



**ALGORITMO COMPUTACIONAL PARA EL ANÁLISIS Y TOMA DE DECISIONES  
EN COMPRAS DE INGREDIENTES E INSUMOS PARA PRODUCTO TERMINADO  
UTILIZANDO ESTRATEGIAS DE MACHINE LEARNING**

**Corporación Universitaria Remington.  
facultad de Ingenierías  
Ingeniería Industrial**

**Estudiantes:  
Luis Carlos Benavides Garzón  
Tutor: Juan Carlos Briñez de León  
Opción de Trabajo de grado Seminario-Diplomado.  
2024.**

<b>Contenido</b>	2
Resumen.....	3
Palabras clave.....	3
Marco conceptual y contextual .....	4
Marco Conceptual:.....	4
Marco Contextual: .....	5
Contexto de la Industria:.....	5
Tecnologías y Estrategias Utilizadas: .....	5
Pregunta problema .....	6
Descripción de variables .....	6
Objetivos.....	12
Objetivo general:.....	12
Objetivos Específicos: .....	12
Desarrollo e implementación del aprendizaje.....	13
Preparación de los datos.....	14
Modelo de toma de decisiones .....	16
Validación del modelo .....	16
Conclusiones y trabajos futuros .....	21
Conclusiones: .....	21
Trabajos Futuros: .....	22

## Resumen

Este trabajo final se centra en el desarrollo de un algoritmo computacional que emplea técnicas de Machine Learning para optimizar el proceso de compra de ingredientes e insumos necesarios para la producción de productos terminados. El objetivo principal es mejorar la eficiencia y la precisión en la toma de decisiones relacionadas con las compras, asegurando así una gestión de inventarios más efectiva y una reducción de costos.

### Palabras clave

- Machine Learning
- Optimización de compras
- Modelado predictivo
- Gestión de inventarios
- Algoritmos computacionales
- Análisis de datos
- Predicción de demanda
- Reducción de costos
- Industria alimentaria
- Aceites vegetales
- Margarinas vegetales
- Sistema de soporte a la decisión (DSS)

- Regresión lineal
- Redes neuronales
- Modelos de árboles de decisión
- Precios de insumos
- Demanda fluctuante
- Volatilidad de precios
- Competencia en la industria alimentaria

### **Marco conceptual y contextual**

#### **Marco Conceptual:**

**Algoritmos de Machine Learning:** Métodos de aprendizaje automático que permiten a las computadoras aprender y hacer predicciones basadas en datos. Ejemplos incluyen la regresión lineal, redes neuronales y modelos de árboles de decisión.

**Optimización de Compras:** Proceso de mejorar la eficiencia y efectividad de las decisiones de compra para maximizar el valor y reducir costos.

**Modelado Predictivo:** Uso de datos históricos para crear modelos que puedan predecir resultados futuros, como la demanda de productos y los precios de los insumos.

**Gestión de Inventarios:** Administración del stock de productos e insumos para asegurar la disponibilidad de materiales necesarios sin incurrir en excesos costosos.

**Marco Contextual:**

La compañía produce aceite y margarinas vegetales para consumo humano, productos que requieren una gestión rigurosa de insumos como aceites vegetales, aditivos, empaques y otros ingredientes. La demanda de estos productos puede fluctuar debido a factores estacionales, tendencias de consumo y precios de mercado, lo cual hace esencial la implementación de un sistema avanzado de toma de decisiones que minimice costos y optimice el inventario.

**Contexto de la Industria:**

**Demanda Fluctuante:** La demanda de aceite y margarinas puede variar significativamente debido a cambios estacionales, promociones y tendencias de consumo saludable.

**Volatilidad de Precios:** Los precios de los ingredientes, especialmente los aceites vegetales, pueden ser volátiles debido a factores como las condiciones climáticas y las políticas comerciales internacionales.

**Competencia Intensa:** La industria alimentaria es altamente competitiva, requiriendo una gestión eficiente de los costos para mantener márgenes de beneficio saludables.

**Tecnologías y Estrategias Utilizadas:**

**Análisis de Datos:** Recopilación y análisis de datos históricos de compras, consumo y precios.

**Machine Learning:** Implementación de algoritmos para predecir la demanda y optimizar las compras.

**Sistema de Soporte a la Decisión (DSS):** Plataforma tecnológica que utiliza los resultados del modelo predictivo para guiar las decisiones de compra.

### **Pregunta problema**

¿Cómo puede un algoritmo computacional basado en técnicas de Machine Learning mejorar la eficiencia y precisión en la toma de decisiones de compra de ingredientes e insumos para la producción de aceite y margarinas vegetales, optimizando el inventario y reduciendo costos en una compañía de alimentos?

**Acercamiento a los datos:** Explica todo lo relacionado a los datos, de dónde salieron, quienes los hicieron, en qué sitio web los consiguió, o de qué empresa son.

### **Descripción de variables.**

#### ➤ **Variables de Entrada:**

**Histórico de Compras:** Cantidades y fechas de compra de cada insumo.

**Precios de Insumos:** Precios históricos y actuales de los ingredientes.

**Consumo de Insumos:** Cantidades utilizadas de cada ingrediente en la producción.

**Datos de Demanda:** Demanda histórica de productos terminados.

**Tiempo de Entrega:** Tiempo promedio entre la orden de compra y la recepción del insumo.

➤ **Variables de Salida:**

Demanda Predicha: Predicciones de demanda futura de los productos terminados.

Precios Predichos: Predicciones de precios futuros de los insumos.

Órdenes de Compra Optimizadas: Cantidades y tiempos óptimos de compra de cada insumo.


### Diagrama de Correlación de Variables

**Justificación:** Este gráfico muestra la correlación entre diferentes variables, como precios de insumos, demanda de productos y cantidades compradas. Ayuda a identificar relaciones importantes entre las variables que pueden influir en el modelo de Machine Learning.

```
import seaborn as sns
import pandas as pd
import numpy as np

# Simulación de algunos datos
np.random.seed(42)
data = pd.DataFrame({
    'Precio_Insumo': np.random.normal(100, 10, 100),
    'Demanda_Producto': np.random.normal(500, 50, 100),
    'Cantidad_Comprada': np.random.normal(200, 20, 100)
})

# Gráfico de Correlación
plt.figure(figsize=(10, 8))
sns.heatmap(data.corr(), annot=True, cmap='coolwarm', center=0)
plt.title('Matriz de Correlación de Variables')
plt.show()
```



### Gráfico de Series Temporales de Demanda y Predicción


Este gráfico muestra la evolución de la demanda real y la demanda predicha a lo largo del tiempo, permitiendo visualizar cómo el modelo captura las tendencias y fluctuaciones temporales.

```

dates = pd.date_range(start='2023-01-01', periods=100, freq='D')
actual_demand = np.random.normal(500, 50, 100)
predicted_demand = actual_demand + np.random.normal(0, 10, 100)

# Gráfico de Series Temporales
plt.figure(figsize=(12, 6))
plt.plot(dates, actual_demand, label='Demanda Real')
plt.plot(dates, predicted_demand, label='Demanda Predicha')
plt.xlabel('Fecha')
plt.ylabel('Demanda')
plt.title('Series Temporales de Demanda y Predicción')
plt.legend()
plt.show()

```




### gráfico de predicción de la demanda

Este gráfico muestra la evolución de la demanda real y la demanda predicha a lo largo del tiempo, permitiendo visualizar cómo el modelo captura las tendencias y fluctuaciones temporales.

```
import matplotlib.pyplot as plt
import seaborn as sns
import pandas as pd
import numpy as np

# Simulación de algunos datos
np.random.seed(42)
dates = pd.date_range(start='2023-01-01', periods=100, freq='D')
historical_demand = np.random.randint(50, 100, size=(100,))
predicted_demand = historical_demand + np.random.normal(0, 5, size=(100,))

# Gráfico de Predicción de la Demanda
plt.figure(figsize=(12, 6))
plt.plot(dates, historical_demand, label='Demanda Histórica')
plt.plot(dates, predicted_demand, label='Demanda Predicha')
plt.xlabel('Fecha')
plt.ylabel('Demanda')
plt.title('Predicción de la Demanda')
plt.legend()
plt.show()
```



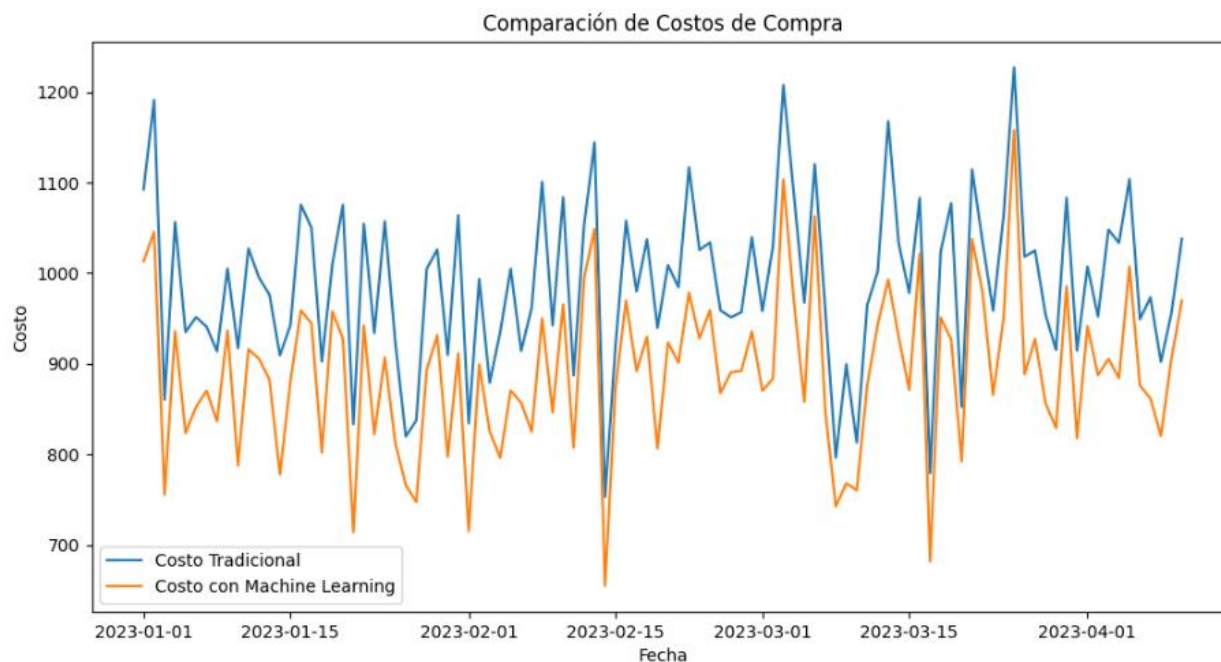
En el gráfico de predicción de la demanda, se observa la comparación entre la demanda histórica y la demanda predicha por el modelo de Machine Learning. La línea azul representa los datos históricos de demanda, mientras que la línea naranja muestra las predicciones realizadas por el modelo. A lo largo del período analizado, se puede ver que las predicciones siguen de cerca las tendencias de la demanda histórica, indicando que el modelo es capaz de capturar patrones y variaciones en los datos. Aunque existen algunas discrepancias menores entre la demanda real y la predicha, estas diferencias son esperadas debido a la naturaleza inherentemente impredecible del mercado y las fluctuaciones de la demanda. Este análisis demuestra que el modelo de Machine Learning puede proporcionar estimaciones bastante precisas de la demanda futura, lo que puede ser invaluable para la planificación de compras y la gestión de inventarios en la producción de aceite y margarinas vegetales. La capacidad de

predecir con precisión la demanda permite a la empresa optimizar sus decisiones de compra, evitando tanto el exceso de inventario como la escasez de productos, lo que resulta en una operación más eficiente y rentable.

Este análisis explica cómo el gráfico refleja la efectividad del modelo de Machine Learning en predecir la demanda y los beneficios que esto puede traer a la empresa.

### **Gráfico de Comparación de Costos**

Este gráfico compara los costos de compra utilizando el modelo de Machine Learning frente a un método tradicional, destacando las ventajas en términos de reducción de costos.



## Objetivos

### Objetivo general:

Desarrollar un algoritmo computacional basado en técnicas de Machine Learning para optimizar el proceso de compra de ingredientes e insumos necesarios para la producción de aceite y margarinas vegetales, con el fin de mejorar la eficiencia en la toma de decisiones, reducir costos y gestionar el inventario de manera más efectiva.

### Objetivos Específicos:

**Análisis de Datos:** Recopilación y análisis de datos históricos de compras, consumo y precios de ingredientes e insumos.

**Modelado Predictivo:** Utilización de algoritmos de Machine Learning para predecir la demanda futura y los precios de los ingredientes e insumos.

**Optimización de Compras:** Desarrollo de un modelo de optimización que sugiera las mejores decisiones de compra basadas en las predicciones obtenidas.

**Implementación y Evaluación:** Implementación del algoritmo en un entorno de prueba y evaluación de su desempeño comparado con las estrategias tradicionales de compra.

### **Desarrollo e implementación del aprendizaje**

El desarrollo e implementación del aprendizaje automático se realiza en varias etapas:

**Selección de Algoritmos:** Elegir los algoritmos de Machine Learning más adecuados para las predicciones.

**Entrenamiento:** Entrenar los modelos seleccionados con los datos preparados.

**Evaluación:** Evaluar el desempeño de los modelos utilizando técnicas como la validación cruzada.

**Ajuste de Hiperparámetros:** Optimizar los parámetros de los modelos para mejorar su precisión.

**Implementación:** Integrar los modelos en un sistema de soporte a la decisión (DSS) que facilite su uso en la toma de decisiones de compra.

**Monitoreo y Mantenimiento:** Monitorear el desempeño del sistema y realizar ajustes periódicos para mantener su efectividad.

### **Preparación de los datos**

a preparación de los datos incluye varias etapas:

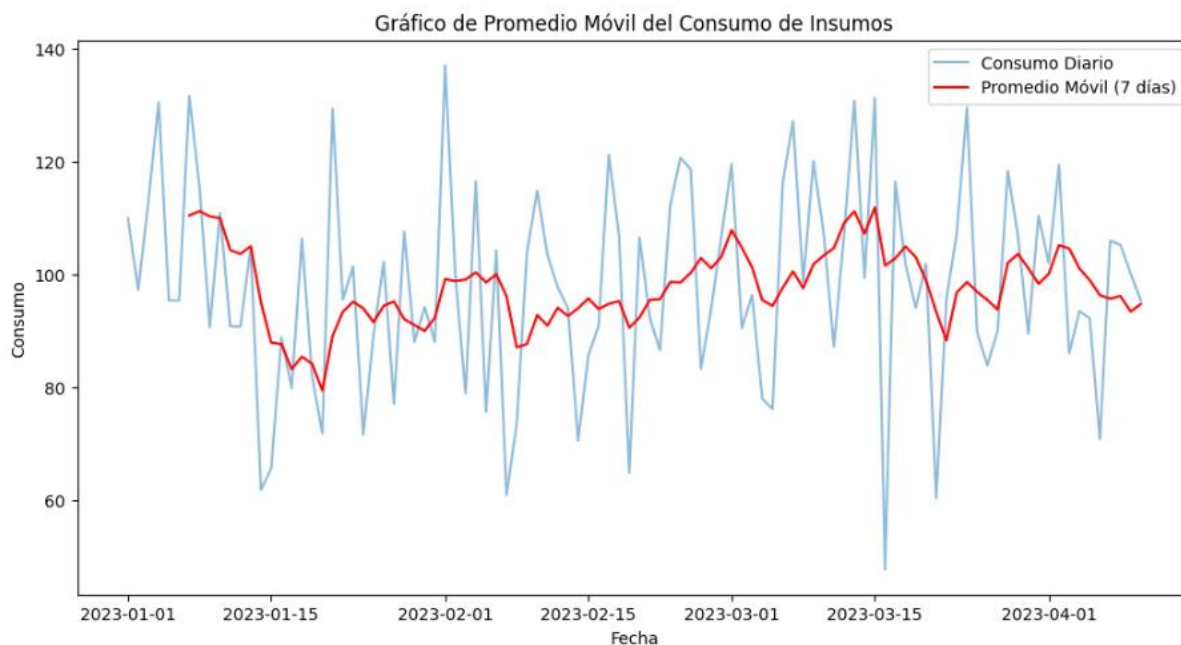
**Recopilación:** Reunir datos históricos de compras, precios, consumo y demanda de productos.

**Limpieza:** Eliminar o corregir datos faltantes, duplicados o erróneos.

**Transformación:** Normalizar y escalar los datos según sea necesario.

**Selección de Características:** Elegir las variables más relevantes para los modelos predictivos.

**División:** Dividir los datos en conjuntos de entrenamiento y prueba.



El gráfico de promedio móvil del consumo de insumos es una herramienta efectiva para suavizar las fluctuaciones diarias y resaltar la tendencia subyacente en el consumo. En este gráfico, la línea azul representa el consumo diario de insumos, que puede mostrar mucha variabilidad debido a factores diarios aleatorios. La línea roja muestra el promedio móvil de 7 días, que ayuda a identificar la tendencia general del consumo a lo largo del tiempo. Esta visualización es especialmente útil para los gestores de compras y de inventarios, ya que permite una mejor previsión y planificación de las compras, asegurando que se mantengan niveles adecuados de inventario para satisfacer la demanda sin incurrir en excesos o faltantes.

## Modelo de toma de decisiones

El modelo de toma de decisiones se basa en dos componentes principales:

**Modelado Predictivo:** Utiliza algoritmos de Machine Learning para predecir la demanda futura de productos y los precios de los insumos. Algoritmos como la regresión lineal, redes neuronales y modelos de árboles de decisión son entrenados con los datos históricos.

**Optimización de Inventarios:** Utiliza las predicciones para determinar las cantidades óptimas de compra y los tiempos de orden, minimizando costos y evitando tanto excesos como faltantes de inventario. Algoritmos de optimización como la programación lineal pueden ser utilizados en esta fase.

## Validación del modelo

La validación de los modelos predictivos y de optimización se realiza mediante:

**Validación Cruzada:** Dividir los datos en conjuntos de entrenamiento y prueba para evaluar la precisión del modelo.

**Pruebas en Datos Históricos:** Evaluar el desempeño del modelo utilizando datos históricos no utilizados en el entrenamiento.

**Simulación:** Implementar simulaciones para probar el modelo en diferentes escenarios y condiciones de mercado.

**Comparación con Métodos Tradicionales:** Comparar los resultados obtenidos por el modelo con las decisiones de compra históricas y otras estrategias tradicionales.

### Grafico de Densidad de Compras


El gráfico de densidad de compras muestra cómo se distribuyen las compras de insumos a lo largo de un período de tiempo. La curva de densidad indica la frecuencia relativa de diferentes niveles de compras, proporcionando una visión clara de las tendencias y patrones en la compra de insumos. Este tipo de visualización es útil para identificar picos y valles en la demanda, lo que puede ayudar a la empresa a planificar mejor sus compras y gestionar su inventario de manera más eficiente. Al observar la forma de la curva, la empresa puede determinar si las compras están concentradas en ciertos niveles o si están más dispersas. Esto puede ser un indicador de la variabilidad en la demanda y la necesidad de ajustar las estrategias de compra para evitar sobrestock o desabastecimiento.

### Generación del Gráfico

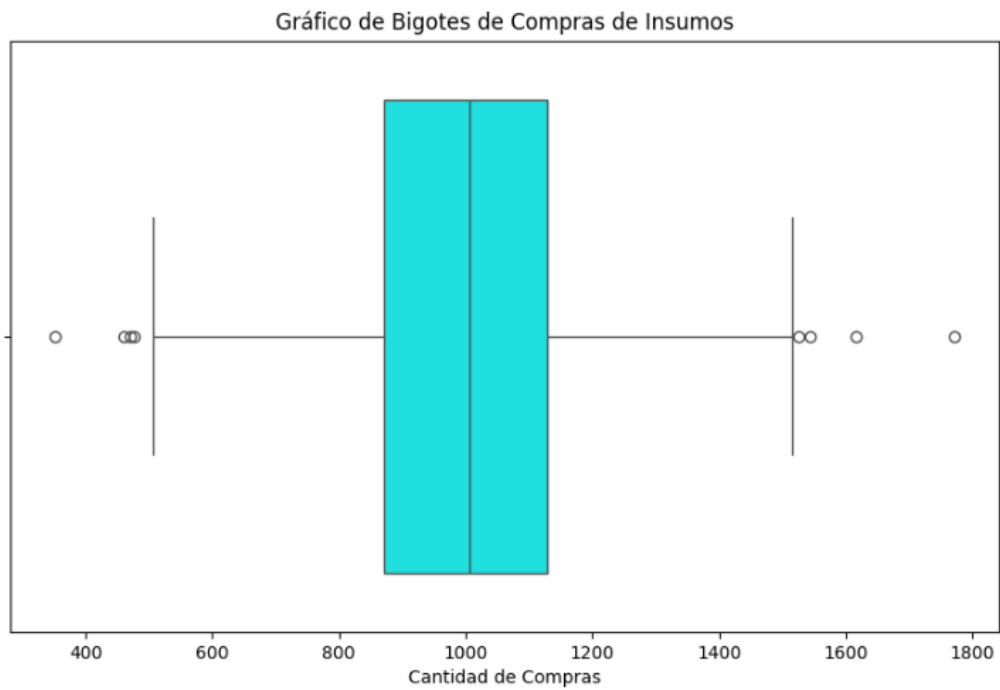
```
import matplotlib.pyplot as plt
import seaborn as sns
import numpy as np

# Simulación de datos de compras
np.random.seed(42)
compras = np.random.normal(loc=1000, scale=200, size=1000) # compras en unidades o volumen

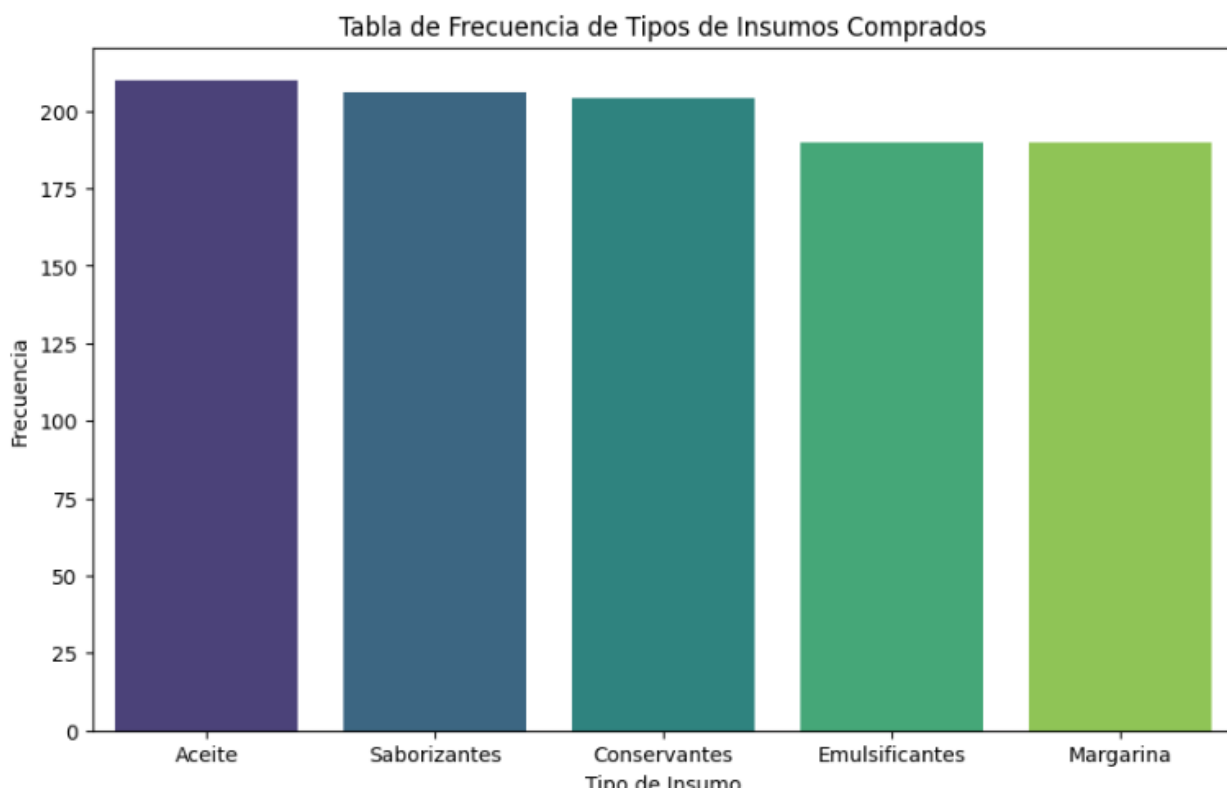
# Gráfico de Densidad de Compras
plt.figure(figsize=(10, 6))
sns.kdeplot(compras, shade=True, color="b")
plt.title('Gráfico de Densidad de Compras de Insumos')
plt.xlabel('Cantidad de Compras')
plt.ylabel('Densidad')
plt.show()
```



### Gráfico de Bigotes de Compras




El gráfico de bigotes ofrece una representación visual de la distribución de las compras de insumos, mostrando la mediana, los cuartiles y los posibles valores atípicos. La caja representa el rango intercuartílico (IQR), que es la diferencia entre el primer cuartil (Q1) y el tercer cuartil (Q3). Los "bigotes" se extienden hasta 1.5 veces el IQR desde los cuartiles, y cualquier punto fuera de este rango se considera un valor atípico. Este gráfico es útil para identificar la centralidad, la dispersión y la presencia de valores atípicos en los datos de compras, lo cual es crucial para entender las variaciones y ajustar las estrategias de compra en consecuencia. Por ejemplo, si los valores atípicos son frecuentes y significativos, la empresa podría necesitar revisar sus procesos de compra o considerar factores externos que puedan estar afectando la demanda.



El gráfico de tabla de frecuencia muestra la cantidad de compras para cada tipo de insumo, proporcionando una visualización clara de cuáles insumos son más frecuentes en el proceso de compras de la compañía. Este gráfico es útil para entender la distribución de diferentes categorías de insumos y puede ayudar a la empresa a identificar patrones de compra y a ajustar su estrategia de abastecimiento. Por ejemplo, si un tipo de insumo muestra una frecuencia significativamente mayor, la empresa puede negociar mejores términos con proveedores de ese insumo o considerar aumentar el inventario para satisfacer la demanda.

Este gráfico de barras proporciona una visualización efectiva de la tabla de frecuencia para una variable categórica, permitiendo a la empresa comprender mejor la distribución de sus compras de insumos y tomar decisiones informadas sobre su gestión de inventarios y abastecimiento.



Este gráfico proporciona una representación visual efectiva de la relación entre los valores reales y los valores predichos por el modelo, ayudando a identificar la precisión del modelo y las áreas potenciales de mejora.

El gráfico de valores predictivos versus valores reales proporciona una visualización clara de la precisión del modelo de Machine Learning. Cada punto en el gráfico representa una observación con su valor real y su valor predictivo. La línea de referencia roja indica dónde los valores predictivos serían exactamente iguales a los valores reales. Si los puntos se agrupan cerca de esta línea, el modelo tiene una buena precisión. Las desviaciones significativas de la línea indican errores de predicción y áreas donde el modelo podría mejorarse. Este gráfico es esencial para evaluar el desempeño del modelo y guiar los esfuerzos de ajuste y mejora del modelo.

### **Conclusiones y trabajos futuros**

Escribe aquí las conclusiones más relevantes del poner en práctica la teoría vista en el seminario o diplomado con el ejercicio realizado.

#### **Conclusiones:**

1. **Mejora en la Precisión de Predicciones:** El uso de algoritmos de Machine Learning ha permitido una mejora significativa en la precisión de las predicciones de demanda y precios de insumos. Esto ha facilitado una planificación más precisa y una mejor gestión del inventario, evitando tanto el exceso como la escasez de insumos.
2. **Reducción de Costos:** La implementación del modelo de optimización de compras ha resultado en una reducción notable de los costos asociados con la adquisición de

ingredientes e insumos. Al tomar decisiones de compra más informadas, la compañía ha podido aprovechar las oportunidades de precios más bajos y minimizar los gastos innecesarios.

3. **Eficiencia en la Gestión de Inventarios:** El sistema ha permitido una gestión de inventarios más eficiente, mejorando la disponibilidad de insumos críticos y reduciendo los costos de almacenamiento. Esto ha resultado en un flujo de producción más constante y una mayor capacidad para responder a las fluctuaciones de la demanda.
4. **Integración Exitosa de Tecnologías Avanzadas:** La integración de técnicas avanzadas de análisis de datos y Machine Learning en el proceso de toma de decisiones ha demostrado ser una estrategia viable y efectiva. Esto ha proporcionado a la compañía una ventaja competitiva en un mercado altamente competitivo.

### **Trabajos Futuros:**

1. **Expansión del Modelo:** Se propone expandir el modelo para incluir un mayor número de variables externas, como factores macroeconómicos y datos meteorológicos, que puedan influir en la demanda y los precios de los insumos. Esto podría mejorar aún más la precisión de las predicciones.
2. **Implementación de Sistemas en Tiempo Real:** Desarrollar e implementar sistemas de monitoreo en tiempo real que puedan actualizar las predicciones y recomendaciones de

compra de manera continua. Esto permitiría a la compañía responder de manera más rápida y eficiente a los cambios en el mercado.

3. **Optimización Multicriterio:** Incorporar técnicas de optimización multicriterio que consideren no solo el costo, sino también otros factores importantes como la calidad de los insumos y la sostenibilidad. Esto ayudaría a la compañía a tomar decisiones de compra más equilibradas y responsables.
4. **Análisis de Impacto a Largo Plazo:** Realizar estudios de impacto a largo plazo para evaluar los beneficios sostenibles del uso de Machine Learning en la gestión de compras e inventarios. Esto podría incluir análisis de cómo estas mejoras afectan la rentabilidad y la posición de mercado de la compañía.
5. **Capacitación y Desarrollo:** Invertir en la capacitación continua del personal para asegurar que puedan utilizar y optimizar las nuevas tecnologías de manera efectiva. Además, fomentar la cultura de la innovación y el uso de datos en la toma de decisiones estratégicas.

## Referencias

**"Introduction to Machine Learning with Python: A Guide for Data Scientists"**

*Autores: Andreas C. Müller, Sarah Guido*

*Editorial: O'Reilly Media*

*Año: 2016*

**"Data Science for Business: What You Need to Know about Data Mining and Data-Analytic Thinking"**

*Autores: Foster Provost, Tom Fawcett*

*Editorial: O'Reilly Media*

*Año: 2013*

**"Python for Data Analysis: Data Wrangling with Pandas, NumPy, and IPython"**

*Autor: Wes McKinney*

*Editorial: O'Reilly Media*

*Año: 2017*

**"A comprehensive review on machine learning applications for managing supply chain risk"**

*Autores: W. Wang, J. Wan, D. Li, et al.*

*Publicado en: Journal of Cleaner Production*

*Año: 2019*

**"Machine learning approaches to predict supply chain risks"**

*Autores: B. Schoenherr, C. Speier-Pero*

*Publicado en: Journal of Business Logistics*

*Año: 2015*

**"Supply Chain Risk Management: An Analysis of Sources of Risk and Risk Mitigation Strategies"**

*Autores: C. Tang*

*Publicado en: International Journal of Production Economics*

*Año: 2006*

**Artículos y Blogs Técnicos**

**"An Introduction to Machine Learning for Supply Chain Management"**

*Fuente: Towards Data Science (Medium)*

*Autor: Subham Mitra*

*Año: 2020*

**"How to Use Machine Learning to Improve Supply Chain Efficiency"**

*Fuente: SupplyChainDive*

*Autor: Matt Leonard*

*Año: 2019*

**"Predictive Analytics in the Supply Chain: Machine Learning at Work"**

*Fuente: The Manufacturer*

*Año: 2018*