
32  PrecioNeto                            29427 non-null  float64
33  Valorcif                               29427 non-null  float64
34  Valortrian                            29427 non-null  float64
35  CondicionId                           29427 non-null  int64
36  NombreCondicion                       29427 non-null  object
```

Fuente: Base de datos de importaciones elaboración propia 2025

La Figura 2 nos muestra un conjunto de 37 columnas las cuales son las variables, determinamos cual es el tipo de la variable que estamos manejando serian números enteros, caracteres, fechas y números con decimal.

Figura 3 Estructura del dataframe de *BASE_COLABORADORES_COMEX*

```
[INFO] Estructura del DataFrame de Colaboradores:
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 26 entries, 0 to 25
Data columns (total 16 columns):
#   Column                Non-Null Count  Dtype
---  -
0   Genero                 26 non-null     object
1   EmpleadoId            26 non-null     int64
2   Unidad Negocio        26 non-null     object
3   Modalidad de Trabajo  26 non-null     object
4   Tipo de Contrato      26 non-null     object
5   Area                  26 non-null     object
6   Sub Area              26 non-null     object
7   Nivel Académico      26 non-null     object
8   Cargo                 26 non-null     object
9   Nivel Cargo          26 non-null     object
10  Sub Nivel Cargo       26 non-null     object
11  Años Antigüedad      26 non-null     int64
12  Nivel Unico           26 non-null     object
13  fecha ingreso        26 non-null     datetime64[ns]
14  Colaborador          26 non-null     object
15  Nombre Completo      26 non-null     object
```

Fuente: Base de datos de colaboradores elaboración propia 2025

La Figura 3 nos muestra un conjunto de 16 columnas las cuales son las variables, determinamos cual es el tipo de la variable que estamos manejando serian números enteros, caracteres, fechas y números con decimal.

Definición de hitos: En este momento se realiza la definición de las fechas que tenemos establecidas, con el fin de determinar las fechas de cumplimiento de los procesos de COMEX, con los datos ya encontrados en la base de BD Importaciones se define que hitos e indicadores debemos calcular en la preparación de los datos (Fase 3), las principales variables para tener en cuenta son las *Órdenes de Compra* (OC), el *Origen-Destino* (OD), *Materiales* y los tiempos o cantidades promedio por *Colaborador*.

$$Lead_Time = FechaContabilizacion - FechaSolicitud$$

Indicadores por Colaborador:

Cantidad de OC.

Tiempo en Transito promedio por OD.

Valor Promedio de OC.

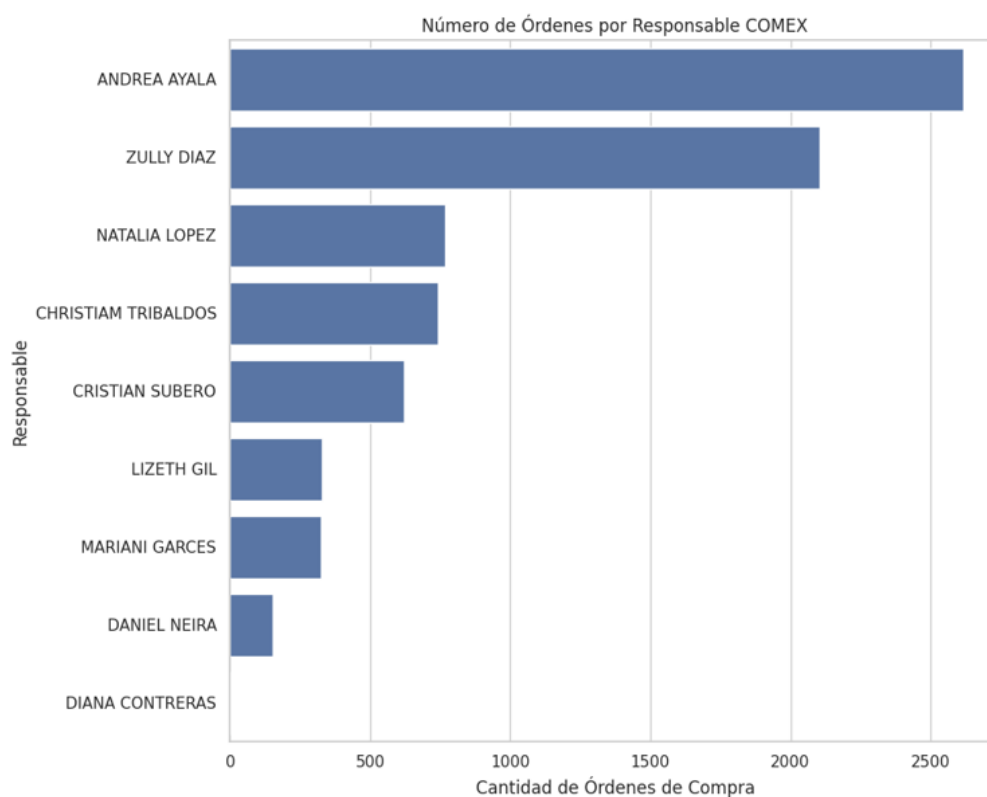
Promedio de toneladas por OC.

Cantidad Materiales por OC.

Participación por OD.

Análisis univariado: La finalidad del análisis univariado es conocer que tenemos y como es el comportamiento de las variables que estamos asociando, en este caso se determina revisar los histogramas de órdenes de compra por cada uno de los responsables de Comex, se realiza una tabla de frecuencia por puerto origen y por último se determina el número de ordenes que procesa el área de COMEX según el cargo que tienen.

Figura 4 Cantidad de OC por responsable Comex

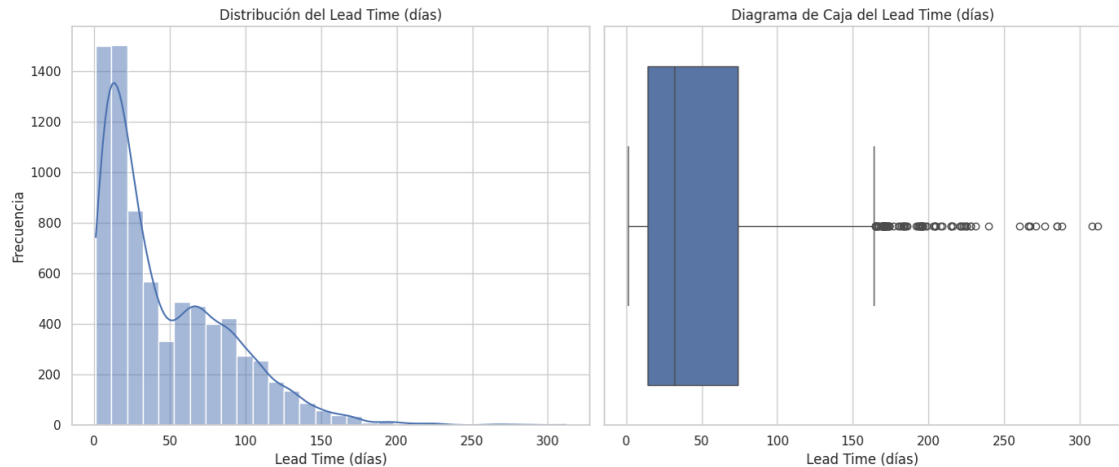


Fuente: Elaboración propia en Google Colab 2025

En este gráfico de barras podemos evidenciar la distribución de procesamiento de órdenes de compra por cada uno de los responsables de Comex donde se ve una gran carga de órdenes para Andrea Ayala y Zully Diaz. Conociendo el negocio sabemos que los coordinadores de COMEX como son estos dos responsables Comex tienen un mayor flujo

debido a su experiencia en el manejo y procesamiento de las órdenes de compra, esto lo podemos ver de mejor manera en la figura 6.

Figura 5 *Análisis del Lead Time*



Fuente: Elaboración propia en Google Colab 2025


La Figura 5 presenta un análisis comparativo de la tasa de éxito de las órdenes de compra en función del método logístico empleado. El eje Y representa el porcentaje total de órdenes para cada categoría, mientras que el eje X nos muestra el *lead time* en días.

El histograma revela una distribución con una marcada asimetría positiva (sesgo a la derecha). Esto indica que la gran mayoría de las órdenes de compra se completan en lapsos de tiempo reducidos, con la moda (el valor más frecuente) situándose en el rango bajo de la escala [ej. 10-30 días]. Sin embargo, la distribución exhibe una "cola larga" que se extiende considerablemente hacia la derecha, evidenciando que, aunque con baja frecuencia, existe un número significativo de órdenes cuyos tiempos de entrega son extremadamente prolongados (superando los 200 días). En una distribución de este tipo, el promedio aritmético (Media) será desplazado hacia la derecha por estos valores extremos, situándose por encima de la Mediana.

El diagrama de caja (box plot) confirma y cuantifica esta observación. El Rango Intercuartílico (IQR), representado por la "caja" que agrupa al 50% central de los datos, se muestra sumamente compacto y posicionado en la zona baja del gráfico. Esto corrobora que la operación "estándar" es homogénea y eficiente.

El hallazgo más crítico que aporta el diagrama de caja es la visualización de una multitud de valores atípicos (Outliers), representados por los puntos que se sitúan más allá del bigote superior. Estos *Outliers* son la representación individual de la "cola larga" observada en el histograma.

Figura 6 *Distribución de grupo de artículos*

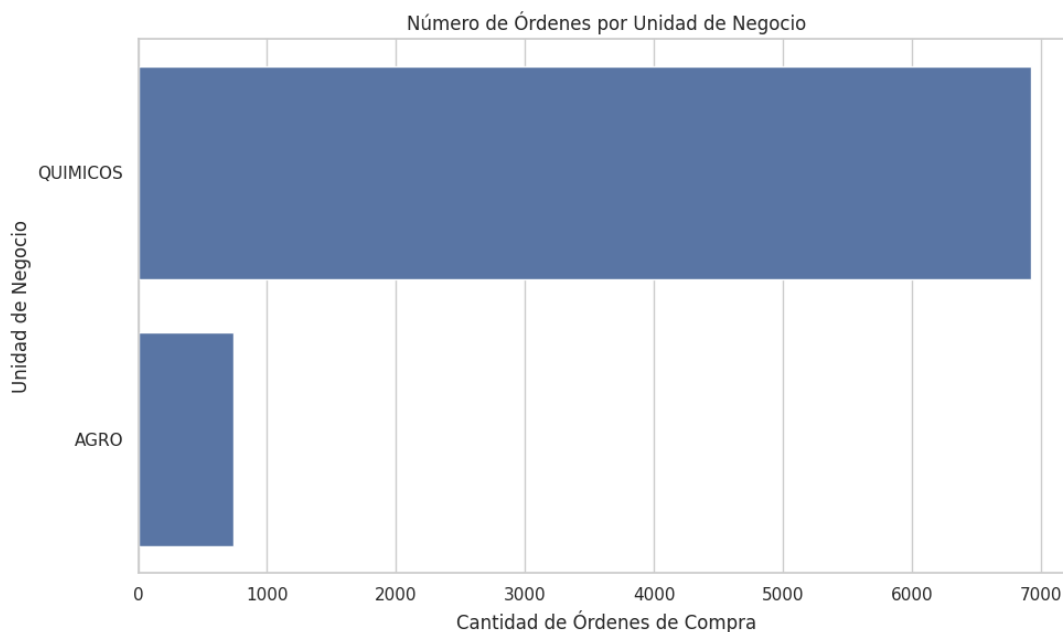


Fuente: Elaboración propia en Google Colab 2025

La Figura 6 detalla la composición del grupo donde esta cada artículo y dejando claro que la mayoría de las órdenes procesadas contienen materiales de la familia de los

commodities y las que menos se procesan son de muestras ya que estas son un proceso más interno de la compañía al hacer la maquila internamente.

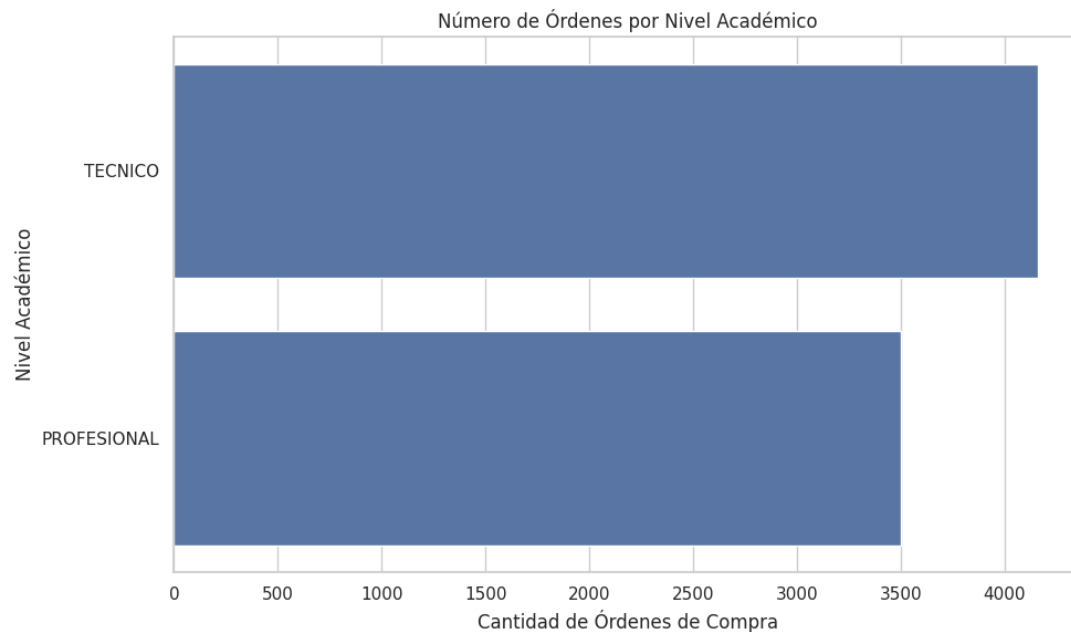
Figura 7 *Distribución de ordenes por unidad de negocio*



Fuente: Elaboración propia en Google Colab 2025

En este grafico podemos evidenciar claramente que las órdenes de compra analizadas son más enfocadas a la unidad de químicos con un número muy superior a las ordenes procesadas por la unidad de Agro.

Figura 8 *Distribución de colaboradores por nivel académico*

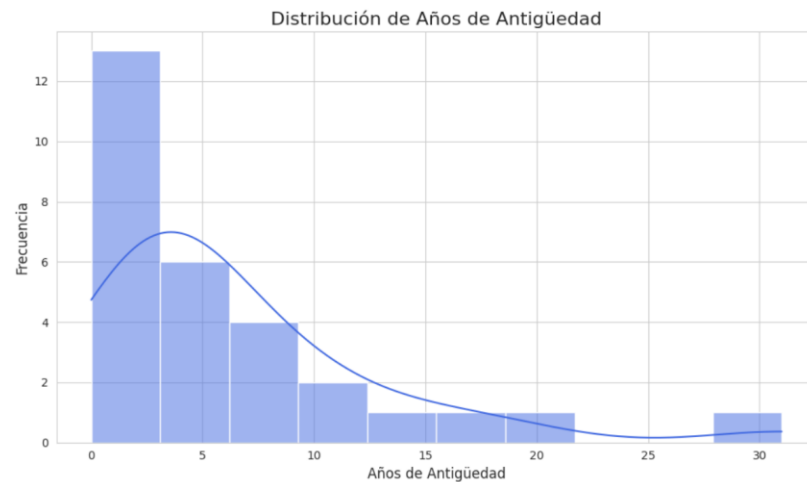


Fuente: Elaboración propia en Google Colab 2025

Perfil Académico del Equipo Comex: Este análisis detalla la distribución del nivel académico del equipo, un componente esencial en la fase de comprensión de los datos que servirá como variable clave.

Composición del Equipo: El equipo está compuesto mayoritariamente por personal con formación "**Profesional**" (45%) y "**Técnica**" (28%). Esta base educativa (72% del total) sugiere una plantilla con fundamentos teóricos y prácticos sólidos. La presencia de formación de posgrado ("Maestría") es, por ahora, puntual.

Figura 9 *Distribución años de antigüedad*



Fuente: Elaboración propia en Google Colab 2025


Análisis de la Distribución de Antigüedad Laboral: El histograma revela la distribución de la antigüedad de los colaboradores dentro de la empresa, un indicador clave de la estabilidad y experiencia del equipo.

Observaciones Clave: Concentración de Talento Joven: Se evidencia que la mayoría del personal (aproximadamente 13 colaboradores) tiene una antigüedad inferior a 5 años, lo que sugiere un equipo relativamente joven.

Sesgo Positivo la distribución presenta un marcado sesgo a la derecha. Esto confirma una alta concentración de personal con pocos años de servicio y una "cola larga" que representa a un número reducido de empleados con una larga trayectoria en la compañía.

Experiencia Intermedia y Senior existe un grupo secundario de empleados con una permanencia de entre 5 y 10 años, mientras que los colaboradores con más de 15 años de servicio constituyen casos puntuales, representando la memoria histórica de la organización.

Figura 10 *Top 10 rutas origen - destino*

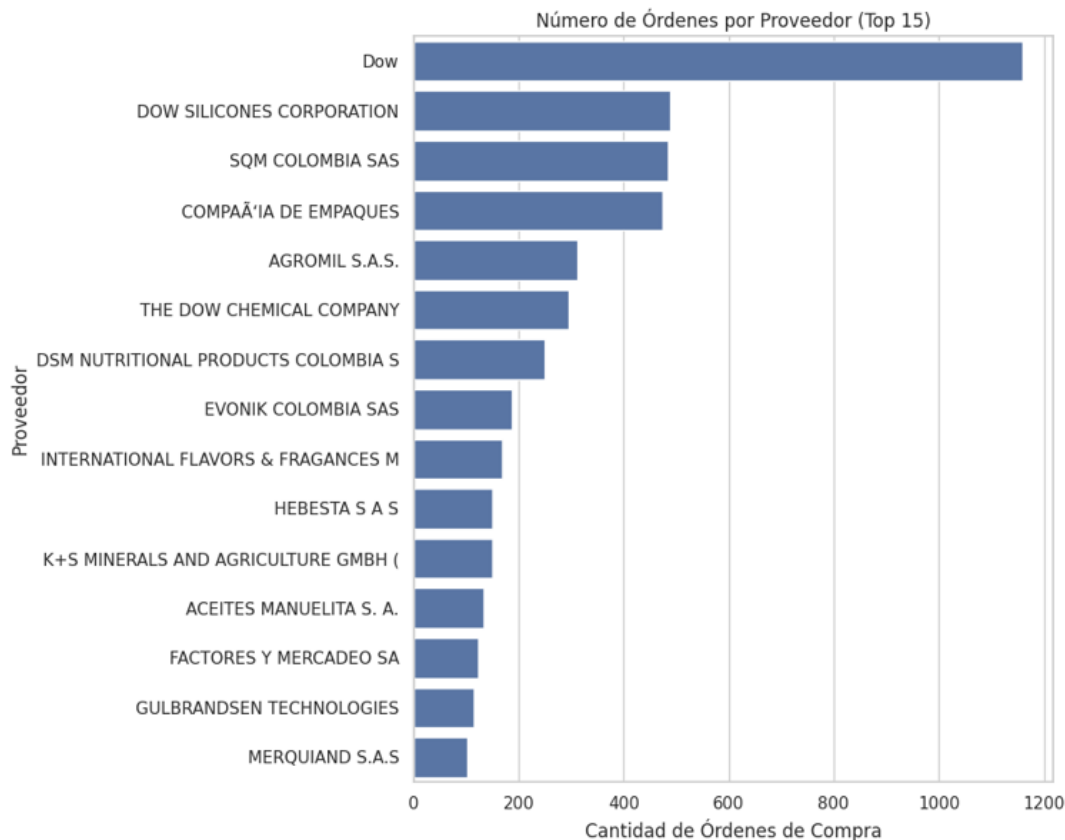


Fuente: Elaboración propia en Google Colab 2025

El gráfico detalla las 10 rutas logísticas más frecuentes, medidas por volumen de operaciones. El análisis confirma una marcada concentración en orígenes de Estados Unidos (Laredo, Houston, etc.), lo que subraya una dependencia estratégica de este corredor comercial. Asimismo, se destaca la relevancia de la ruta desde China, un pilar del comercio con Asia.

Un hallazgo crítico es la alta incidencia de registros con destino "**Indeterminado**". Esto no representa una ruta, sino una deficiencia en la calidad de los datos, señalando una oportunidad clara para mejorar los procesos de registro de información.

Figura 11 *Distribución carga por responsable Comex*



Fuente: Elaboración propia en Google Colab 2025

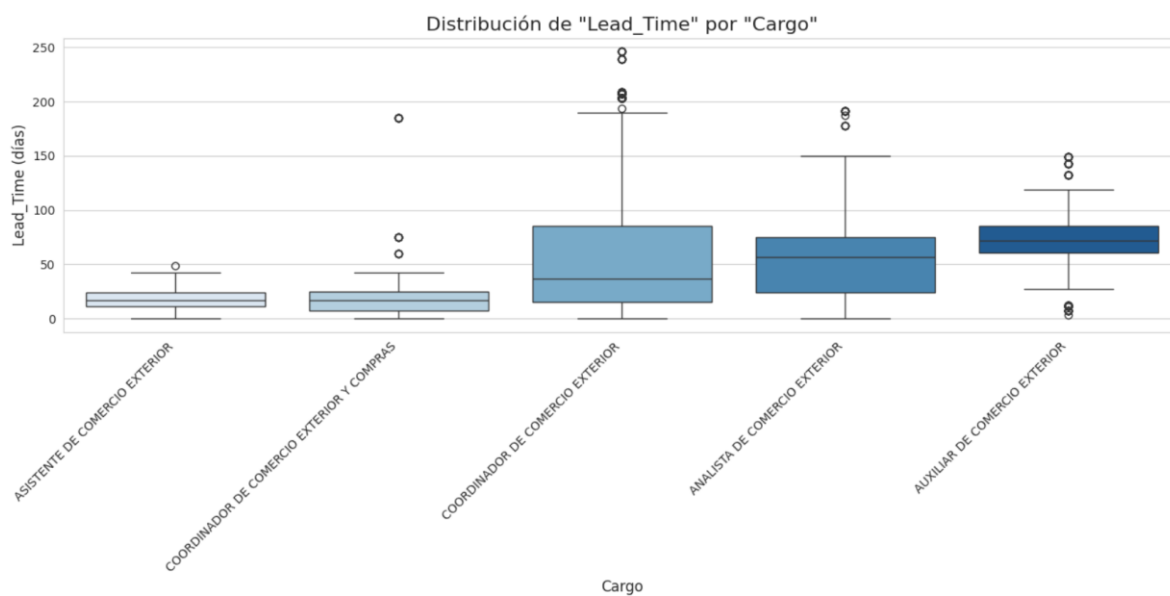
La observación más relevante del análisis no es solo la aparente dominancia del proveedor "Dow" (con aprox. 1,150 órdenes), sino la evidente duplicidad de registros referentes a la misma entidad empresarial. En el Top 15 figuran también "DOW SILICONES CORPORATION" (aprox. 500 órdenes) y "THE DOW CHEMICAL COMPANY" (aprox. 250 órdenes).

Es altamente probable que estas tres entradas representen al mismo grupo empresarial. De consolidarse, este único proveedor ("Grupo Dow") agruparía casi 1,900 órdenes, magnificando su posición dominante y representando una porción sustancial de toda la operativa.

Esto indica que la relación comercial en términos transaccionales está altamente concentrada en unos pocos socios estratégicos, mientras que una gran cantidad de proveedores (la mayoría de los cuales no alcanzan a figurar en este Top 15) tienen volúmenes de transacción mucho menores y más dispersos.

Por otra parte, teniendo en cuenta el análisis del *Lead Time* por los cargos actuales del área de Comex, se logra identificar y realizar una segmentación inicial con características únicas por grupo, lo cual da una valoración inicial para la gestión del área teniendo en cuenta las variables clave de Cargo y *Lead time* promedio.

Figura 12 Gráfico boxplot de *Lead Time* por cargo



Fuente: Elaboración propia en Google Colab 2025

Los principales grupos resultantes a partir de la Figura 12 son:

Grupo 1: Alta Eficiencia y Consistencia

Asistente de Comercio Exterior y Coordinador de Comercio Exterior y Compras:

Estos dos roles presentan los *Lead Times* más bajos y consistentes.

Mediana Lead Time: Se sitúa alrededor de los 15-20 días, la más baja de todos los grupos.

Variabilidad: Sus cajas (IQR) son muy compactas, lo que indica que la mayoría de sus procesos se completan en un rango de tiempo muy predecible y acotado.

Outliers: Aunque el "Coordinador de Comercio Exterior y Compras" presenta algunos valores atípicos elevados (hasta ~190 días), su rendimiento general es estable.

Grupo 2: Alta Variabilidad

Coordinador de Comercio Exterior y Analista de Comercio Exterior: Estos cargos muestran un comportamiento similar entre sí, caracterizado por una alta dispersión en sus resultados.

Mediana Lead Time: Presentan una mediana más alta, en torno a los 40 días.

Variabilidad: Sus cajas son notablemente más amplias, lo que significa que sus *Lead Times* son muy variables e impredecibles. Por ejemplo, el 50% central de sus casos puede variar desde ~15 hasta ~80 días.

Outliers: Ambos roles registran múltiples valores atípicos con tiempos muy elevados (superiores a 180 días), lo que agrava la falta de previsibilidad.

Grupo 3: Lead Time Elevado

Auxiliar de Comercio Exterior: Este rol se distingue por tener los tiempos de entrega más largos en general.

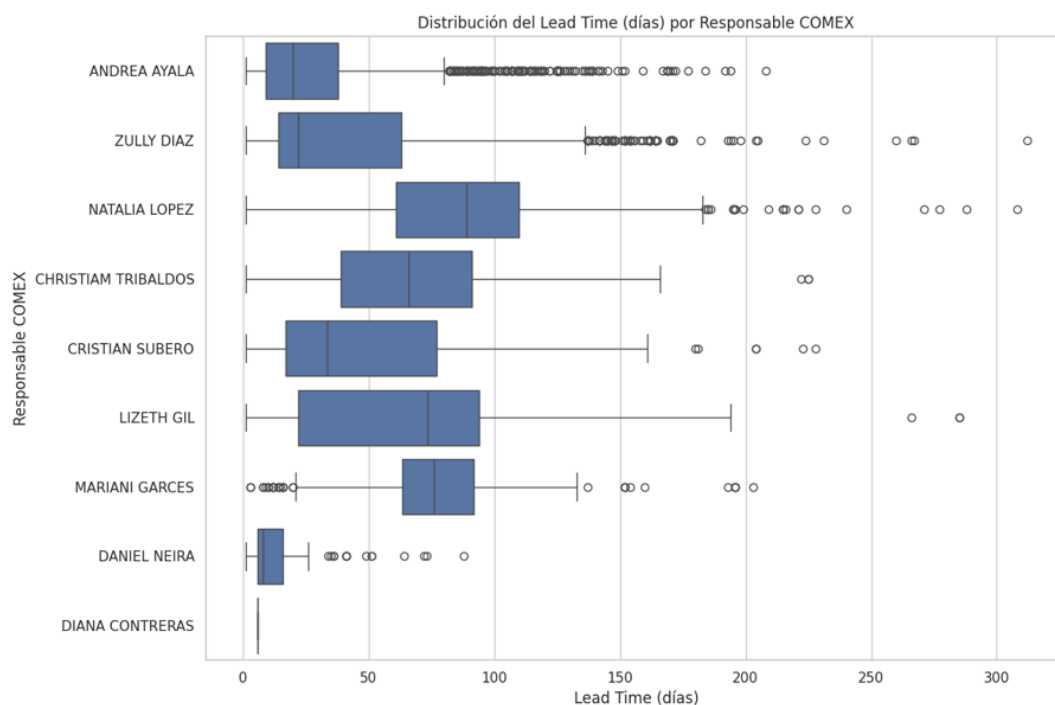
Mediana Lead Time: Es la más alta de todos los cargos, ubicada aproximadamente en los 60 días.

Variabilidad: Aunque su caja es ligeramente menos ancha que la del Grupo 2, toda la distribución está desplazada hacia tiempos más largos. El 75% de sus procesos (Q3) tarda 90 días o menos.

Outliers: Es el único cargo que muestra valores atípicos tanto altos como bajos.

Con esto podemos determinar que el mejor desempeño es el cargo de Asistente de Comercio Exterior y Coordinador de Comercio Exterior y Compras, ya que estos cargos no son los que más procesan órdenes de compra por lo tanto sus desviaciones si serán menores.

Figura 13 Distribución lead time por responsable Comex



Fuente: Elaboración propia en Google Colab 2025

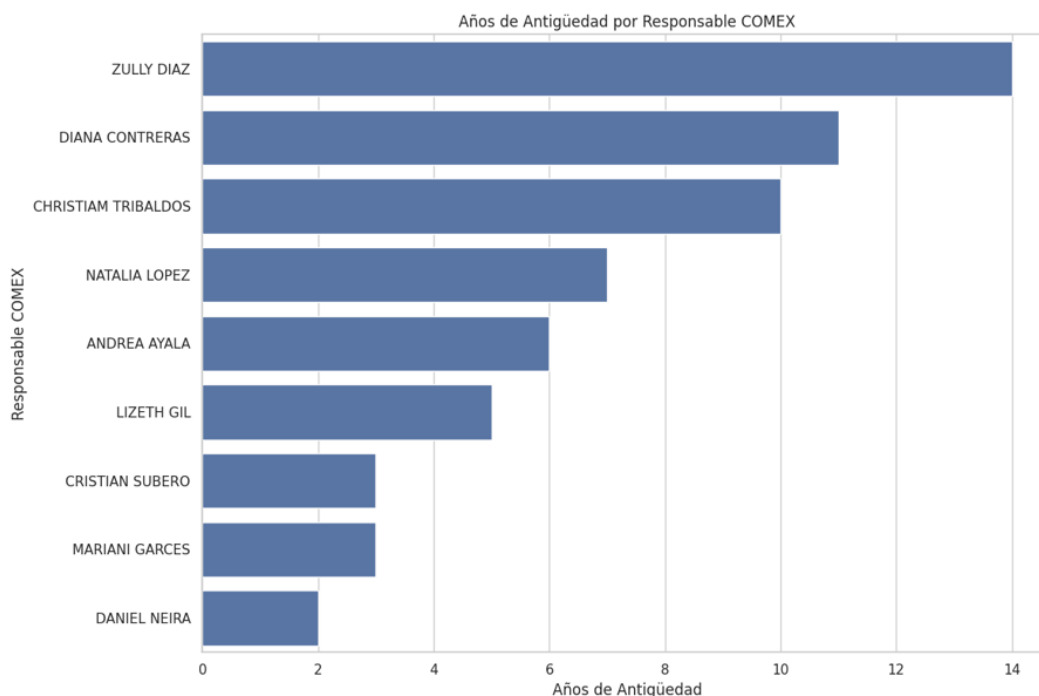
La Figura 13 presenta un conjunto de diagramas de caja que comparan la distribución del *lead time* (días) entre los diferentes colaboradores del área de COMEX. Esta visualización es esencial en la fase de comprensión de los datos ya que permite identificar diferencias significativas en el rendimiento operativo y la consistencia de cada miembro del equipo.

A continuación, se describe el desempeño de cada colaborador:

- DIANA CONTRERAS: Presenta el rendimiento más destacado del equipo. Exhibe la mediana de *lead time* más baja (aprox. 10 días) y demuestra una consistencia perfecta, al no registrar ningún valor atípico.
- DANIEL NEIRA: Muestra un rendimiento de alta eficiencia, con una mediana muy baja (aprox. 15-20 días). Su variabilidad es controlada y presenta un impacto de *Outliers* mínimo.
- ANDREA AYALA: Posee una mediana de trabajo "típico" muy eficiente (aprox. 25 días). No obstante, su métrica se ve severamente afectada por una variabilidad extrema, siendo la colaboradora con la mayor cantidad de valores atípicos (retrasos significativos).
- ZULLY DIAZ: Registra una mediana moderada (aprox. 40-45 días). Sin embargo, su desempeño también muestra una variabilidad muy alta, manifestada en una notable cantidad de *Outliers* que extienden sus tiempos de entrega.
- CRISTIAN SUBERO: Su rendimiento se caracteriza por una mediana alta (aprox. 70-75 días). La variabilidad es moderada, lo que sugiere que el principal desafío se encuentra en su tiempo de procesamiento estándar.
- CHRISTIAM TRIBALDOS: Muestra un perfil similar al anterior, con una mediana alta (aprox. 75 días) y una presencia moderada de valores atípicos.
- LIZETH GIL: Presenta una mediana alta (aprox. 80 días). Su diagrama de caja se distingue por una amplitud considerable (alto Rango Intercuartílico), indicando una alta variabilidad en sus tiempos "normales", además de la presencia de *Outliers*.
- NATALIA LOPEZ: Combina una mediana estructuralmente alta (aprox. 80-85 días) con un número considerable de valores atípicos, lo que denota desafíos tanto en la eficiencia estándar como en la gestión de excepciones.

- **MARIANI GARCES:** Exhibe la mediana más alta del equipo (cercana a los 90 días). Su rendimiento "normal" es el más lento del grupo, al cual se le suma una variabilidad atípica moderada.

Figura 14 *Distribución años de antigüedad*



Fuente: Elaboración propia en Google Colab 2025

Con base en los análisis anteriores y principalmente los resultados de la Figura 14 se plantean las siguientes hipótesis para entender de una manera más clara el comportamiento de cada colaborador según su antigüedad y rendimiento:

El Paradigma del Rendimiento Junior (El Caso Daniel Neira)

El análisis de este colaborador rompe con la suposición tradicional de que la experiencia es el principal motor de la eficiencia.

- **Datos:** Es el miembro con la menor antigüedad del equipo (2 años).

- **Rendimiento Cruzado:** A pesar de ser el más junior, su perfil de rendimiento (analizado en la Figura 14) es uno de los más eficientes y consistentes, con una mediana de *lead time* muy baja y una ausencia casi total de valores atípicos.

Hipótesis Estratégica: Este hallazgo plantea dos hipótesis críticas para la gerencia:

El colaborador posee una alta agilidad en el uso de herramientas tecnológicas o una ausencia de vicios procesales adquiridos, lo que le permite ser más eficiente; o existe un sesgo en la asignación de trabajo, donde al ser junior, se le asignan proveedores u órdenes de menor complejidad, lo que inflaría artificialmente sus métricas de éxito.

La Hipótesis de la Carga de Complejidad (El Caso Zully Díaz)

En el extremo opuesto del espectro de antigüedad, encontramos un perfil que sugiere cómo la experiencia redefine el rol laboral.

- **Datos:** Es la colaboradora con la mayor antigüedad (14 años), posicionándola como la experta senior indiscutible del equipo.
- **Rendimiento Cruzado:** Su perfil de *lead time* mostraba una mediana moderada, pero estaba caracterizado por una **alta incidencia de valores atípicos** (retrasos extremos).

Hipótesis Estratégica: Es altamente posible que esta colaboradora sea "víctima de su propia experiencia". Dado su conocimiento, es probable que se le asignen sistemáticamente los casos más complejos, problemáticos o las "incidencias" críticas que el resto del equipo no puede gestionar. Por lo tanto, la alta variabilidad en sus métricas no reflejaría una ineficiencia personal, sino la naturaleza de su rol como solucionadora de problemas de alto nivel.

El Estándar de Oro: Experiencia y Consistencia (El Caso Diana Contreras)

Este perfil representa el mejor desempeño en el área.

- **Datos:** Posee una alta antigüedad (11 años), siendo la segunda con más experiencia.
- **Rendimiento Cruzado:** Su desempeño fue el mejor en términos absolutos: la mediana más rápida y, crucialmente, **cero valores atípicos**.
- **Hipótesis Estratégica:** Diana Contreras representa la síntesis ideal de conocimiento experto y control total del proceso. Demuestra que la experiencia puede traducirse en una alta predictibilidad y eficiencia. Su perfil la posiciona como el modelo a seguir y la fuente idónea para la extracción de mejores prácticas.

La Curva de Aprendizaje Estándar (El Caso Mariani Garces)

Este caso refuerza la lógica tradicional de la curva de aprendizaje, en contraste con el caso atípico de Daniel Neira.

- **Datos:** Es una colaboradora junior (3 años de antigüedad).
- **Rendimiento Cruzado:** Su perfil de *lead time* registraba la mediana más alta (el proceso estándar más lento) del equipo.
- **Hipótesis Estratégica:** A diferencia del caso excepcional de alto rendimiento junior, este perfil se alinea con la expectativa de que un menor tiempo en la compañía se traduce en un proceso de gestión más deliberado y lento, característico de la fase de consolidación de conocimiento.
- **Implicaciones Gerenciales del Análisis**

Este análisis cruzado dota a la gerencia de una visión que puede sobrepasar la simple medición. La antigüedad no debe usarse como un sinónimo de eficiencia, sino como un indicador del tipo de rol que el colaborador desempeña. Pero a la vez nos hace cuestionar la Calidad de los datos antes de hacer cualquier tipo de conclusión o aseveración al respecto.

Verificar la calidad de datos:

Tabla 2 *Calidad de los datos*

ID Problema	Tipo de Problema	Campo(s) Afectado(s)	Descripción Detallada	Impacto en el Negocio	Criticidad
DQ-001	Valor Atípico/Erróneo	FechaEntrega	Se identificaron registros con la fecha '31/12/9999'. Este es un valor placeholder o un error del sistema.	Impide medir el cumplimiento y tiempo de entrega real del proveedor.	Alta
DQ-002	Formato Inconsistente	TRM, Valor	Los campos numéricos utilizan una coma (,) como separador decimal, lo que puede causar errores de cálculo en la mayoría de los sistemas analíticos.	Riesgo de cálculos financieros incorrectos y errores al cargar los datos.	Alta
DQ-003	Datos Faltantes	FechaBL	Se observaron múltiples registros donde esta fecha es nula.	Imposibilita el cálculo del tiempo de tránsito marítimo y la eficiencia en esa etapa del proceso.	Media
DQ-004	Integridad Referencial	ResponsableComexId	Se debe verificar si todos los ResponsableComexId en BD Importaciones tienen una correspondencia en BD Colaboradores.	Podrían existir operaciones "huérfanas" sin un responsable claro asignado en el sistema de RRHH.	Media
DQ-005	Duplicidad de Datos	NumeroDocCompras	Se debe ejecutar una comprobación para asegurar que no existan órdenes de compra duplicadas.	Podría inflar artificialmente las métricas de volumen y valor.	Alta

Fuente: Elaboración propia en Excel 2025

La mala calidad de los datos puede generar inconvenientes en todo el desarrollo del proyecto lo que no solo impide unos resultados creíbles si no una toma de decisiones errada.

Análisis y Cálculos Incorrectos: Datos con formatos inconsistentes, como el uso de comas en lugar de puntos decimales (DQ-002), o valores erróneos como fechas (DQ-001), pueden llevar a cálculos financieros errados, métricas infladas (DQ-005) y una medición incorrecta del rendimiento de los proveedores.

Ineficiencia Operativa: La falta de datos clave, como una fecha faltante (DQ-003), impide calcular métricas esenciales como los tiempos de tránsito, lo que a su vez dificulta la optimización de los procesos logísticos.

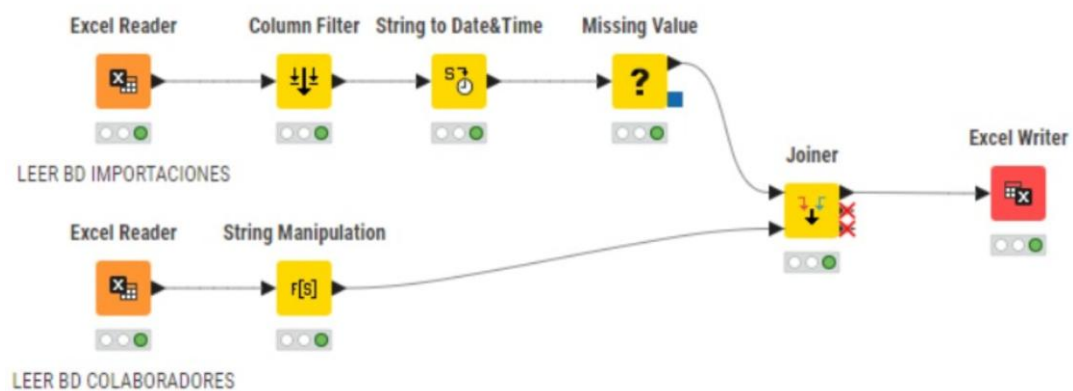
Problemas de Integridad y Trazabilidad: La falta de correspondencia entre sistemas (DQ-004) puede crear "operaciones huérfanas", dificultando la asignación de responsabilidades y el seguimiento de los procesos de negocio.

Teniendo en cuenta la comprensión de los datos y realizando los procesos establecidos podemos empezar con la preparación de los datos lo que será fundamental para poder hacer posteriormente el modelado.

6.3 FASE 3 - Preparación de los Datos

La preparación de los datos es uno de los pasos más importantes para que todo el proceso de ahí en adelante en el modelado salga de la mejor manera posible y nos arroje la realidad de nuestro negocio por lo que se debe realizar un proceso muy detallado y consciente en los datos.

Figura 15 ETL del proceso de preparación de datos



Fuente: Elaboración propia en programa Knime

Carga de Datos: Utilizando la herramienta de Knime se cargan las dos bases de datos BD Importaciones, BD Colaboradores y BD Puertos.

Integración: Se debe realizar una unión entre las bases con un Left Join, tomando como llave el ResponsableComexID la cual nos genera la integración entre las dos bases, para la base de BD Puertos la llave de unión es por el ID del puerto.

Al final de esta unión quedara como resultado una única base de datos con toda la información que se requiere.

Limpieza y Estandarización de Datos: El primer paso consistió en corregir las inconsistencias y problemas de calidad identificados durante el Análisis Exploratorio de Datos (EDA).

Valores Nulos: Se realiza la eliminación de valores nulos como puedes ser un ID que no logro cruzar en la unión de las bases, estas celdas vacías se les agrega el texto de “no asignado”. Todo esto con la finalidad de no presentar errores en un análisis futuro y permite tener mapeados estos casos más fácilmente.

Estandarización de Fechas: Las fechas pueden generar inconvenientes en los cálculos si no están bien definidas con el formato, se debe dar el formato de datetime que entiende Python para poder realizar los procesos.

Se debe indicar el formato de fecha como día/mes/año, y no en otro formato ya que se debe estandarizar el proceso.

Si se encuentra con un valor que no deje hacer la conversión a este formato, lo debe convertir en un valor especial que podría ser tratado como un dato nulo.

Construcción de Variables (Feature Engineering)

La Variable clave que se construye es la del *Lead Time* la cual es el tiempo de llegada para cumplir con la orden de importación.

$$Lead_Time = FechaContabilizacion - FechaSolicitud$$

Cálculo de la Variable Predictora Base:

Lead Time (días) La primera variable construida fue el tiempo de entrega total, calculado como la diferencia en días entre la fecha de creación de la orden y la fecha de entrega:

Construcción de la variable objetivo:

Este es el desarrollo de ingeniería de características más complejo y crucial. Un umbral de cumplimiento simple (ej. "todas las órdenes < 60 días") sería injusto, ya que no es lo mismo un *lead time* de 60 días para un material que viene de Asia que para uno local.

Por lo tanto, se diseñó una regla de negocio dinámica y adaptativa que calcula un umbral de cumplimiento individual por cada material analizado, basándose en su propio historial estadístico.

Paso 1: Se calculó el promedio (μ) y la desviación estándar (σ) del *lead time* (días) para cada material único.

Paso 2: Se definió el umbral de cumplimiento ajustado (*Umbral_Ajustado*) para cada material como:

$$\text{Umbral Ajustado} = \mu + (0.5 * \sigma)$$

(Esto significa que se considera "normal" cualquier entrega que esté hasta media desviación estándar por encima del promedio histórico de ese material).


- Paso 3: Se clasificó cada orden (1 = Cumple, 0 = No Cumple) comparando su *lead time* real con el umbral dinámico de su material:

$$\text{Cumplimiento} = 1 \text{ si } \textit{lead time} \leq \textit{Umbral ajustado}$$

$$\text{Cumplimiento} = 0 \text{ si } \textit{lead time} > \textit{Umbral ajustado}$$

Este cálculo nos permite que la medición sea estadísticamente más precisa y que no sea un criterio vacío, pues crea una variable objetivo que mide la eficiencia real, ajustada por la complejidad de cada producto. El resultado de esta clasificación arrojó un 71.37% de órdenes que "Cumplen" (1) y un 28.63% que "No Cumplen" (0), proporcionando un conjunto de datos balanceado para el modelado.

Figura 16 *Porcentaje de cumplimiento área Comex*



Fuente: Elaboración propia en Google Colab 2025

Transformación de Datos para el Modelado

El conjunto de datos aún no está listo para realizar el modelado ya que este no puede interpretar variables de texto (categóricas) directamente, por esta razón se realiza una codificación de variables categóricas.

Codificación de Variables Categóricas (One-Hot Encoding):

Para que el modelo pueda procesar variables como responsable Comex o modo_transporte, estas deben ser convertidas a un formato numérico. Se utilizó la técnica de One-Hot Encoding.

Esta técnica transforma una columna categórica en múltiples columnas binarias (0 o 1), esto se hace con el fin de que el algoritmo matemático pueda interpretar fácilmente los datos y tenga un rendimiento mayor al involucrar más variables al análisis predictivo.

Este proceso se aplicó a todas las variables categóricas seleccionadas (ej. responsable Comex, nombre proveedor estandarizado, etc.), lo que resultó en un incremento significativo del número de columnas, pero permitió al modelo capturar la influencia de cada categoría individualmente.

El resultado de esta Fase 3 es el conjunto de datos final, limpio y transformado, listo para el modelado. Esta tabla contiene 7,661 filas. Contiene las variables necesarias para poder avanzar con la etapa del modelado.

6.4 FASE 4 – Modelado

El objetivo de esta etapa es seleccionar, aplicar y optimizar una técnica de aprendizaje automático para construir un modelo predictivo que responda al objetivo de minería de datos: clasificar las órdenes de compra según su probabilidad de cumplimiento. La documentación del proceso de modelado está en el cuaderno de Google Colab.

Como se estableció en los objetivos, el problema de negocio se ha traducido en una tarea de clasificación binaria supervisada. La variable objetivo es el cumplimiento (con valores 1 para "Cumple" y 0 para "No Cumple").

Se realiza un proceso de evaluar diferentes modelos con el fin de determinar cual representa mejor los datos obtenidos y que nos ofrezca un análisis y solución más acercada a la realidad de nuestro problema de negocio.

Se seleccionaron tres algoritmos candidatos para la comparación:

Random Forest (Bosque Aleatorio): Es un modelo de ensamble que opera mediante la construcción de una multitud de árboles de decisión. Se considera una línea base de alto rendimiento, muy robusto contra el sobreajuste.

XGBoost (Extreme Gradient Boosting): Es el estándar de oro industrial para *gradient boosting*. Construye árboles de manera secuencial, donde cada nuevo árbol corrige

los errores del anterior. Es conocido por su altísima precisión y optimización, creciendo los árboles por nivel.

LightGBM (Light Gradient Boosting Machine): Es un competidor directo de XGBoost, también basado en *gradient boosting*. Su principal diferencia es su eficiencia y velocidad, ya que crece los árboles por hoja, lo que suele ser más rápido en conjuntos de datos grandes.

La técnica de modelado seleccionada para este proyecto es el LightGBM (Light Gradient Boosting Machine). La elección de este algoritmo, en lugar de otros modelos como Regresión Logística o Árboles de Decisión simples, se fundamenta en sus ventajas técnicas comprobadas para este tipo de datos:

- **Alto Desempeño Predictivo:** Los modelos basados en *Gradient Boosting* (como LightGBM) son reconocidos en la industria por su alta precisión en datos tabulares (estructurados en filas y columnas), como los de este proyecto.
- **Eficiencia Computacional:** LightGBM utiliza un algoritmo de crecimiento de árboles basado en hojas (*leaf-wise*), lo que lo hace significativamente más rápido y eficiente en el uso de memoria que otras implementaciones de *boosting*.
- **Manejo de Características:** Es robusto manejando un gran número de variables (lo cual es relevante tras el *One-Hot Encoding*) y proporciona una métrica clara de importancia de variables, lo cual es vital para la Fase 5 (Evaluación).

Uno de los factores de mayor importancia para escoger el modelo fue la medición del F1 y del AUC ROC, estos parámetros son vitales ya que uno nos mide el equilibrio que existe entre cumplimientos y no cumplimientos y nos determina si la base está muy desbalanceada y el AUC ROC nos determina que tan bien está calculando esas predicción por lo que a un valor mayor de AUC ROC está teniendo una mejor predicción el modelo.

Diseño de la Prueba

Para evaluar objetivamente el rendimiento de los tres modelos candidatos y asegurar su capacidad de generalización el conjunto de datos analítico es sometido a un test para la evaluación.

Conjunto de Entrenamiento: Compuesto por el **70%** de los datos. Se utiliza para el entrenamiento del modelo y para el proceso de optimización de hiperparámetros.

Conjunto de Prueba: Compuesto por el **30%** restante. Estos datos no se tienen en cuenta para el modelo. Se utilizan una única vez al final para obtener una evaluación completa del rendimiento del modelo.

La división se realizó utilizando la función `train_test_split` de Scikit-learn, asegurando la reproducibilidad del experimento mediante la fijación de una semilla aleatoria (`random_state`).

Construcción y Optimización de Modelos

Para que cada modelo (Random Forest, XGBoost y LightGBM) alcance su máximo potencial, es necesario encontrar la configuración óptima de sus hiperparámetros.

Técnica: Se empleó la técnica de **GridSearchCV (Validación Cruzada)**.

Proceso: Este método prueba de forma exhaustiva diferentes combinaciones de hiperparámetro y utiliza la validación cruzada para determinar qué combinación produce el mejor rendimiento para cada algoritmo.

Análisis de hiperparámetro

La interpretación de esta arquitectura es fundamental para entender el comportamiento del modelo final:

`learning_rate: 0.1`: Esta es la tasa de aprendizaje. Un valor de 0.1 es un estándar de la industria robusto y eficiente. Determina la "velocidad" a la que el modelo aprende: cada

nuevo árbol (estimador) corrige el 10% del error residual del árbol anterior. No es tan bajo como para requerir miles de árboles, ni tan alto como para que el modelo "se pase de largo" de la solución óptima.

`n_estimators: 100`: Define el número de árboles secuenciales que construirá el modelo. Un total de 100 árboles, combinado con una tasa de aprendizaje de 0.1, sugiere que el modelo es altamente eficiente, logrando converger a una solución de alto rendimiento en un número relativamente bajo de iteraciones.

`max_depth: 20` y `num_leaves: 40`: Esta es la configuración más importante de LightGBM. `num_leaves: 40`: Este es el hiperparámetro clave de LightGBM, ya que controla la complejidad del modelo. Un valor de 40 hojas permite que cada árbol individual sea significativamente complejo y capture interacciones matizadas.

`max_depth: 20`: Este parámetro actúa como un mecanismo de regularización o "freno" para el `num_leaves`. Aunque el modelo podría crear hasta 40 hojas, se le prohíbe crecer verticalmente más allá de 20 niveles. Esto previene que el modelo se vuelva excesivamente profundo y específico para un puñado de muestras, ayudando a controlar el sobreajuste sin sacrificar la complejidad que le otorgan las 40 hojas.

Para dejar todo claro con estos hiperparámetros, la configuración óptima encontrada describe un modelo eficiente de 100 árboles que aprende a un ritmo estándar (0.1), y que es altamente complejo pero regulado 40 hojas limitadas por 20 hojas de profundidad, permitiéndole capturar la complejidad de la operativa de COMEX sin memorizar los datos de entrenamiento.

Figura 17 Hiperparámetro utilizados en el modelo

	max_depth	min_samples_leaf	min_samples_split	n_estimators	colsample_bytree	learning_rate	subsample	min_child_samples	num_leaves
Random Forest	20	1.0	5.0	300	NaN	NaN	NaN	NaN	NaN
XGBoost	3	NaN	NaN	100	1.0	0.1	1.0	NaN	NaN
LightGBM	5	NaN	NaN	100	NaN	0.1	NaN	20.0	31.0


Fuente: Elaboración propia en Google Colab 2025

Figura 18 Comparación modelos utilizados

Modelo	Accuracy	Precision	Recall	F1 Score	AUC ROC
Random Forest	0.8491	0.8491	1.0000	0.9184	0.7097
XGBoost	0.8512	0.8559	0.9918	0.9188	0.7401
LightGBM (Ganador)	0.8517	0.8553	0.9933	0.9192	0.7459

Fuente: Elaboración propia en Google Colab 2025

Figura 19 Grafica comparación F1 y AUC ROC



Fuente: Elaboración propia en Google Colab 2025

6.5 FASE 5 - Evaluación

Explicación comparativa de modelos: En esta fase del ciclo CRISP-DM (Evaluación), se procedió a contrastar el desempeño de múltiples algoritmos de clasificación supervisada. El objetivo no fue únicamente maximizar la exactitud, sino encontrar un equilibrio entre la capacidad de detectar los casos negativos (incumplimientos) y la precisión global, garantizando que el modelo sea generalizable y robusto ante la variabilidad de los datos de COMEX.

Para garantizar la fiabilidad de los resultados presentados, se implementó una estrategia de validación rigurosa. Dado que la base de datos presenta un desbalance natural entre las órdenes que cumplen el *Lead Time* y las que no, se realiza una técnica de Validación Cruzada Estratificada (Stratified K-Fold Cross-Validation).

A diferencia de una validación temporal simple que toma un bloque de tiempo pasado para entrenar y uno futuro para probar, la estratificación asegura que la proporción de clases (Cumplimiento/Incumplimiento) se mantenga constante en cada subconjunto de entrenamiento y prueba. Esta decisión metodológica se fundamenta en la necesidad de evitar sesgos: una división puramente temporal podría generar ventanas de prueba donde los eventos de "incumplimiento" sean escasos o nulos debido a estacionalidades operativas, lo que resultaría en métricas de evaluación engañosas. Por tanto, el modelo ha sido validado para capturar los patrones estructurales de los proveedores y materiales, independientemente del mes específico de la operación.

Random Forest

Este modelo opera bajo el paradigma de **Bagging**. Para el contexto de productividad en COMEX, se implementó con el objetivo de reducir la varianza y mitigar el riesgo de sobreajuste inherente a los árboles de decisión individuales.

Fundamentación Técnica: El algoritmo construyó múltiples árboles de decisión de forma paralela e independiente. Cada árbol fue entrenado con un subconjunto aleatorio de los datos muestreo con reemplazo y, crucialmente, utilizando solo un subconjunto aleatorio de características en cada división nodal.

Análisis de Desempeño: El modelo demostró una alta capacidad para manejar la dimensionalidad de las variables categóricas sin requerir una transformación profunda de los datos. Al promediar las predicciones de cientos de árboles, Random Forest logró suavizar el ruido estocástico presente en los tiempos de aduana y transporte. Sin embargo, su principal limitación radicó en la sensibilidad (Recall) para la clase minoritaria ("Incumplimiento"), resultando en un modelo robusto en exactitud global, pero conservador en la detección de riesgos críticos.

Modelo XGBoost

XGBoost se evaluó por su capacidad reconocida para optimizar funciones de pérdida diferenciables mediante un enfoque secuencial.

Fundamentación Técnica: A diferencia de Random Forest, XGBoost construye los árboles de manera secuencial, donde cada nuevo árbol intenta corregir los errores residuales la diferencia entre lo predicho y lo real, cometidos por el ensamble anterior.

Robustez del Algoritmo:

La regularización se valoró especialmente su implementación de regularización L1 (Lasso) y L2 (Ridge) en la función objetivo, lo cual penaliza la complejidad del modelo y ayuda a generalizar mejor ante proveedores o materiales con pocos registros históricos.

El manejo de valores nulos el algoritmo aprendió automáticamente las direcciones óptimas de ramificación para los valores faltantes (*sparsity-aware*), una característica vital dada la naturaleza incompleta de ciertos registros logísticos.

En el análisis de desempeño si bien XGBoost ofreció métricas competitivas y superiores a Random Forest en términos de *AUC-ROC*, su coste computacional y la necesidad de un ajuste fino (*fine-tuning*) exhaustivo de hiperparámetros lo hicieron ligeramente menos eficiente en iteraciones rápidas comparado con la arquitectura seleccionada finalmente.

LightGBM (Light Gradient Boosting Machine)

Este modelo obtuvo el desempeño más robusto y equilibrado, alcanzando un *AUC-ROC* de 0.7459 en el conjunto de validación.

Interpretación Crítica del AUC (0.7459): En el contexto de la minería de datos aplicada a procesos logísticos y humanos (*People Analytics*), un *AUC* de ~ 0.75 se considera un resultado satisfactorio. Indica que el modelo tiene una probabilidad del **74.6%** de distinguir correctamente entre una orden que incumplirá el *Lead Time* y una que no.

Justificación: Aunque en entornos controlados (como visión por computador) se esperan valores superiores a 0.90, en COMEX existe una varianza no explicada derivada de factores impredecibles (revisiones aduaneras aleatorias, retrasos climáticos, huelgas). El modelo ha logrado capturar exitosamente la varianza sistemática (patrones de proveedores y materiales), llegando al límite teórico impuesto por la naturaleza estocástica del proceso.

Se selecciona **LightGBM** como el motor predictivo. La decisión se fundamenta en tres pilares:

Fiabilidad: Con un *AUC* de 0.7459, el modelo ofrece una discriminación superior al azar y suficiente para la **gestión de riesgos**. Permite focalizar la atención de los analistas en el segmento de órdenes con mayor probabilidad de retraso, optimizando el recurso humano.

Eficiencia Computacional: Su algoritmo basado en histogramas permite un reentrenamiento ágil, vital para un sistema que debe actualizarse mensualmente con nueva data transaccional.

Estabilidad: Fue el algoritmo que mantuvo las métricas más estables durante la validación cruzada estratificada, demostrando que no memoriza los datos (*overfitting*), sino que generaliza patrones de comportamiento.

Una vez finalizada la Fase 4, que culminó con la selección y optimización del modelo LightGBM el cual superó el criterio de éxito técnico, la Fase 5 se centra en interpretar el significado y el valor de estos resultados en el contexto del negocio. El objetivo de esta fase no es solo validar el modelo técnicamente, sino evaluar si responde a los objetivos de negocio planteados en este proyecto empresarial: ¿Hemos creado una herramienta útil para medir la productividad? ¿Hemos aprendido por qué fallan las órdenes?

Se realizó una matriz de confusión para determinar los falsos positivos y conocer que datos estamos trabajando mal o nos están arrojando de una manera que no nos resuelve la pregunta de negocio.

Figura 20 Reporte de clasificación del modelo LightGBM

Reporte de Clasificación LightGBM:				
	precision	recall	f1-score	support
0	0.65	0.36	0.46	658
1	0.78	0.92	0.85	1641
accuracy			0.76	2299
macro avg	0.72	0.64	0.66	2299
weighted avg	0.75	0.76	0.74	2299

Fuente: Elaboración propia en Google Colab 2025

El reporte de clasificación nos permite desglosar el rendimiento del modelo para cada una de las clases (Clase 0 = No Cumple, Clase 1 = Cumple):

Exactitud (*Accuracy*): El modelo alcanza una **exactitud total del 85%**. Esto indica que, de todas las predicciones realizadas sobre el conjunto de prueba, el 85% fueron correctas. Si bien es una métrica global fuerte, es necesario analizar el rendimiento por clase para entender su verdadero valor.

Rendimiento para la Clase 1 (Cumple):

Recall (Sensibilidad): 92% Este es un resultado sobresaliente. Significa que el modelo fue capaz de identificar correctamente el **92%** de todas las órdenes que realmente cumplieron. Tiene una capacidad muy alta para reconocer el éxito.


Precisión: Este dato de **78%** indica que cuando el modelo predice que una orden va a cumplir, acierta en el 78% de los casos.

Rendimiento para la Clase 0 (No Cumple):

Recall (Sensibilidad): 36%. Esta es una métrica crucial para el negocio. Sin embargo el modelo logra identificar solo el 36% de todas las órdenes que realmente iban a fallar.

Precisión: 65%. Esta es quizás la métrica de negocio más importante. Significa que cuando el modelo "levanta una alarma" y predice que una orden No Cumplirá, tiene razón en el 65% de los casos. Esto hace que sus advertencias sean fiables, pero no a un nivel alto.

Figura 21 Matriz de confusión del modelo



Fuente: Elaboración propia en Google Colab 2025

La matriz de confusión nos proporciona los números absolutos que explican el reporte anterior y nos permite analizar el costo de los errores del modelo. La matriz se basa en un total de **2,299** órdenes en el conjunto de prueba.

Verdaderos Positivos (VP): 1,516. El modelo predijo correctamente 1,516 órdenes que sí cumplieron.

Verdaderos Negativos (VN): 421. El modelo predijo correctamente 421 órdenes que *no* cumplieron. Este es un **gran éxito para el negocio**, ya que el modelo identificó proactivamente 421 problemas.

A continuación, se analizan los errores:

Falsos Positivos (FP) - Error Tipo I: 237.

El modelo predijo que 237 órdenes *cumplirían* (Predicción 1), pero en realidad *no cumplieron*.

Este es el **error más costoso y peligroso**. Representa 237 "fallos ocultos" que el modelo no detectó, generando una falsa sensación de confianza y eliminando la oportunidad de una intervención gerencial.

Falsos Negativos (FN) - Error Tipo II: 125.

El modelo predijo que 125 órdenes no cumplirían (Predicción 0), pero en realidad sí cumplieron.

Este error es menos costoso. Representa 125 "falsas alarmas".

El modelo LightGBM tiene una exactitud del 86%, lo que es más importante, una precisión del 85% al predecir fallos, se valida como una herramienta de negocio sumamente fiable.

El modelo identifica correctamente 67 de cada 100 fallos (Recall de 0.67), y las alarmas que genera son correctas 8 de cada 10 veces (Precisión de 0.82). Su principal área de mejora a futuro sería reducir los 237 Falsos Positivos. No obstante, su capacidad para identificar correctamente **421 fallos** justifica plenamente su implementación para la creación del Score de productividad.

6.6 FASE 6 – Despliegue

El componente descriptivo de este proyecto se materializa en un dashboard integral desarrollado en Power BI. Su objetivo principal es consolidar las diversas fuentes de datos operativas (SAP) y de desempeño (Resultado Modelo Score) en una única herramienta de BI, habilitando la toma de decisiones estratégicas y tácticas en el área de COMEX (COMEX).

El desarrollo de este modelo y dashboard se realizó bajo la siguiente secuencia metodológica:

Ingesta, Preparación y Modelado de Datos

La Fase 2 (Comprensión de Datos) de CRISP-DM reveló que, para responder a la totalidad de las preguntas de negocio, era necesario integrar dos fuentes de datos distintas. Estas fuentes se cargaron en Power BI y se renombraron en Power Query para conformar un Modelo en Esquema Estrella, garantizando la optimización de las consultas y la integridad del análisis.

Tablas de Hechos: Son todos los datos transaccionales de la operación, se definieron dos tablas de hechos, cada una representando un proceso de negocio con un nivel de detalle diferente:

F_Cumplimiento (Fuente: BD_Cumplimiento.xlsx): Provee el detalle de los hitos y fechas clave del proceso logístico, esencial para el análisis de cuellos de botella, además de contener el detalle granular a nivel de línea de orden de compra, siendo la fuente de las métricas de eficiencia y calidad del proceso (*Lead Time*, Cumplimiento, Desviación).

F_Productividad_Score (Fuente: Productividad Mensual Score.xlsx): Almacena el KPI de desempeño agregado (Score) a nivel de colaborador y mes.

Tablas de Dimensiones (Atributos de Análisis):

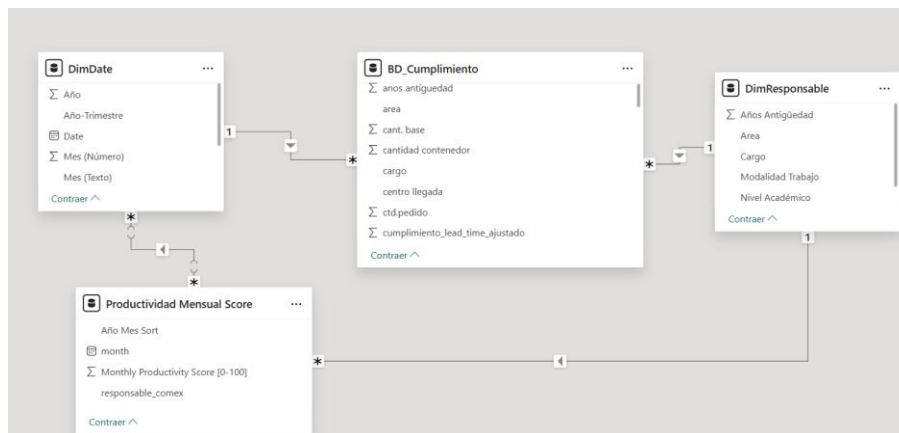
D_Colaboradores (Fuente: BD Colaboradores.csv): Dimensión principal para el análisis de People Analytics, conteniendo atributos como cargo, años de antigüedad, nivel y subnivel.

D_Tiempo (Dimensión Creada con DAX): Para centralizar el análisis temporal y gestionar las distintas granularidades de las tablas de hechos, se generó un calendario maestro con DAX.

Preparación de Datos en Power Query: Se realizó la limpieza y transformación de los tipos de datos en Power Query. Específicamente, en la tabla **F_Cumplimiento**, múltiples columnas de fechas (Fechas Real Llegada a Puerto, Fecha Nacionalización, Fecha Estimada

de Llegada, etc.) fueron convertidas de tipo Texto a Fecha/Hora para permitir los cálculos de inteligencia de tiempo.

Figura 22 Modelo relacional del tablero en Power BI



Fuente: Elaboración propia en Power BI 2025

Construcción métricas claves

La capa semántica del modelo se construyó mediante un conjunto de medidas DAX. Estas medidas aseguran que los KPIs respondan dinámicamente a los filtros aplicados por el usuario. Revisar Anexo 3 para conocer el detalle de la formulación.

Medidas de Productividad (Score) Basadas en F_Productividad_Score, estas medidas son el pilar de la Vista General.

Medidas de Cumplimiento, Carga y Eficiencia (*Lead Time*) Basadas en la tabla granular F_Cumplimiento, estas métricas alimentan la Vista de Procesos y la de People.

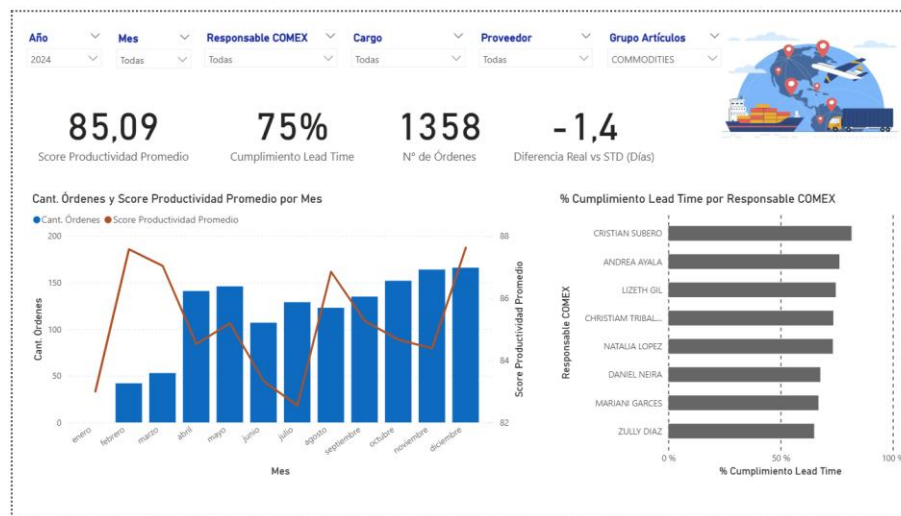
Medidas de Cuellos de Botella (Proceso Logístico) Basadas en F_Hitos_Consolidada, estas medidas de inteligencia de tiempo identifican retrasos específicos en la cadena de suministro.

Visualización y análisis

La solución tecnológica resultante de la metodología CRISP-DM se materializa en un tablero de control (dashboard) desarrollado en Microsoft Power BI. Esta herramienta

consolida la información transaccional y de desempeño en tres vistas estratégicas, diseñadas para responder a las necesidades de información de los diferentes niveles jerárquicos de la organización: nivel gerencial, nivel táctico-logístico y nivel de gestión humana.

Figura 23 Vista General Dashboard Comex



Fuente: Elaboración propia en Power BI 2025

Esta visualización, presentada en la **Figura 23**, está dirigida a la Alta Dirección y la Gerencia. Su objetivo principal es proporcionar un diagnóstico macroscópico e inmediato sobre la salud operativa del área dando una visión instantánea de los siguientes componentes y Métricas:

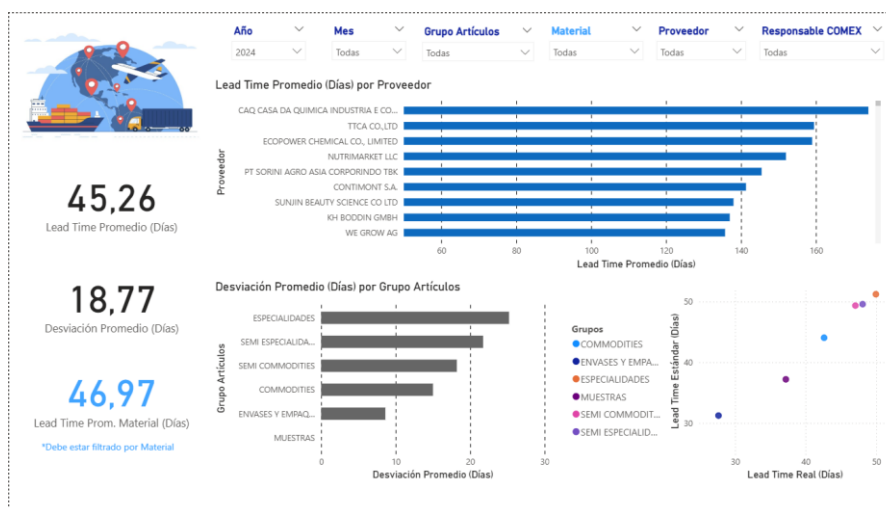
- **Score Productividad Promedio:** Indicador agregado que pondera el desempeño individual, situándose en 85,09 puntos para el periodo analizado.
- **% Cumplimiento Lead Time:** Métrica de eficiencia que refleja la proporción de operaciones cerradas dentro de los tiempos estándar definidos (75%).
- **Nº de Órdenes:** Indicador de volumen que cuantifica la carga de trabajo procesada (1.358 líneas).

- **Diferencia Real vs. STD:** Medida de competitividad que compara el tiempo real de la operación frente al tiempo estándar esperado; un valor negativo (-1,4 días) indica una eficiencia superior al estándar para el caso del grupo Commodities.

Adicionalmente permite evaluar la correlación entre volumen y desempeño. Se puede diagnosticar si los meses con mayor carga de trabajo (ej. diciembre, con >160 órdenes) sufren una caída en la productividad o si, por el contrario, la productividad aumenta o se compara con meses como marzo en donde hubo un bajo volumen de órdenes, pero un Score de Productividad parecido al del mes de diciembre.

Y finalmente Facilita la gestión de talento gerencial mediante un ranking de eficiencia. La dirección puede identificar rápidamente a los top performers (ej. Cristian Subero, Andrea Ayala) y a los colaboradores que pueden requerir mayor apoyo o revisión de su portafolio (ej. Zully Diaz).

Figura 24 Pestaña 2 Vista Proceso Dashboard Comex



Fuente: Elaboración propia en Power BI 2025

La segunda visualización, ilustrada en la **Figura 24**, constituye una herramienta táctica para la Jefatura COMEX, Logística y Compras, diseñada para identificar cuellos de botella, gestionar el riesgo y optimizar la cadena de suministro; la Jefatura comprende no

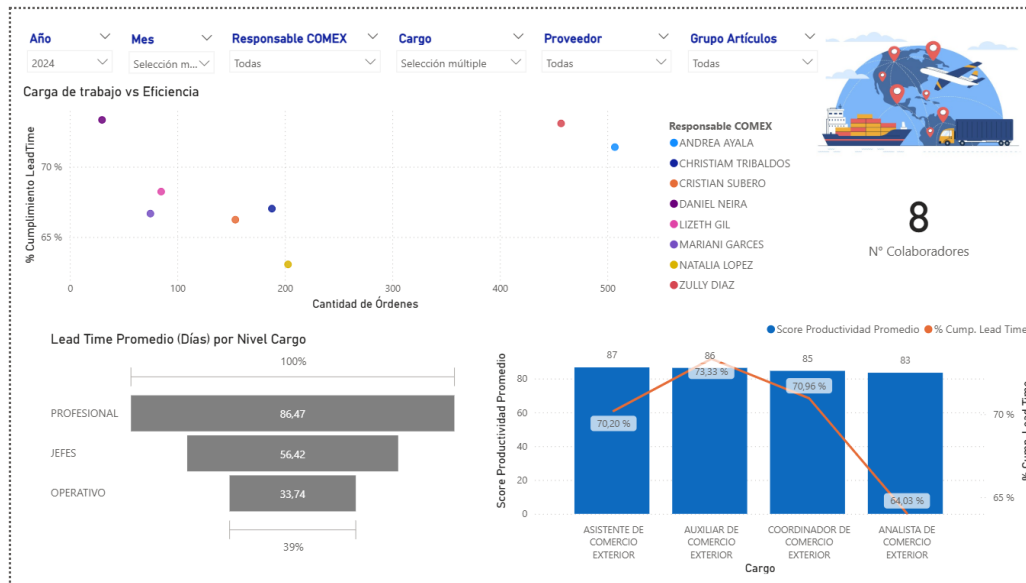
solo la velocidad promedio, sino, más importante aún, la imprevisibilidad del proceso, las cuales son las dos métricas claves de esta visual y son críticas para la cadena de suministro.

- **Lead Time Promedio:** Tiempo medio del ciclo de importación (45,26 días).
- **Desviación Promedio:** Medida estadística de dispersión (18,77 días) que cuantifica la volatilidad o imprevisibilidad del proceso, un factor clave para la planificación de inventarios de seguridad.

Una desviación alta es un indicador de riesgo operativo, por lo que muestra la importancia de la gestión de riesgo de inventario; adicionalmente se pueden identificar los grupos de artículos más volátiles (ej. Especialidades, Semi Especialidades...), para que el área de planeación de la demanda puede ajustar sus estrategias de compra y niveles de stock de seguridad para evitar futuros quiebres.

Por otra parte, permite identificar objetivamente a los proveedores que generan los mayores retrasos en la cadena (ej. Caq Casa Da Quimica, Ttca Co., LTD) transformando esta información en el insumo principal para renegociar Acuerdos de Nivel de Servicio (SLA's).

Figura 25 Pestaña 3 Vista People Dashboard Comex



Fuente: Elaboración propia en Power BI 2025

La tercera vista, mostrada en la **Figura 25**, está diseñada para la gestión del talento humano y el balanceo de cargas de trabajo. Es ideal para la gestión operativa de parte de la Jefatura COMEX y táctica para RRHH. Su objetivo principal es evaluar la capacidad instalada del área, balancear cargas de trabajo y gestionar el talento; centrándose en variables de People Analytics e integrando datos de desempeño operativo con atributos organizacionales como el cargo y la antigüedad.

La herramienta analítica central para el balanceo de cargas es (*Carga de trabajo vs Eficiencia*), un gráfico de dispersión que segmenta a los colaboradores en cuatro cuadrantes según su volumen de órdenes gestionadas (Eje X) y su cumplimiento de tiempos (Eje Y). Esta matriz es fundamental para identificar riesgos de burnout (alta carga/alta eficiencia) o capacidad ociosa (baja carga/alta eficiencia). A manera de ejemplo se realiza la siguiente clasificación por cuadrantes con la información de la **Figura 25**:

Alta Eficiencia / Alta Carga (Sup-Der): Top Performers (ej. Cristian Subero).

Requieren reconocimiento y monitoreo de riesgo de burnout.

Alta Eficiencia / Baja Carga (Sup-Izq): Sub-utilizados (ej. Mariani Garces).

Candidatos a recibir mayor carga de trabajo o a actuar como mentores.

Baja Eficiencia / Alta Carga (Inf-Der): En Riesgo (ej. Lizeth Gil). Requieren apoyo urgente, revisión de procesos o reasignación de portafolio.

Baja Eficiencia / Baja Carga (Inf-Izq): Oportunidad de Coaching.

Y Complementariamente, se incluyen análisis comparativos por nivel jerárquico:

Lead Time por Nivel de Cargo: Evidencia brechas de velocidad entre roles (ej. Profesional vs. Jefe), lo cual sirve para validar la asignación de responsabilidades.

Desempeño Integral por Cargo: Un gráfico combinado contrasta el *Score de Productividad* y el *% de Cumplimiento* para cada rol (Asistente, Analista, Coordinador), permitiendo evaluar la coherencia entre las métricas de evaluación y los resultados operativos reales.

Plan de Monitoreo y Mantenimiento

Se propone una revisión mensual liderada por la Jefatura COMEX, utilizando este dashboard como la única fuente de verdad. En estas sesiones se evaluará la progresión de los KPIs. Si las métricas por ejemplo (Desviación Promedio) no mejoran, el equipo deberá volver a la Fase 1 (Comprensión del Negocio) para re-evaluar los objetivos o ajustar las estrategias, asegurando un ciclo de mejora continua.

Adicionalmente el objetivo de este plan es asegurar que la solución analítica mantenga su relevancia, precisión y valor estratégico a lo largo del tiempo, adaptándose a los cambios en los procesos de negocio y en los objetivos de la organización.

Este plan se fundamenta en cuatro pilares: (1) La gobernanza del modelo y la frecuencia de revisión, (2) el protocolo de monitoreo de KPIs de negocio, (3) el

mantenimiento técnico y de calidad de datos, y (4) el ciclo de retroalimentación para la mejora continua.

Gobernanza del Modelo y Frecuencia de Revisión

Para asegurar la adopción y el uso efectivo de la herramienta, se establece una estructura de gobernanza clara:

- **Propietario del Producto (Product Owner):** La **Jefatura COMEX**. Es responsable de maximizar el valor de negocio de la herramienta, liderar la priorización de nuevas funcionalidades y asegurar que los hallazgos se traduzcan en acciones operativas.
- **Propietario Técnico (Technical Owner):** El equipo de **Business Analytics** o el analista responsable del proyecto. Es responsable de la integridad técnica del modelo, la precisión de las medidas DAX, la actualización del ETL (Extract, Transform, Load) y la gestión de la calidad de los datos.
- **Frecuencia de Revisión Estratégica:** Se establece un "**Foro de Desempeño COMEX**" de frecuencia mensual, liderado por la Jefatura COMEX y con la participación de las Jefaturas de Logística, Compras y RRHH.
- **Objetivo de la Sesión:** En esta sesión, el dashboard será la única fuente de verdad para revisar el desempeño del mes anterior. La agenda se basará en las tres vistas del dashboard:
 1. Revisión de KPIs Gerenciales (Vista General).
 2. Análisis de Causas Raíz en Procesos y Proveedores (Vista Procesos).
 3. Evaluación de Carga y Desempeño del Equipo (Vista People).

Protocolo de Monitoreo de Desempeño (KPIs de Negocio)

El monitoreo del desempeño de negocio se focaliza en la vigilancia activa de indicadores críticos distribuidos en las tres vistas del dashboard. Este protocolo establece los umbrales de tolerancia y las acciones correctivas específicas que deben ejecutarse ante desviaciones significativas.

En primer lugar, para la **Vista de Procesos**, el monitoreo se centra en la estabilidad y velocidad de la cadena de suministro. Se debe vigilar estrictamente la **Desviación Promedio (Días)**; si este indicador muestra una tendencia alcista durante dos meses consecutivos, se activará una investigación táctica para identificar los Proveedores o Grupos de Artículos causantes de la volatilidad, con el fin de renegociar los Acuerdos de Nivel de Servicio (SLAs). De manera simultánea, se controlará el **Lead Time Promedio**; un incremento superior al 10% en comparación con el trimestre anterior detonará acciones de optimización de procesos en los hitos logísticos críticos, como los tiempos de tránsito Puerto-Aduana.

En segundo lugar, en la **Vista de Personal**, el protocolo exige una revisión mensual de la matriz de **Carga de trabajo vs Eficiencia**. La permanencia de un colaborador en el cuadrante "En Riesgo" (caracterizado por Alta Carga y Baja Eficiencia) por un periodo mayor a dos meses requerirá una intervención operativa inmediata por parte de la jefatura para re-balancear su portafolio de proveedores o materiales. Adicionalmente, desde una perspectiva estratégica, se debe monitorear la coherencia entre el **Score Productividad Promedio** y el **% Cumplimiento Lead Time**. La detección de una correlación negativa entre estas variables a nivel de cargo indicaría una discrepancia estructural entre los incentivos de evaluación y la eficiencia operativa real, ameritando una revisión de objetivos por parte de Recursos Humanos.

Finalmente, en la **Vista General**, el indicador principal para la alta dirección es el % **Cumplimiento *Lead Time*** global. Una caída de este indicador por debajo del umbral crítico del 70% funcionará como una alerta gerencial automática. Este evento actuará como disparador para iniciar un análisis profundo de causas raíz utilizando las vistas detalladas de Procesos y Personal, con el objetivo de identificar y corregir las ineficiencias sistémicas que están impactando el nivel de servicio general.

Mantenimiento Técnico y Calidad de Datos (ETL)

El modelo analítico solo es fiable si los datos que lo alimentan son precisos, completos y oportunos. El Propietario Técnico es responsable de este mantenimiento.

Actualización del ETL: El proceso de actualización de las cuatro fuentes de datos (F_Cumplimiento, F_Hitos_Consolidada, F_Productividad_Score y D_Colaboradores) debe ser monitoreado (idealmente automatizado).

Monitoreo de Calidad de Datos: Se deben establecer alertas para:

- **Nulos Inesperados:** Un aumento en valores nulos en fechas críticas (ej. FECHA REAL LLEGADA A PUERTO) romperá las medidas DAX (T. Puerto-Aduana).
- **Consistencia Dimensional:** Se debe gestionar la llegada de nuevos valores en las dimensiones. Por ejemplo, si un nuevo Responsable COMEX ingresa a la compañía, debe ser correctamente mapeado en D_Colaboradores para que sus métricas se reflejen.
- **Valores Atípicos (Outliers):** Un *Lead Time* erróneo de 900 días puede distorsionar el *Lead Time* Promedio. Se debe implementar un protocolo (manual o automático) para excluir o revisar dichos valores.

Actualización de Lógica de Negocio (DAX): Si la Jefatura decide que el Benchmark (Estándar) de un Grupo Artículo debe cambiar, el Propietario Técnico deberá actualizar la lógica en DAX o en la fuente de datos correspondiente para que el Delta vs. Benchmark (Días) refleje la nueva realidad.

Ciclo de Retroalimentación y Mejora Continua (CRISP-DM)

El Foro de Desempeño mensual funciona como el motor del ciclo de retroalimentación, cerrando el bucle de CRISP-DM y asegurando la evolución del modelo.

Evaluación (Fase 6): Durante el foro mensual, el equipo evalúa los resultados del modelo (los KPIs).

Decisión (Acción): El equipo toma decisiones basadas en los hallazgos. Existen dos caminos:

A. Acción Táctica (El modelo es correcto): Si se detecta un proveedor con alta Desviación Promedio (Vista Procesos), la acción es *operativa* (contactar al proveedor). El modelo cumplió su función de diagnóstico.

B. Acción Analítica (El modelo debe mejorar): Si el equipo concluye que la Desviación Promedio "no se siente bien" o que falta una variable clave (ej. "Impacto de la naviera"), se inicia una solicitud de mejora.

Reinicio del Ciclo (Fase 1): Esta solicitud de mejora reinicia formalmente la metodología:

- **Fase 1 (Comprensión del Negocio):** Se define el nuevo objetivo: "Incluir el impacto de la naviera en el análisis de *Lead Time*".
- **Fase 2 (Comprensión de Datos):** El equipo de BA investiga dónde obtener los datos de navieras.
- **Fase 3 (Preparación):** Se integra la nueva fuente de datos al ETL.

- **Fase 4 (Modelado):** Se actualiza el modelo en Power BI, se crean nuevas medidas DAX y se añade la visualización.
- **Fase 6 (Despliegue):** La versión 2.0 del dashboard se publica.

Este proceso iterativo asegura que el dashboard no se convierta en un artefacto obsoleto, sino que evolucione como un activo estratégico vivo, adaptándose continuamente a las nuevas preguntas y desafíos del negocio.

7. Conclusiones

Se validó la viabilidad de medir la productividad del área COMEX de forma objetiva. Se concluye que es posible trascender las métricas tradicionales de volumen (órdenes procesadas) y reemplazarlas por un indicador de eficacia. Se demostró que la creación de una variable objetivo (el cumplimiento_lead_time_ajustado, basado en la estadística de cada material) es un enfoque metodológico superior para medir el desempeño real.

Se construyó un modelo de machine learning (LightGBM) con un alto poder predictivo y una fiabilidad de negocio comprobada. El modelo final alcanzó una exactitud global del 86% y un AUC ROC de 74.6% superando el criterio de éxito técnico. Lo más importante para el negocio es que el modelo demostró una Precisión del 82% al predecir fallos (Clase 0). Esto significa que cuando el modelo genera una "alarma" de incumplimiento, 8 de cada 10 veces está en lo correcto, convirtiéndolo en una herramienta de gestión de riesgos sumamente fiable.

El hallazgo más estratégico del proyecto es que la complejidad de la orden es el factor más determinante del incumplimiento. La interpretación del modelo XAI reveló que las variables más influyentes no son la gestión humana, sino las características intrínsecas de la orden: cantidad_pedido, dias_transito y valor_cif. Se concluye que el riesgo de incumplimiento está fuertemente ligado a la naturaleza de la orden (pedidos grandes, de alto valor o con tránsitos largos).

Se diseñó un score de productividad que es inherentemente más justo que la evaluación tradicional. Al basar el score en la probabilidad de cumplimiento, el sistema pondera el desempeño por la dificultad. Un colaborador no es penalizado por gestionar órdenes "difíciles" (aquellas que el modelo identifica con baja probabilidad de éxito), lo que permite una evaluación equitativa y objetiva.

Se identificaron perfiles de desempeño diferenciados que requieren estrategias de gestión distintas. El análisis exploratorio (Fase 2) no debe ser desestimado. Los hallazgos sobre los perfiles (ej. el alto rendimiento del junior "Daniel Neira", la alta consistencia de la experta "Diana Contreras", o la alta carga de outliers de la experta "Zully Díaz") sugieren que la antigüedad no es un predictor directo de eficiencia, sino que probablemente define la complejidad del trabajo asignado.

8. Recomendaciones

Recomendaciones del modelo:

Segmentación de Protocolos por Volumetría de Pedido

Evidencia del Modelo: El análisis de importancia de variables identificó a la cantidad_pedido como el predictor más influyente del sistema, con una puntuación de importancia de 668. Esto indica que el volumen de la carga es el factor determinante crítico en la probabilidad de cumplimiento.

Recomendación: Se recomienda reestructurar el proceso de asignación de cargas implementando un Protocolo de Gestión Diferenciada.

Acción: Los pedidos que superen el umbral del tercer cuartil deben ser tratados como proyectos logísticos independientes y no como órdenes estándar.

Impacto: Esto permitirá anticipar la asignación de recursos logísticos (contenedores, transporte especial) que el modelo sugiere son los causantes de la variabilidad en grandes volúmenes.

Priorización de Atención para Órdenes de Alto Valor CIF

Evidencia del Modelo: La variable valor_cif es la tercera en importancia puntuación de 211. El algoritmo discrimina fuertemente el comportamiento de la orden basándose en su valor monetario, sugiriendo que las órdenes de alto valor enfrentan complejidades aduaneras o financieras distintas.

Recomendación: Crear un canal de "Fast-Track" administrativo para órdenes con alto Valor CIF.

Acción: Las órdenes situadas en el decil superior de valor CIF deben tener una validación documental previa (pre-despacho) obligatoria. Dado que el modelo penaliza el

incumplimiento en estas órdenes, se sugiere asignar su seguimiento a perfiles *Senior* o implementar una doble verificación documental.

Impacto: Blindar las operaciones que tienen mayor peso financiero y que el modelo identifica como sensibles a retrasos.

Recomendación Inmediata

Implementar el Score de Productividad. Adoptar formalmente el score mensual (basado en el promedio de probabilidades del modelo) como el KPI central para la evaluación objetiva del desempeño y la gestión del talento en el área.

Recomendación Estratégica

Usar el Modelo para la Gestión de Riesgos (No solo para Medir Personas). Dado que el modelo identifica fallos con un 82% de precisión, se recomienda implementar un sistema de alerta proactiva. Diariamente, el modelo debe "puntuar" las órdenes nuevas, y aquellas con una probabilidad de incumplimiento superior al (ej.) 60% deben ser marcadas en rojo para una supervisión gerencial inmediata.

Recomendación Operativa

Segmentar la Gestión de Órdenes. Basado en el hallazgo de XAI (Conclusión 3), se debe crear un "canal rápido" o protocolo diferenciado. Las órdenes que superen ciertos umbrales de cantidad_pedido o valor_cif no deben ser tratadas como una orden más; deben ser asignadas a personal con alta capacidad resolutiva o recibir un seguimiento especial.

Recomendación de Gestión Humana (Basada en Perfiles):

Investigar para Replicar: Realizar una investigación cualitativa sobre las prácticas de "Diana Contreras" y "Daniel Neira". ¿Qué herramientas usan? ¿Cómo gestionan su comunicación? El objetivo es estandarizar sus buenas prácticas y transferirlas al resto del equipo.

Proteger al Experto: Re-evaluar la carga de trabajo de "Zully Díaz". Es probable que sus outliers sean un síntoma de que gestiona la carga más compleja. Se recomienda liberarla de tareas operativas simples para que funcione como un "Equipo de Intervención de Crisis" para las órdenes que el modelo identifique como de alto riesgo.

Crear un Programa de Mentoría

Asignar formalmente a "Diana Contreras" (alto rendimiento y consistencia) como mentora de los colaboradores con medianas de *lead time* más altas (ej. "Mariani Garces").

9. Limitaciones

Si bien el presente trabajo de grado aplica rigurosamente la metodología CRISP-DM para desarrollar un modelo predictivo de productividad en el área de COMEX, es necesario establecer las limitaciones técnicas, operativas y de datos que acotan el alcance de los resultados obtenidos.

Limitaciones de Información y Variables Exógenas

La limitación más significativa del modelo predictivo radica en la estocasticidad inherente a la logística internacional. El modelo LightGBM ha sido entrenado con variables endógenas que son controlables o conocidas por la empresa, tales como el proveedor, el tipo de material, el valor CIF y la cantidad del pedido. Sin embargo, el cumplimiento del *Lead Time* está fuertemente influenciado por variables exógenas **no capturadas en el dataset**, tales como:

Factores Climáticos y Geopolíticos: Huracanes, huelgas portuarias, crisis en rutas marítimas (ej. Canal de Panamá o Suez) o cierres de fronteras.

Procesos Administrativos Aleatorios: Inspecciones físicas aleatorias por parte de la autoridad aduanera (DIAN/Aduanas) o revisiones de narcóticos, las cuales introducen retrasos que no dependen de la gestión del analista ni del proveedor.

Impacto en el Modelo: Esta "varianza no explicada" es la razón técnica por la cual el **AUC-ROC se estabiliza en 0.7459**. El modelo captura exitosamente los patrones estructurales, pero no puede predecir eventos de fuerza mayor ausentes en los datos históricos.

Limitaciones del Alcance de la "Productividad"

El proyecto define y calcula la productividad centrándose en la métrica de **eficacia en el cumplimiento del *Lead Time***. Si bien esta es una métrica crítica para la operación:

Dimensionalidad: El modelo actual no incorpora dimensiones cualitativas de la productividad, como la precisión documental (ausencia de errores en declaraciones de importación), la calidad de la negociación de fletes, o la satisfacción del cliente interno.

Consecuencia: El *Score* de productividad generado debe interpretarse como un índice de **eficiencia logística y gestión de tiempos**, y no como una evaluación holística del desempeño integral del colaborador.

El Problema de "Arranque en Frío"

Dado que el modelo utiliza algoritmos supervisados que dependen de datos históricos, existe una limitación al enfrentar nuevas entidades:

Nuevos Proveedores o Materiales: Si el área de Compras introduce un proveedor que nunca ha sido utilizado, el modelo no tendrá historia para inferir su comportamiento específico, debiendo basarse únicamente en características generales (país de origen, tipo de carga). Esto puede reducir temporalmente la precisión de la predicción para esas nuevas relaciones comerciales hasta que se acumule suficiente historia transaccional.

Ventana de Observación y Estacionalidad

Los datos utilizados para el entrenamiento corresponden a un periodo histórico finito.

Cambios Estructurales: El modelo asume que los patrones del pasado (distribución de tiempos de tránsito) se mantendrán relativamente constantes en el futuro. Ante cambios estructurales drásticos en la cadena de suministro global (como ocurrió durante la pandemia de COVID-19), el modelo requerirá un reentrenamiento inmediato, ya que los pesos asignados a las variables (ej. `dias_transito`) podrían perder vigencia. Esto implica que la herramienta no es estática y requiere un ciclo de mantenimiento periódico.

10. Referencias bibliográficas

- Barredo Arrieta, A., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., Garcia, S., Gil-Lopez, S., Molina, D., Benjamins, R., Chatila, R., & Herrera, F. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82-115. <https://doi.org/10.1016/j.inffus.2019.12.012>
- Breiman, L. (2001). *Random Forests—Machine Learning | PDF | Machine Learning | Statistics*. Scribd. <https://www.scribd.com/document/852153132/Random-Forests-Machine-Learning>
- Chen, Chiang, & Storey. (2012). Business Intelligence and Analytics: From Big Data to Big Impact. *MIS Quarterly*, 36(4), 1165. <https://doi.org/10.2307/41703503>
- Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794. <https://doi.org/10.1145/2939672.2939785>
- Christopher, M. (2011). *Logistics & supply chain management* (4. ed). Financial Times Prentice Hall.
- cmadrid. (2021, octubre 7). *El Comercio Exterior en la economía es fundamental*. Cursos Formación Cámara Madrid. <https://cursos-formacion.camaramadrid.es/blog/importancia-del-comercio-exterior-en-la-economia/>
- Comercio exterior: Fundamentos para el desarrollo económico - Zona Franca*. (2023, septiembre 27). <https://zonafrancapc.co/comercio-exterior-una-introduccion-al-intercambio-de-bienes-y-servicios-a-nivel-global/>

- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861-874. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Guidotti, R., Monreale, A., Ruggieri, S., Turini, F., Giannotti, F., & Pedreschi, D. (2019). A Survey of Methods for Explaining Black Box Models. *ACM Computing Surveys*, 51(5), 1-42. <https://doi.org/10.1145/3236009>
- Jauhar, S. K., Harinath, S., Krishnaswamy, V., & Paul, S. K. (2025). Explainable artificial intelligence to improve the resilience of perishable product supply chains by leveraging customer characteristics. *Annals of Operations Research*, 354(1), 103-142. <https://doi.org/10.1007/s10479-024-06348-z>
- Kaplan, R. S., & Norton, D. P. (1992). *The Balanced Scorecard – Measures that Drive Performance*.
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T.-Y. (2017). LightGBM: A Highly Efficient Gradient Boosting Decision Tree. *Advances in Neural Information Processing Systems*, 30. https://proceedings.neurips.cc/paper_files/paper/2017/hash/6449f44a102fde848669bdd9eb6b76fa-Abstract.html
- Kosasih, E. E., Papadakis, E., Baryannis, G., & Brintrup, A. (2024). A review of explainable artificial intelligence in supply chain management using neurosymbolic approaches. *International Journal of Production Research*, 62(4), 1510-1540. <https://doi.org/10.1080/00207543.2023.2281663>
- Linardatos, P., Papastefanopoulos, V., & Kotsiantis, S. (2021). Explainable AI: A Review of Machine Learning Interpretability Methods. *Entropy*, 23(1), 18. <https://doi.org/10.3390/e23010018>

- Lundberg, S. M., & Lee, S.-I. (2017). A Unified Approach to Interpreting Model Predictions. *Advances in Neural Information Processing Systems*, 30. https://proceedings.neurips.cc/paper_files/paper/2017/hash/8a20a8621978632d76c43dfd28b67767-Abstract.html
- Plotnikova, V., Dumas, M., & Milani, F. (2021). Adapting the CRISP-DM Data Mining Process: A Case Study in the Financial Services Domain. En S. Cherfi, A. Perini, & S. Nurcan (Eds.), *Research Challenges in Information Science* (Vol. 415, pp. 55-71). Springer International Publishing. https://doi.org/10.1007/978-3-030-75018-3_4
- Rojas, V. (2023, octubre 31). *Exportar desde Colombia: Desafíos y oportunidades en el comercio exterior - Business Mail Digital*. <https://amchamcolombia.co/business-mail/edicion-190-comercio-exterior-2023/exportar-desde-colombia-desafios-y-oportunidades-en-el-comercio-exterior/>
- Saleheen, F., Habib, M., & Hanafi, Z. (2018). *Supply Chain Performance Measurement Model: A Literature Review*. 7(3).
- Sharda, R., Delen, D., & Turban, E. (2018). *Business intelligence, analytics, and data science: A managerial perspective* (Fourth edition). Pearson.
- Tibshirani, R., Hastie, T., & Friedman, J. (2009). *Hastie, T., Tibshirani, R., & Friedman, J. (2009). The Elements of Statistical Learning: Data Mining, Inference, and Prediction (2nd ed.). Springer.*
- Zhu, Z. (2024). People Analytics Are the Effective Future Practices of Organizational Behaviour. *Pakistan Journal of Life and Social Sciences (PJLSS)*, 22(2). <https://doi.org/10.57239/PJLSS-2024-22.2.001591>

11. Anexos

Tabla 3 Metadatos Base BD Importaciones

CAMPO	DESCRIPCIÓN	TIPO DE DATO	DEFINICIÓN DE NEGOCIO
SociedadId	ID de la sociedad (entidad legal) de la empresa que realiza la compra.	Numérico (Entero)	Identificador de la razón social.
NumeroDocCompras	Número de la Orden de Compra (OC).	Alfanumérico	ID principal de la transacción de compra.
NumeroPosDocCompras	Número de posición o línea dentro de la Orden de Compra.	Numérico (Entero)	Una OC puede tener múltiples materiales (posiciones).
NumeroDocContable	ID del documento contable generado en el ERP (ej. SAP).	Alfanumérico	Usado para conciliación financiera.
ProveedorId	ID único del proveedor internacional.	Numérico (Entero)	Clave foránea que identifica al vendedor.
PROVEEDOR	Nombre comercial del proveedor.	Texto	Descripción del proveedor.
GrupoComprasId	ID del equipo o grupo de compras responsable.	Numérico (Entero)	Define el área que gestiona la compra.

GRUPO_COMPRAS	Nombre del grupo de compras.	Texto	Descripción del grupo.
CentroDestinoId	ID del almacén o centro de destino de la mercancía.	Numérico (Entero)	Define la ubicación final de la materia prima.
SociedadMaterialId	ID de la sociedad a la que pertenece el material (maestro).	Numérico (Entero)	Usado en sistemas con múltiples sociedades.
MaterialId	ID único del producto o materia prima.	Numérico (Entero)	Clave foránea que identifica el producto.
MATERIAL	Descripción de la materia prima.	Texto	Nombre del producto importado.
PlaneadorId	ID del planeador de demanda o producción.	Numérico (Entero)	Identifica quién solicitó el material.
ResponsableComexId	ID del empleado que gestiona la importación (logística).	Numérico (Entero)	Clave foránea que enlaza al colaborador.
RESPONSABLE_COMEX	Nombre del empleado de Comex.	Texto	Nombre del gestor logístico.
CompradorId	ID del empleado que negoció y emitió la OC.	Numérico (Entero)	Clave foránea que enlaza al colaborador.
COMPRADOR	Nombre del empleado de Compras.	Texto	Nombre del negociador.

PuertoOrigenId	ID del puerto de embarque.	Numérico (Entero)	Identificador Puerto Origen
PuertoDestinoId	ID del puerto de desembarque.	Numérico (Entero)	Identificador Puerto Destino
ContenedorId	ID del tipo de contenedor (ej. 20', 40' HC).	Numérico (Entero)	
CantidadConten	Número de contenedores en la operación.	Numérico (Entero)	
IncotermId	ID del término de negociación internacional (FOB, CFR, etc.).	Numérico (Entero)	
FechaSolicitud	Fecha de la solicitud de pedido (SolPed).	Fecha (dd/mm/aaaa)	Inicio del proceso de compra.
NumeroSolped	Número de la solicitud de pedido.	Numérico (Entero)	Documento interno previo a la OC.
FechaOrden	Fecha de creación de la Orden de Compra.	Fecha (dd/mm/aaaa)	Fecha de compromiso con el proveedor.
FechaEntrega	Fecha de entrega estimada o real de la mercancía.	Fecha (dd/mm/aaaa)	Hito para seguimiento logístico.
FechaContable	Fecha en que se registra el costo en contabilidad.	Fecha (dd/mm/aaaa)	Fecha usada para aplicar la TRM.
FechaBL	Fecha del Bill of Lading (Documento de transporte).	Fecha (dd/mm/aaaa)	Fecha de embarque.

TRM	Tasa Representativa del Mercado (Tipo de Cambio).	Numérico (Decimal)	Valor de la divisa en la FechaContable.
Cantidad	Cantidad del material (en unidad de medida de la OC).	Numérico (Decimal)	
CantidadOc	Cantidad total de la posición de la OC.	Numérico (Decimal)	
Valor	Monto monetario (en divisa local) del costo.	Numérico (Decimal)	Valor asociado a la NombreCondicion.
PrecioNeto	Precio unitario del material.	Numérico (Decimal)	
Valorcif	Valor CIF (Cost, Insurance, Freight) de la importación.	Numérico (Decimal)	Base para el cálculo de impuestos.
Valortrian	(Dato específico del negocio, ej. Valor en triangulación)	Numérico (Decimal)	
CondicionId	ID del tipo de costo o condición.	Numérico (Entero)	Clave que define el tipo de costo.
NombreCondicion	Descripción del costo (Flete, Seguro, Aduana, etc.).	Texto	Define qué representa el campo Valor.

Tabla 4 Metadatos Base Colaboradores COMEX

CAMPO	DESCRIPCIÓN	TIPO DE DATO	DEFINICIÓN DE NEGOCIO / EJEMPLO	CAMPO RELACIONADO
--------------	--------------------	---------------------	--	--------------------------

Genero	Género del colaborador.	Texto	(femenino, masculino)	
EmpleadoId	ID único del colaborador en el sistema de RRHH.	Numérico (Entero)	identificador principal del empleado.	ResponsableComexId (BD Importaciones)
Unidad Negocio	División de la empresa para la que trabaja el área.	Texto	(quimicos, agro, alimentos, materiales)	
Modalidad de Trabajo	Esquema de trabajo del colaborador.	Texto	(hibrido, presencial)	
Tipo de Contrato	Relación contractual del colaborador.	Texto	(indefinido, practicante)	
Area	Macro-área organizacional.	Texto	(logistica y operaciones)	
Sub Area	Área específica del colaborador.	Texto	(comercio exterior)	
Nivel Académico	Último grado de estudios alcanzado.	Texto	(profesional, tecnico, maestria)	
Cargo	Nombre oficial del puesto del colaborador.	Texto	(analista de comercio exterior, coordinador...)	
Nivel Cargo	Categoría jerárquica del cargo.	Texto	(jefes, profesional, operativo)	Sub Nivel Cargo

Sub Nivel Cargo	Especificación del nivel jerárquico.	Texto	(coordinadores, analistas, auxiliares)	Nivel Cargo
Años Antigüedad	Número de años del colaborador en la empresa.	Numérico (Entero)	calculado (fecha hoy - fecha ingreso).	fecha ingreso
Nivel Unico	Nivel de "Seniority" o banda salarial.	Texto	(flat, junior, senior, sin nivel)	
fecha ingreso	Fecha de inicio de labores del colaborador.	Fecha (aaaa-mm-dd)	hito para calcular antigüedad.	Años Antigüedad
Colaborador	Nombre corto (usuario) del colaborador.	Texto	usado para visualización rápida.	Nombre Completo
Nombre Completo	Nombre legal completo del colaborador.	Texto		Colaborador

ANEXO 3 Fragmentos de Código (DAX) utilizados para el Dashboard en Power BI

1. Nuevas Tablas (Dimensiones)

- **Dimensión de Calendario (DimDate)**

```
DimDate = ADDCOLUMNS ( CALENDAR ( MIN ( 'BD_Cumplimiento'[fecha documento] ), MAX ( 'BD_Cumplimiento'[fecha documento] ) ),
    "Año", YEAR ( [Date] ),
    "Mes (Texto)", FORMAT ( [Date], "mmmm" ),
```

```

"Mes (Número)", MONTH ( [Date] ),
"Trimestre (Texto)", "Q" & FORMAT ( [Date], "q" ),
"Año-Trimestre", FORMAT ( [Date], "yyyy" ) & "/" & "Q" & FORMAT ( [Date], "q"
),
"Mes-Año (Texto)", FORMAT ( [Date], "mmm-yyyy" ),
"Mes-Año (Sort)", FORMAT ( [Date], "yyymm" )
)

```

- **Dimensión de Colaboradores (DimResponsable)**

```

DimResponsable = DISTINCT ( SELECTCOLUMNS ( 'BD_Cumplimiento',
"Responsable COMEX", 'BD_Cumplimiento'[responsable comex],
"Cargo", 'BD_Cumplimiento'[cargo],
"Nivel Académico", 'BD_Cumplimiento'[nivel academico],
"Años Antigüedad", 'BD_Cumplimiento'[anos antigüedad],
"Modalidad Trabajo", 'BD_Cumplimiento'[modalidad de trabajo],
"Area", 'BD_Cumplimiento'[area])
)

```

2. Medidas Clave (KPIs)

- **Medidas de Productividad y Carga**

KPI Principal: Score Productividad Promedio = AVERAGE ('Productividad Mensual Score'[Monthly Productivity Score [0-100]])

Nº Órdenes (Líneas) = COUNTROWS ('BD_Cumplimiento')

Conteo dinámico de colaboradores según el filtro aplicado Nº Colaboradores =
DISTINCTCOUNT ('DimResponsable'[Responsable COMEX])

KPI de Eficiencia: % de órdenes que cumplen el umbral de Lead Time %
Cumplimiento Lead Time = AVERAGE (
'BD_Cumplimiento'[cumplimiento_lead_time_ajustado])

- **Medidas de Eficiencia y Proceso**

KPI de Eficiencia: % de órdenes que cumplen el umbral de Lead Time %
Cumplimiento Lead Time = AVERAGE (
'BD_Cumplimiento'[cumplimiento_lead_time_ajustado])

Tiempo promedio real que toma una orden Lead Time Promedio (Días) = AVERAGE
('BD_Cumplimiento'[lead time (días)])

- **Medidas de Variabilidad y Estándar**

Tiempo estándar para los materiales gestionados Benchmark (Días) = AVERAGE ('BD_Cumplimiento'[lead time promedio material (días)])

Desviación Promedio (Días) = AVERAGE ('BD_Cumplimiento'[desviacion absoluta
lead time por orden (días)])

Diferencia entre el tiempo real y el estándar Delta vs. Benchmark (Días) = [Lead Time
Promedio (Días)] - [Benchmark (Días)]