



TRABAJO DE GRADO
Opción Seminario-Diplomado.

**ALGORITMO COMPUTACIONAL PARA LA PREDICCIÓN DE NIVEL DE
SATISFACCIÓN DE COMPRA DE UN USUARIO, UTILIZANDO ESTRATEGIAS DE
MACHINE LEARNING**

Corporación Universitaria Remington.
Nombre de la facultad: Ingenierías
Nombre del programa académico: Ingeniería De Sistemas

Estudiante:
Daniel David Aguirre Aristizábal

Tutor: Juan Carlos Briñez de León

Opción de Trabajo de grado Seminario-Diplomado.
2024.

Dedicatoria

A mis padres, hermano, esposa y abuela, quienes fueron y han sido motivación para lograr las metas propuestas; y que seguramente sin su ayuda y consejos no hubiera sido posible llegar hasta donde me encuentro.

Agradecimientos

En primer lugar, a Dios, quien ha sido el que me ha dado todo y me ha ayudado en mi proceso de aprendizaje, a mis profesores quienes con su disposición y apoyo he logrado adquirir nuevos conocimientos, y habilidades; a mis compañeros quienes han ayudado a que todo esto sea posible, y por último a toda mi familia pilar fundamental en momentos de estrés y angustia.

Tabla de Contenidos

Resumen	1
Palabras Clave	1
Marco Conceptual y Contextual	2
Contexto:	2
Sistemas de Recomendación	2
Algoritmos de Machine learning en Sistemas de Recomendación.	3
Descripción de Caso de Estudio	5
Pregunta Problema	5
Hipótesis	6
Objetivos	6
Objetivo General	6
Objetivos Específicos	6
Desarrollo e Implementación del Aprendizaje	7
Preparación y Análisis de los Datos	7
Modelo de Toma de Decisiones	15
Validación del Modelo	19
Conclusiones	24
Referencias Bibliográficas	25

Resumen

El presente trabajo se enfoca en brindar una solución a una pequeña cadena de supermercados llamada Merk+, en la predicción de las calificaciones brindadas por sus clientes, en aras de mejorar el servicio brindado y realizar estrategias que permitan a Merk+ tomar mejores decisiones. Dentro del análisis comenzamos con una breve descripción de la situación de Merk+, para posteriormente, con base a la data brindada por la cadena de supermercados; dentro de estos datos podemos encontrar el tipo de datos de nuestras variables, cantidad de personas por género, mapa de correlaciones, gráfico de bigotes, entre otros gráficos y tablas con información, la cual fue previamente limpiada y normalizada con el fin de evitar outliers que puedan afectar nuestro análisis.

Con base a nuestro análisis, hemos entregado el uso de algoritmos de clustering y de regresión de datos con múltiples entradas. En el proceso de clustering segmentaremos nuestros clientes o compras, con el fin de poder identificar un factor común que pueda afectar las calificaciones que está entregando los clientes.

En cuanto a la regresión de datos con múltiples entradas, le permitirá a Merk+ proyectar la posible calificación por parte del usuario con base a los artículos comprados, método de pago, sucursal de la compra, entre otros. Con esto se busca que Merk+ pueda brindar un mejor servicio para sus clientes y así mismo destacar entre su competencia.

Palabras Clave

Recomendación, Sistemas de recomendación, Clustering, IA, Inteligencia artificial, Machine Learning, regresión con múltiples entradas.

Marco Conceptual y Contextual

Contexto:

Sistemas de Recomendación

Los sistemas de recomendación representan flujos de trabajo que utilizan inteligencia artificial para tomar decisiones basadas en datos históricos, lo cual permite recomendar productos, servicios o beneficios personalizados a los usuarios según sus intereses y patrones de comportamiento. En términos técnicos, Nvidia define un sistema de recomendación como "un algoritmo de inteligencia artificial o IA, generalmente asociado con el aprendizaje automático, que utiliza Big Data para sugerir o recomendar productos adicionales a los consumidores" (What Is A Recommendation System?, s. f.).

En la actualidad, la eficiencia de estos sistemas es alta, siempre y cuando se disponga de una base de datos sólida y grande, para que los algoritmos puedan identificar las preferencias y patrones de consumo. Esta capacidad ha impulsado el desarrollo de nuevas estrategias empresariales, permitiendo ofrecer experiencias, servicios y productos más personalizados. Ejemplos conocidos incluyen a Netflix, que sugiere series y películas basadas en el historial de visualización del usuario, o Spotify, que recomienda canciones acordes a los gustos musicales de cada persona. En Amazon, se utilizan datos de compras previas para proponer productos relevantes para cada cliente, potenciando el interés y las ventas.

Los beneficios de los sistemas de recomendación para las empresas son diversos: pueden aumentar las ventas, mejorar el servicio al cliente mediante recomendaciones personalizadas y optimizar la eficiencia operativa. De acuerdo con González (2020), “investigaciones recientes revelan que la recomendación de productos puede llevar a un aumento del 70% en las tasas de compra”.

En un mercado en constante movimiento, ofrecer servicios personalizados marca una gran diferencia. Un estudio del Observatorio Hostinger indica que "el 62,1% de los españoles afirma haber comprado en la web guiados por recomendaciones personalizadas" (Galindo & Galindo, 2024). Además, en Estados Unidos, “el 91% de los consumidores tiene más probabilidades de apoyar marcas que ofrecen experiencias personalizadas y recomendaciones relevantes en función de sus comportamientos y perfiles” (Online Grocery Recommendation Using Machine Learning, s. f.). Estos datos destacan la necesidad de implementar sistemas de recomendación con técnicas de aprendizaje automático (Machine Learning) para mejorar la experiencia del cliente y aumentar la lealtad hacia la marca.

Esta implementación no solo incrementa las ventas, sino que también fortalece la relación con los consumidores al ofrecerles una experiencia individualizada que los hace sentir valorados y comprendidos.

Algoritmos de Machine learning en Sistemas de Recomendación.

Los algoritmos de Machine Learning aplicados en los sistemas de recomendación se basan en el análisis de conjuntos de datos recopilados, lo cual permite que el sistema evolucione y mejore sus recomendaciones a partir de datos históricos y nuevos. Para que

un sistema de recomendación funcione de manera óptima, es fundamental contar con grandes volúmenes de información, ya que así el algoritmo puede adaptar sus recomendaciones de forma progresiva y precisa.

Existen varios enfoques en los sistemas de recomendación basados en Machine Learning:

- **Sistemas de recomendación con filtros colaborativos:** También llamado collaborative filtering, basan su lógica en las características del usuario. Es decir, este analiza todo lo que el usuario ha realizado en anteriores ocasiones pueden ser compras, calificaciones sobre productos, o incluso el tiempo que permanece observando el producto.
- **Sistemas de recomendación con filtros basados en contenido:** Llamado en ingles content-based filtering, se basan en el análisis del producto y no en el usuario. Es decir, utiliza atributos del producto tales como su marca, precio, calificaciones, tamaño, etc. Para hacer recomendaciones; como ejemplo podemos hablar de la marca Apple, la cual no se recomienda a cualquier tipo de usuario, ya que sus precios son un poco más altos.
- **Sistemas de recomendación híbrido:** Este sistema combina ambas predicciones mencionadas con anterioridad, es decir toma parte de las funciones del filtro con base a la recomendación de usuario y las funciones del filtro basado en contenido,

con el fin de hacer un “match” mucho más acertado.

Es importante indicar que estos sistemas de recomendación funcionan con una gran cantidad de datos, por lo que no todos los negocios pueden aplicarla a su operación diaria.

Es importante destacar que estos sistemas de recomendación requieren grandes cantidades de datos para funcionar correctamente, lo cual puede limitar su implementación en algunas empresas que no cuentan con los recursos o la infraestructura necesarios para procesar y almacenar grandes volúmenes de información.

Descripción de Caso de Estudio

La cadena de supermercados Pereirana “Merk+” y la cual cuenta con 3 sucursales, desea saber la calificación que pueda entregar sus clientes para los pedidos realizados; para ello, la cadena brinda un archivo con estadísticas de compras realizadas por otros clientes con anterioridad tales como la sede donde realizó la compra, cantidad y valor del producto, categoría del producto, la calificación que brindó en su momento, entre otros.

Pregunta Problema

¿Cómo desarrollar una estrategia computacional para Merk+ que le permita saber cuál será la calificación o nivel de satisfacción del cliente a partir del histórico de calificaciones de otros clientes con base a sus pedidos anteriores, haciendo uso de algoritmos de Machine Learning?

Hipótesis

El análisis computacional de los datos de calificación de los clientes del supermercado Merk+ junto con un algoritmo de regresión de múltiples entradas, permitirá implementar un sistema que entregue una posible predicción de calificaciones con base a sus posibles compras. Ello, con miras de ver que factores pueden ser claves en mejores calificaciones.

Objetivos

Objetivo General

A partir de los datos existentes, brindar un software que permita predecir la posible calificación o satisfacción de un cliente del supermercado Merk+, haciendo uso de algoritmos de Machine Learning.

Objetivos Específicos

- Implementar un algoritmo de Machine Learning para la regresión de los datos con múltiples entradas para la predicción de información
- Evaluar y analizar el desempeño de los algoritmos implementados para la posible toma de decisiones.
- Validar el funcionamiento de toma de decisiones a partir de datos nuevos.
- Implementación de Clustering, para la agrupación de datos y poder tomar decisiones a partir de ello.

Desarrollo e Implementación del Aprendizaje

Con base a los datos recopilados por la cadena de almacenes Merk+, y gracias al uso de algoritmos de Machine Learning, más exactamente regresión de datos y Clústers, encontraremos una solución para las necesidades del cliente.

Preparación y Análisis de los Datos

Gracias a los datos entregados por el supermercado obtenemos la siguiente información, y la cual veremos representada en una tabla:

Tabla 1. Variables de Dataset

```

RangeIndex: 1000 entries, 0 to 999
Data columns (total 17 columns):
 #   Column                Non-Null Count  Dtype
---  -
 0   Invoice ID            1000 non-null   object
 1   Branch               1000 non-null   object
 2   City                 1000 non-null   object
 3   Customer type       1000 non-null   object
 4   Gender               1000 non-null   object
 5   Product line        1000 non-null   object
 6   Unit price          1000 non-null   float64
 7   Quantity            1000 non-null   int64
 8   Tax 5%              1000 non-null   float64
 9   Total               1000 non-null   float64
10   Date                1000 non-null   object
11   Time                1000 non-null   object
12   Payment             1000 non-null   object
13   cogs                1000 non-null   float64
14   gross margin percentage 1000 non-null   float64
15   gross income        1000 non-null   float64
16   Rating              1000 non-null   float64
dtypes: float64(7), int64(1), object(9)
memory usage: 132.9+ KB

```

La tabla anterior muestra que contamos con 18 columnas y un total de 1000 registros. A continuación, se detallan las variables:

- **Invoice ID:** El id con el cual se identifican las facturas.
- **Branch:** Sucursal del supermercado donde el cliente hizo la compra.
- **City:** Ciudad de la ubicación de la sucursal.
- **Customer type:** Indica el tipo de cliente, ya si es miembro especial o si no lo es.
- **Gender:** Género del cliente.
- **Product line:** Categoría del producto comprado, ya sea salud y belleza, accesorios electrónicos, hogar y estilo de vida, entre otros.
- **Unit Price:** Precio unitario del producto.
- **Quantity:** Cantidad comprada.
- **Tax 5%:** Impuesto calculado del subtotal.
- **Total:** Total a pagar después del impuesto.
- **Date:** Fecha de la compra.
- **Time:** Hora de la compra.
- **Payment:** Método de pago, ya sea efectivo, chequera electrónica o tarjeta de crédito.
- **Cogs:** Indica Costo of Goods Sold, y es un costo total antes de impuestos.
- **Gross income:** Ingreso bruto de la transacción.
- **Rating:** Calificación entregada por el cliente del 1 a l 10.

Gracias a esta información y en consideración a lo necesitado procederemos a eliminar las siguientes columnas: Invoice ID, City, Tax 5%, Time, Cogs, Date y gross margin percentage.

Para fines de lograr el análisis, vamos a cambiar los datos de tipo objeto a tipo numérico

- **Branch:** Las sucursales A, B y C se reemplazarán por 1, 2 y 3, respectivamente.
- **Customer Type:** "Member" será reemplazado por 1 y "Normal" por 0.
- **Gender:** "Female" se codificará como 0 y "Male" como 1.
- **Product line:** Las categorías 'Health and Beauty', 'Electronic Accessories', 'Home and Lifestyle', 'Sports and Travel', 'Food and Beverages', y 'Fashion Accessories' se asignarán a los valores 10, 20, 30, 40, 50 y 60, respectivamente.
- **Payment:** Los métodos de Pago 'Ewallet', 'Cash' y 'Credit Card' se representarán como 1, 2 y 3, en ese orden.

Con base a las modificaciones realizadas, nuestra tabla de variables queda de la siguiente manera

Tabla 2. Variables finales Dataset

```

RangeIndex: 1000 entries, 0 to 999
Data columns (total 9 columns):
#   Column          Non-Null Count  Dtype
---  -
0   Branch          1000 non-null   int64
1   Customer type   1000 non-null   int64
2   Gender          1000 non-null   int64
3   Product line    1000 non-null   int64
4   Unit price      1000 non-null   float64
5   Quantity        1000 non-null   int64
6   Total           1000 non-null   float64
7   Payment         1000 non-null   int64
8   Rating          1000 non-null   float64
dtypes: float64(3), int64(6)
memory usage: 70.4 KB

```

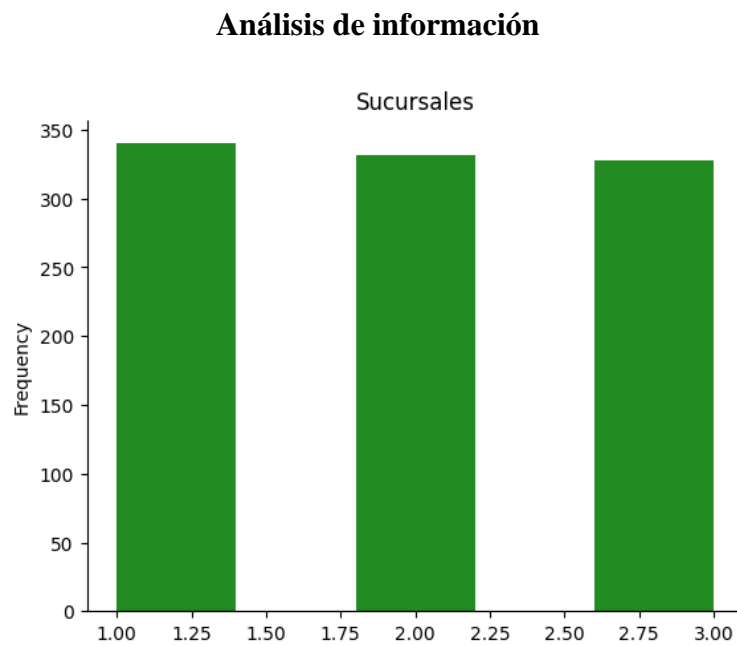


Figura 1. Ventas por sucursal

De la anterior grafica detectamos que la sucursal 1, es la que mayor cantidad de ventas ha tenido, seguido por la sucursal 2 que al igual que la sucursal 3 están en similitud de ventas aproximadamente.

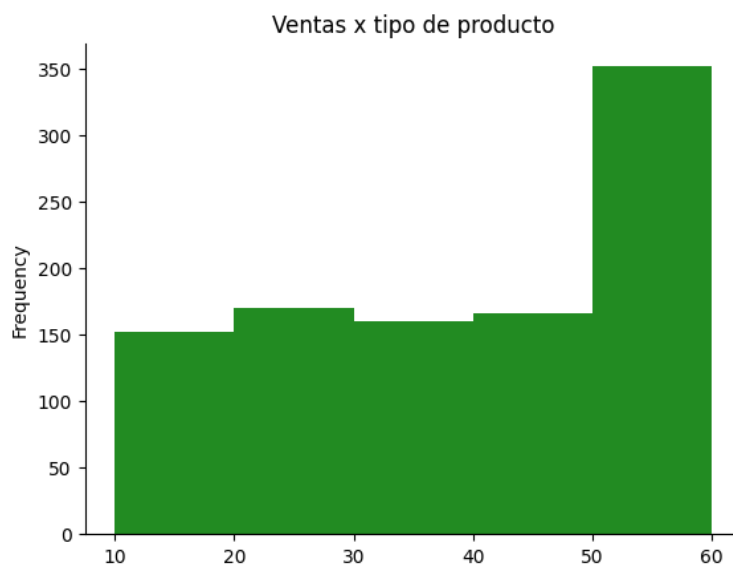


Figura 2. Ventas x categoría de productos

Del siguiente análisis logramos resaltar por gran diferencia, el tipo de producto que más ventas tiene son los Accesorios de moda con un aproximado de 350 ventas realizadas es decir el 35% de las ventas realizadas, seguido por los accesorios electrónicos, con un aproximado de 160 artículos en la venta; otra observación al respecto.

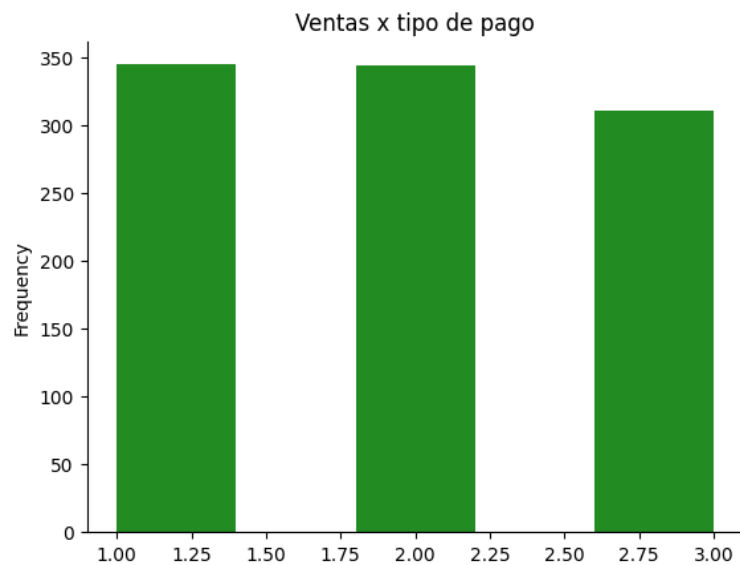


Figura 3. Ventas x tipo de pago

El grafico indica que los pagos realizados con tarjeta de crédito son menores a los pagos realizados con efectivo o chequeras electrónicas, los cuales son sumamente parejo.

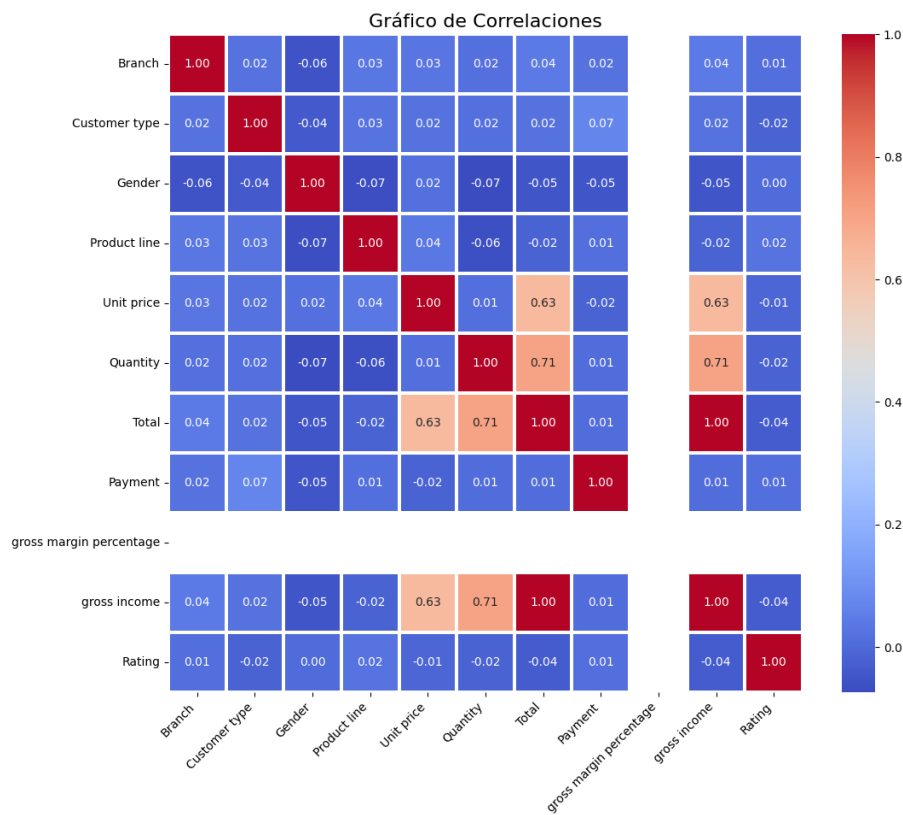


Figura 4. Correlaciones de variables

Dentro del gráfico de correlaciones observamos que las relaciones más fuertes dentro de nuestro conjunto de datos son el total con la cantidad, esto es algo obvio puesto que, a mayor cantidad de compra de los productos, mayor es la cantidad de dinero a pagar, así mismo el precio unitario y el ingreso bruto está relacionado fuertemente; por último, encontramos que el total y el ingreso bruto se relacionan de forma directa.

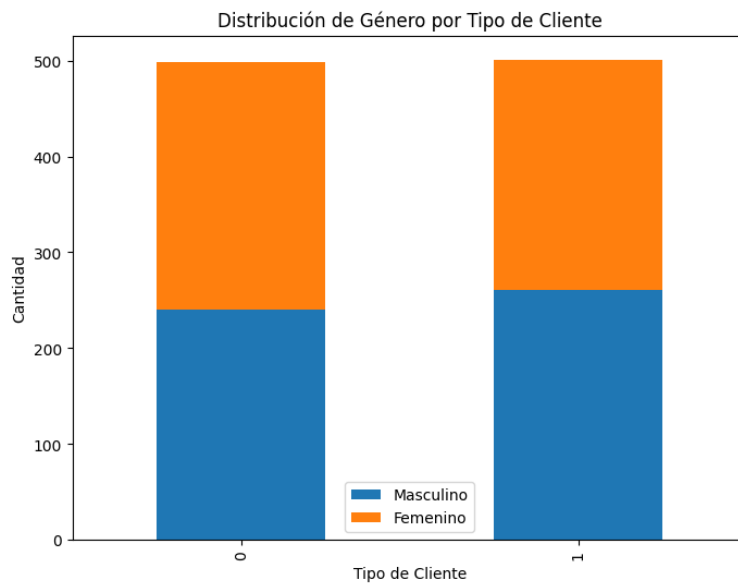


Figura 5. Distribución género x tipo de cliente

De la grafica anterior tenemos que la mayor cantidad en clientes miembros, son hombres, por otro lado, podemos decir que los clientes normales están distribuidos de forma equitativa entre hombres y mujeres.

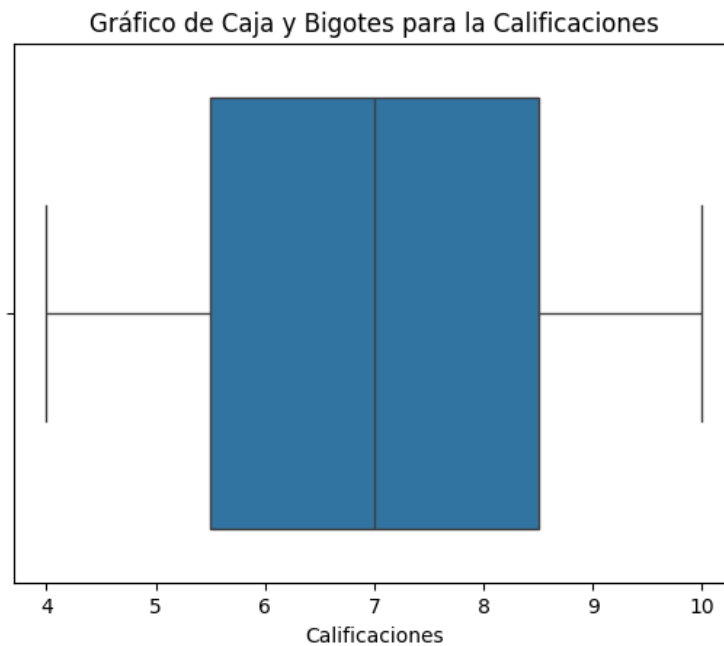


Figura 6. Gráfico caja y bigotes de calificaciones

Con base al gráfico de caja y bigotes, encontramos que la mayoría de las calificaciones se encuentran entre 5,5 y 8,5; adicionalmente encontramos outliers que pudieran afectar el entrenamiento de nuestra inteligencia en posibles casos.

Como parte del análisis del gráfico, también se evidencia de una media 7; indicando que es un buen promedio en el valor de las calificaciones recibido por Merk+.

Modelo de Toma de Decisiones

Clustering

Para la toma de decisiones, hemos segmentado en 5 grupos con base a la gráfica del método del codo, el cual nos muestra lo siguiente




Figura 7. Gráfico método del codo

Al momento de ingresar o generar los grupos, este nos los ha dividido de la siguiente manera

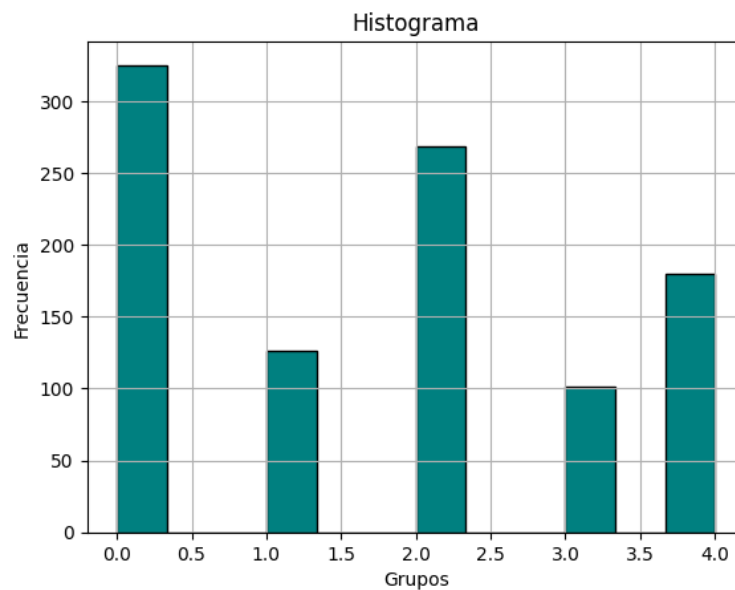


Figura 8. Histograma de grupos creados en clustering

Del gráfico anterior y con base al método del código, hemos creado 5 grupos, los cuales la IA ha organizado del 0 al 4, siendo el grupo 0 con mayor concentración de compras, seguido entonces del grupo 2, y el grupo 3 el grupo con la menor cantidad de datos o compras.

En este caso nuestra IA, ha realizado 5 grupos, dentro de los cuales sus centroides se muestran de la siguiente manera.

Tabla 3. Centroides de los grupos

Centroides:									
	Branch	Customer type	Gender	Product line	Unit price	Quantity	Total	Payment	Rating
0	2.009202	0.493865	0.530675	35.736196	37.900552	3.052147	87.664275	1.972393	6.935583
1	1.992063	0.523810	0.500000	33.968254	75.740794	7.730159	595.462667	1.976190	6.911905
2	1.914179	0.503731	0.511194	35.895522	51.808918	5.242537	232.190457	1.951493	7.104104
3	2.099010	0.524752	0.425743	35.742574	87.284752	9.178218	836.894391	2.019802	6.796040
4	1.994413	0.480447	0.463687	36.759777	61.858436	6.754190	405.623036	1.938547	6.986034

Regresiones con múltiples entradas

Para el presente análisis, se entrenan 2 modelos de Inteligencia Artificial, los cuales quedarán con el siguiente rango de error.

```

#Modelo para predicciones de series de tiempo (KNN: Bueno si sabemos que los datos no se salen del rango)
from sklearn.neighbors import KNeighborsRegressor as KNNR
Modelo_1=KNNR()
Modelo_1.fit(Entradas,Salida)
Prediction1 = Modelo_1.predict(Entradas)
RMSE1 = np.sqrt(np.mean((Prediction1-Salida)**2))
print('El error RMSE del modelo KNN es: ',RMSE1)

El error RMSE del modelo KNN es: 1.514293102407853

#Modelo para series de tiempo complicadas (Sólo se conoce la dinámica)
from sklearn.neural_network import MLPRegressor
Modelo_2 = MLPRegressor()
Modelo_2.fit(Entradas,Salida)
Prediction2 = Modelo_2.predict(Entradas)
RMSE2 = np.sqrt(np.mean((Prediction2-Salida)**2))
print('El error RMSE del modelo ANN es: ',RMSE2)

El error RMSE del modelo ANN es: 1.8527298901712814

```

Figura 9. Código con el nivel de error de las IA

Nuestra primera IA tiene un error del 1,5; mientras que la segunda IA tiene un error del 1.85, ambos muy bajos.

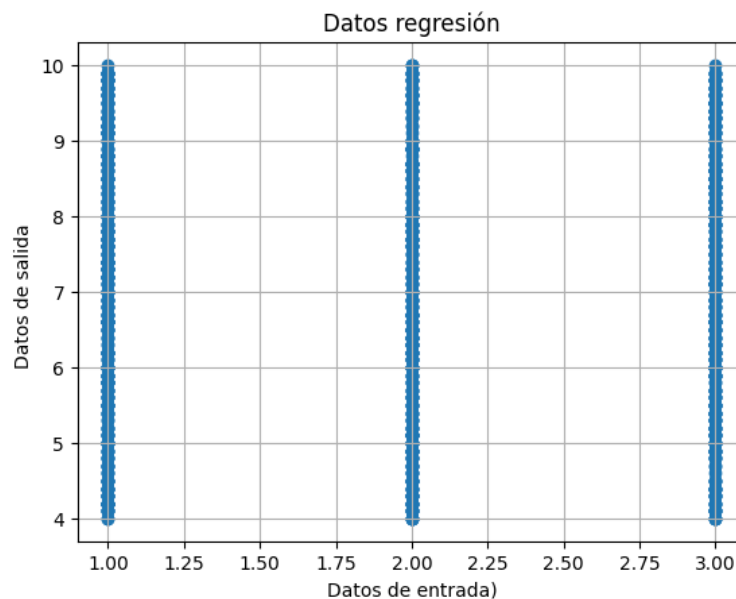


Figura 10. Datos de regresión

En este caso nuestros según la gráfica se puede evidenciar que los valores, se encuentran distribuidos en 3 entradas, por lo que esto puede sugerir que existen otras variables que puedan afectar el resultado final.

Validación del Modelo

Validación del modelo con el Clustering

Para la validación del clustering, se ha generado las siguientes preguntas las cuales recopilarán los datos para indicar a que grupo será arrojado.

```

#Tomando un cliente nuevo para asignarle un grupo según el modelo anterior
Cliente_New = np.zeros((1,9))
Cliente_New[0,0]=float(input('Ingrese la sucursal donde compro el cliente 1,2,3: '))
Cliente_New[0,1]=float(input('¿Cliente es miembro? 1 Si, 2, No: '))
Cliente_New[0,2]=float(input('Ingrese genero del usuario 1 Masculino - 0 Femenino: '))
Cliente_New[0,3]=float(input('Ingrese la categoria de producto: '))
Cliente_New[0,4]=float(input('Ingrese precio unitario : '))
Cliente_New[0,5]=float(input('Ingrese cantidad comprada: '))
Cliente_New[0,6]=float(input('Ingrese Total: '))
Cliente_New[0,7]=float(input('Ingrese el metodo de pago: '))
Cliente_New[0,8]=float(input('Ingrese Calificación brindada por el cliente (1-10): '))

Etiqueta_Cliente = Modelo_Cluster.predict(Cliente_New)
print('Según los datos del cliente, el grupo es: ',Etiqueta_Cliente)
print(' ')

if Etiqueta_Cliente == 0:
    print('Decisión del grupo 0')
if Etiqueta_Cliente == 1:
    print('Decisión del grupo 1')
if Etiqueta_Cliente == 2:
    print('Decisión del grupo 2')
if Etiqueta_Cliente == 3:
    print('Decisión del grupo 3')
if Etiqueta_Cliente == 4:
    print('Decisión del grupo 4')

```

Figura 11. Código para la solicitud de datos por clustering

Como parte del ejercicio, hemos puesto a prueba nuestro modelo arrojando los siguientes resultados.

```

Ingrese la sucursal donde compro el cliente 1,2,3: 1
¿Cliente es miembro? 1 Si, 0, No: 0
Ingrese genero del usuario 1 Masculino - 0 Femenino: 1
Ingrese la categoria de producto: 30
Ingrese precio unitario : 125
Ingrese cantidad comprada: 2
Ingrese Total: 250
Ingrese el metodo de pago: 3
Ingrese Calificación brindada por el cliente (1-10): 8
Según los datos del cliente, el grupo es: [2]

Decisión del grupo 2

```

Figura 12. Datos arrojados por clustering 1

Como parte de los datos arrojados, se le indica a nuestra IA, que el cliente ha comprado en la sucursal número 1, el cual no es miembro; se sabe que es de genero masculino, el

cual ha comprado productos de la categoría hogar y estilo de vida de los cuales a comprado 2, cada uno de \$125 para un total de \$250, el cliente realizó su pago con tarjeta de crédito y entregó una calificación de 8.

Con base a esto nuestro modelo ha entendido que este cliente está dentro del grupo 2.

```
Ingrese la sucursal donde compro el cliente 1,2,3: 3
¿Cliente es miembro? 1 Si, 0, No: 1
Ingrese genero del usuario 1 Masculino - 0 Femenino: 0
Ingrese la categoria de producto: 60
Ingrese precio unitario : 100
Ingrese cantidad comprada: 4
Ingrese Total: 400
Ingrese el metodo de pago: 1
Ingrese Calificación brindada por el cliente (1-10): 7
Según los datos del cliente, el grupo es: [4]

Decisión del grupo 4
```

Figura 13. Datos arrojados por clustering 2

Se ha puesto a prueba nuevamente el algoritmo de clustering, donde hemos entregado parámetros distintos, como decisión de nuestro modelo se ha guardado el cliente al grupo 4; los datos entregados indican que el cliente a comprado en la sucursal 3, de la cual es cliente miembro, su género es femenino y ha adquirido 4 artículos de catalogados como artículos de moda; cada uno de estos con un precio de \$100, para un total de \$400; el cliente al momento de realizar el pago lo hace mediante chequera electrónica y ha brindado una calificación de 7.

Validación modelo Regresión con múltiples entradas.

Para la validación es importante recordar que este cuenta con 2 modelos, ambas con un error aproximado de 1,51 y el otro modelo un error de 1.85 ambas de forma aproximada.

Este modelo ya puede predecir aproximadamente la calificación que pueda entregar un usuario con base a sus compras, genero, y monto de la compra entre otros.

```
#Se ingresan los datos de entrada para generar una predicción
Nueva_entrada = np.zeros((1,8))
Nueva_entrada[0,0]=float(input('Ingrese la sucursal donde compro el cliente 1,2,3: '))
Nueva_entrada[0,1]=float(input('¿Cliente es miembro? 1 Si, 2, No: '))
Nueva_entrada[0,2]=float(input('Ingrese genero del usuario 1 Masculino - 0 Femenino: '))
Nueva_entrada[0,3]=float(input('Ingrese la categoria de producto: '))
Nueva_entrada[0,4]=float(input('Ingrese precio unitario : '))
Nueva_entrada[0,5]=float(input('Ingrese cantidad comprada: '))
Nueva_entrada[0,6]=float(input('Ingrese Total: '))
Nueva_entrada[0,7]=float(input('Ingrese el metodo de pago: '))

Proyeccion_1 = Modelo_1.predict(Nueva_entrada)
Proyeccion_2 = Modelo_2.predict(Nueva_entrada)

print('')
print('')
print('Según los datos ingresados, la proyección del nivel de satisfacción, usando KNN será: ',Proyeccion_1[0])
print('')
print('Según los datos ingresados, la proyección del nivel de satisfacción, usando ANN será: ',Proyeccion_2[0])
```

Figura 14. Código para solicitud de datos por regresión

Para fines de mostrar los resultados se ha puesto a prueba el modelo, arrojando los siguientes resultados.

```
Ingrese la sucursal donde compro el cliente 1,2,3: 3
¿Cliente es miembro? 1 Si, 2, No: 1
Ingrese genero del usuario 1 Masculino - 0 Femenino: 1
Ingrese la categoria de producto: 40
Ingrese precio unitario : 60
Ingrese cantidad comprada: 2
Ingrese Total: 120
Ingrese el metodo de pago: 2

Según los datos ingresados, la proyección del nivel de satisfacción, usando KNN será: 7.2
Según los datos ingresados, la proyección del nivel de satisfacción, usando ANN será: 7.574879628430478
```

Figura 15. Datos entregados por regresión 1

Para el ejemplo anterior hemos indicado que nuestro cliente ha comprado en la sucursal 3, en donde es miembro de nuestro supermercado, su genero es masculino, ha comprado 2 productos de categoría deportes y viajes, ambos artículos de 60 cada uno, para un total de 120, y el cual ha pagado en efectivo; su posible calificación basándose en ambos modelos oscila entre el 7,2 y 7,6 aproximadamente.

```
Ingrese la sucursal donde compro el cliente 1,2,3: 1
¿Cliente es miembro? 1 Si, 2, No: 1
Ingrese genero del usuario 1 Masculino - 0 Femenino: 0
Ingrese la categoria de producto: 20
Ingrese precio unitario : 30
Ingrese cantidad comprada: 3
Ingrese Total: 90
Ingrese el metodo de pago: 3

Según los datos ingresados, la proyección del nivel de satisfacción, usando KNN será: 5.24
Según los datos ingresados, la proyección del nivel de satisfacción, usando ANN será: 5.740309767054774
```

Figura 16. Datos entregados por regresión 2

Según la presente imagen, evidenciamos que el nivel de satisfacción de este usuario se encuentra entre 5,2 y 5,7; a diferencia de los datos anteriores este cliente ha comprado en la sucursal uno, es miembro del supermercado, de género femenino, y quien adquirió 3 productos de hogar y estilo de vida, cada articulo por un valor de \$30 para un total de \$90.

Conclusiones

Gracias a la información suministrada por el supermercado Merk+, y gracias a los modelos utilizando Machine Learning e Inteligencia Artificial, hemos brindado no solo una si no dos soluciones que le permitirán en primer lugar agrupar sus clientes, para tomar acciones o estrategias en aras de mejorar su nivel de satisfacción y en segundo lugar, se le brinda un modelo predictivo que puede ayudar a el supermercado a predecir que posibles aspectos son los que influyen más dentro de la calificación del supermercado.

Utilizando las estrategias de Machine Learning le permitirá a la cadena de supermercados llegar de mejor manera a sus clientes, brindando gran ventaja contra su competencia, puesto que estará ofreciendo una experiencia mucho más personalizada a todos sus clientes, demostrando que son importantes para la organización, siendo un factor diferencial e innovador dentro de su ciudad.

Gracias a esta implementación de estos modelos, no solamente pueden ser aplicados en aspecto de calificaciones, si no también que pueden ser en la cantidad de stocks en su inventario, ventas, predicciones en costos de productos, entre otras funciones que le pueden entregar estos modelos, siempre y cuando estén correctamente programados para su ejecución.

Referencias Bibliográficas

Sistemas de recomendación: uso de la IA para mejorar la relevancia y el valor. (s. f.). Intel. <https://www.intel.la/content/www/xl/es/artificial-intelligence/recommendation-systems.html>

GraphEverywhere, E. (2019, 2 diciembre). Sistemas de recomendación | Qué son, tipos y ejemplos. GraphEverywhere. <https://www.grapheverywhere.com/sistemas-de-recomendacion-que-son-tipos-y-ejemplos/>

Munar, P., & Cyberclick. (s. f.). Sistemas de recomendación: ¿qué són y cómo pueden ayudar a tu negocio online? <https://www.cyberclick.es/numerical-blog/sistemas-de-recomendacion-que-son-como-pueden-ayudar-a-tu-negocio-online>

DelAlmeida. (2023, 26 septiembre). De qué manera los sistemas de recomendación pueden ayudarte a conseguir más ventas? Datosciencia. <https://www.datosciencia.com/post/sistemasderecomendaci%C3%B3n>

Gonzalez, L. (2020b, agosto 18). Sistema de recomendaciones. Aprende IA. <https://aprendeia.com/sistema-de-recomendaciones-inteligencia-artificial/>

Galindo, S., & Galindo, S. (2024b, octubre 11). Los algoritmos deciden dos de cada tres compras 'online' en España. Autónomos y Emprendedores. <https://www.autonomosyemprendedor.es/articulo/todo-digital/algoritmos-deciden-cada-compras-online-espana/20241010132752038860.html>

Pérez, A. A., & Close, J. G. (2015). Sistemas de recomendación. Robots Autónomos: Navegación.

info@smartup.es. (2020, 30 julio). Sistemas de Recomendación: Todo lo que necesitas saber sobre los algoritmos usados por Amazon, Spotify y Netflix. Blog Smartup. <https://blog.smartup.es/sistemas-de-recomendacion-algoritmos-usados-por-amazon-spotify-netflix/>

What is a Recommendation System? (s. f.-b). NVIDIA Data Science Glossary. <https://www.nvidia.com/en-us/glossary/recommendation-system/>

Online grocery recommendation using machine learning. (s. f.-b). <https://www.wavegrocery.com/blogpost/understanding-the-need-for-personalized-recommendations-in-online-grocery>

Arsys. (s. f.-a). Algoritmos de recomendación Machine Learning. <https://www.arsys.es/blog/sistemas-recomendacion-machinelearning>

Lee, I. (2023, 12 marzo). Sistema de recomendación Python y Machine Learning | Medium. Medium. <https://ivan-lee.medium.com/sistema-de-recomendacion-con-python-y-machine-learning-50858941b2bc>

González, B. A. (s. f.). Sistemas de recomendación de contenido con Machine Learning – Cleverdata. <https://cleverdata.io/sistemas-recomendacion-machine-learning/>

Jauregui, A. F. (2024, 21 septiembre). Sistema de Recomendación con Python. Ander Fernández. <https://anderfernandez.com/blog/sistema-de-recomendacion-con-python/>

Zaragoza, J., & Cyberclick. (s. f.). Data Science: cómo crear un sistema de recomendación con machine learning. <https://www.cyberclick.es/numerical-blog/data-science-como-crear-un-sistema-de-recomendacion-con-machine-learning>