



UNIVERSIDAD DE CHILE

FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS

DEPARTAMENTO DE INGENIERÍA INDUSTRIAL

**EVALUACIÓN Y DISEÑO DE UN MODELO DE RECOMENDACIONES PARA
UNA COMPAÑÍA DE CONSUMO MASIVO**

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL INDUSTRIAL

CRISTIAN MAURICIO VALDÉS SALAMANCA

PROFESOR GUÍA:

ALEJANDRA PUENTE CHANDÍA

MIEMBROS DE LA COMISIÓN:

LUIS ABURTO LAFOURCADE

ERICK MENDEZ GUZMAN

SANTIAGO DE CHILE

2019

**RESUMEN DE LA MEMORIA PARA
OPTAR AL TÍTULO DE:** Ingeniero Civil
Industrial
POR: Cristian Mauricio Valdés Salamanca
FECHA: 27/07/2019
PROFESOR GUÍA: Alejandra Puente Chandía

EVALUACIÓN Y DISEÑO DE UN MODELO DE RECOMENDACIONES PARA UNA COMPAÑÍA DE CONSUMO MASIVO

La presente memoria evalúa el modelo de recomendación SVD para un set de datos transaccional en una empresa de consumo masivo. Las recomendaciones de este modelo buscan acertar en potenciales compras de productos por parte de pequeñas bodegas y puestos de mercado pertenecientes al canal de venta tradicional del Perú.

Este problema es relevante dado que el proceso de venta se reduce a solo a cobrar y tomar pedidos. Una sugerencia personalizada cambia la situación por lo que puede ser de gran impacto. Es por esto que los objetivos de la presente memoria se centran en aumentar a través del modelo SVD la tasa de aceptación de productos por parte de clientes.

El modelo SVD utiliza la matriz de valoraciones de productos por parte de los clientes. El modelo permite descomponer la matriz en sus valores singulares y reducir su dimensionalidad, esto a su vez permite agrupar la información esencial en dos matrices que guardan los factores latentes de los clientes en una y de los productos en otra. Dada la reducción de dimensionalidad, el producto entre las matrices de factores latentes es un aproximado de la matriz real. Para lograr obtener los factores latentes más precisos que den un resultado más parecido a la matriz real de valores conocidos, se utiliza la optimización de la gradiente descendente. Una vez ajustados los factores latentes se puede reconstruir la matriz de valoraciones completa, la reconstrucción de la información de valoración que no se tenía en la matriz original, son las predicciones del modelo.

El modelo SVD sugiere productos distintos a los valorados por el cliente, se espera que el experimento tenga éxito en más casos del indicador de productos distintos. Lamentablemente en el experimento realizado en 4 semanas, la mayoría de los perfiles evaluados no se logró un mejor indicador. Salvo en el perfil específico de Limpieza que se logró en promedio vender 6 veces más productos distintos que el grupo de control. Este número es estadísticamente significativo. El ratio de vendidos es alto puesto que en el grupo de control se ven muy pocos productos no comprados anteriormente.

En conclusión, se observa que el modelo presenta problemas en matrices masivas y altamente dispersas, se observa también que, si bien en un perfil pequeño se vende más unidades, lo hace en productos más económicos. Para mejorar este modelo se propone que al ser una base transaccional, se agrupen los productos iguales que se diferencien únicamente en la cantidad de unidades contenidas, también se propone evaluar un modelo más reducido en que solo se recomienden los productos que mayor margen entreguen. También se recomienda que se busquen parámetros más precisos de aprendizaje para un dataset transaccional.

AGRADECIMIENTOS

En esta sección quiero en primer lugar agradecer a mi familia, quienes en todo momento de mi vida me han brindado su constante apoyo para poder lograr cada uno de los desafíos que me han tocado. Por esto, muchísimas gracias Mamá, Papá, Rodrigo y Nicole. Me siento muy feliz de la familia que formamos.

También agradezco a cada uno de mis amigos en esta etapa universitaria. Gracias a ustedes, esta etapa será un muy lindo recuerdo siempre. Es por esto que mando un especial agradecimiento a Diego Freire, Danton Freire, Franco Robbiano, Cesar Arriagada, Felipe Garrido, Mario Garrido, Jaime Sanz, Joaquín Galindo, Matías Yañez, Daniel Aviv, Tomás Wolf, Iván Castro, Carolina Mayol, Álvaro Sepúlveda, y Daniela Araneda quienes han sido super incondicionales siempre.

Quiero agradecer también a todos esos que siempre han estado ahí, desde siempre, que pese a que no los veo seguido, son igual de geniales para mí. Por esto le mando agradecimientos a mis ex compañeros de colegio, Víctor Aguilera, Diego Ibáñez, Felipe San Martín, Sebastián Piña y a todos los compipas que cada vez que los veo, se pasa genial.

Además, agradecer a mis tíos y a mis primitos, sobre todo al Tomás Lira y la Rocío Valdés, ustedes son verdaderos hermanitos menores para mí.

También quiero agradecer al departamento de ingeniería industrial, sobre todo a Mónica Valdebenito que en todo el proceso de titulación ha sido una gran guía y apoyo.

Finalmente quiero agradecer a los profesores que me acompañaron en esta memoria, Alejandra Puente, Luis Aburto y Erick Méndez que fueron un gran apoyo en este proceso final de la carrera, he aprendido muchísimo gracias a ustedes.

Muchas gracias a todos!!!!

TABLA DE CONTENIDO

1. ANTECEDENTES GENERALES	12
1.1 Características de la empresa	12
1.2 Mercado y características	13
2. JUSTIFICACIÓN DEL PROYECTO	16
2.1 Ventajas del canal tradicional	16
2.2 Problema en la distribución	16
2.3 Actual motor de recomendaciones utilizado	17
2.4 Memoria realizada directamente relacionada.....	18
2.4.1 Hallazgos basados en la cantidad de recomendaciones por estrategia	18
2.4.2 Hallazgos basados en la posición que tiene una estrategia con respecto a las demás	18
2.4.3 Hallazgos basados en la implementación de un filtro colaborativo	20
2.5 Justificaciones adicionales	21
3. DESCRIPCIÓN DEL PROYECTO	22
4. OBJETIVOS.....	23
4.1 Objetivo general.....	23
4.2 Objetivos específicos.....	23
5. ALCANCES	23
6. RESULTADOS ESPERADOS	24
7. MARCO CONCEPTUAL.....	25
7.1 Sistemas de Recomendación	25
7.2 Tipos de sistemas de recomendación	25
7.3 Tipos de filtros colaborativos	27
7.3.1 Filtros colaborativos basados en la memoria.....	27
7.3.2 Filtros colaborativos basados en un modelo	28
7.3.3 Filtros colaborativos híbridos	28
7.4 Modelo de recomendación SVD	29
7.4.1 Funcionamiento tradicional del modelo	29
7.4.2 Funcionamiento corregido del modelo SVD	33
7.5 Indicadores para medir la calidad de los modelos.....	34
7.5.1 Root mean squared error (RMSE).....	34
7.5.2 Mean absolut error (MAE)	35
8. METODOLOGÍA	36

9. DESARROLLO METODOLÓGICO	39
9.1 Comprensión de los datos	39
9.1.1 Fuente de los datos	39
9.1.2 Recopilación inicial de los datos.....	39
9.1.3 Análisis descriptivo	43
9.2 Preparación de los datos.....	50
9.2.1 Selección de datos	50
9.2.2 Limpieza y transformación de los datos.....	51
9.3 Modelamiento del sistema de recomendación.....	54
9.3.1 Selección de técnica de modelado y construcción.....	54
9.3.2 Descripción de la comparación con otros modelos.....	54
9.3.3 Construcción del modelo SVD	54
9.3.4 Comparación del modelo SVD con similares	55
9.3.5 Generación de recomendaciones.....	57
9.4 Diseño Experimental	58
9.4.1 Descripción del experimento e indicadores.	58
9.4.2 Descripción de la construcción de grupos de control y experimental	59
9.4.3 Aprendizajes de la fase de prueba del experimento	59
9.4.4 Hipótesis generales	60
9.4.5 Hipótesis referidas al rendimiento del modelo propuesto versus el utilizado por la empresa.....	62
9.4.6 Hipótesis referidas al rendimiento del modelo propuesto por perfil versus el mismo modelo ajustado de manera global.....	63
9.5 Evaluación de resultados.....	64
9.5.1 Explicación inicial de la evaluación	64
9.5.2 Resultados para la hipótesis que compara el modelo ajustado de manera global con el usado por la empresa.....	66
9.5.3 Resultados para las hipótesis que comparan el rendimiento de las bodegas versus los puestos de mercado.	67
9.5.4 Resultados del experimento cuando se alterna la posición de la estrategia.....	69
9.5.5 Resultados de las hipótesis referidas al rendimiento del modelo propuesto versus el utilizado por la empresa.	70
1) Resultados para el perfil Abarroteros.....	70
9.5.6 Resultados de las hipótesis referidas al rendimiento del modelo propuesto por perfil versus el mismo modelo ajustado de manera global.	78
10. CONCLUSIONES	86
11. RECOMENDACIONES.....	88

12. TRABAJO FUTURO	89
13. BIBLIOGRAFÍA.....	90
14. ANEXOS.....	93

ÍNDICE DE TABLAS

Tabla 1: Efectividad según posición para la estrategia frecuentes.	19
Tabla 2: Efectividad según posición para la estrategia perfil.	19
Tabla 3: Efectividad según posición para la estrategia asociados.	19
Tabla 4: Primera semana de experimentos de la implementación de un filtro colaborativo.	20
Tabla 5: Segunda semana de experimentos de la implementación de un filtro colaborativo.	20
Tabla 6: Tercera semana de experimentos de la implementación de un filtro colaborativo.	20
Tabla 7: Cuarta semana de experimentos de la implementación de un filtro colaborativo.	21
Tabla 8: Matriz de valoraciones de los clientes por los productos del dataset completo. Fuente: Elaboración propia.	51
Tabla 9: Información de los datos de cada perfil. Fuente: Elaboración propia.	53
Tabla 10: MAE de cada modelo en cada perfil. Elaboración propia.	56
Tabla 11: RMSE de cada modelo en cada perfil. Elaboración propia.	56
Tabla 12: Códigos de productos recomendados para el perfil panadería. Elaboración propia.	57
Tabla 13: Resumen resultados modelo SVD vs Modelo utilizado por la empresa.	78
Tabla 14: Resumen de calibración global vs específica.	85
Tabla 15: Test t para venta PS entre Bodegas y Puestos de Mercado.	98
Tabla 16: Test t para Efectividad entre Bodegas y Puestos de Mercado.	99
Tabla 17: Test t para el indicador Productos Distintos entre Bodegas y Puestos de Mercado.	100
Tabla 18: Test t para Venta PS entre la posición 1 y la posición 2.	102
Tabla 19: Test t para Efectividad entre la posición 1 y la posición 2.	102
Tabla 20: Test t para Productos distintos entre la posición 1 y la posición 2.	103
Tabla 21: Test t para Venta PS entre la posición 2 y la posición 3.	103
Tabla 22: Test t para Efectividad entre la posición 2 y la posición 3.	103
Tabla 23: Test t para Productos distintos entre la posición 2 y la posición 3.	104
Tabla 24: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Abarroteros.	106
Tabla 25: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Abarroteros y además eliminando productos vistos y no comprados.	106
Tabla 26: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Abarroteros.	106
Tabla 27: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Abarroteros y además eliminando productos vistos y no comprados.	107

Tabla 28: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Abarroteros	107
Tabla 29: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Abarroteros y además eliminando productos vistos y no comprados.	107
Tabla 30: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica al perfil abarroteros en m1g1 y de manera global en m1g2.	108
Tabla 31: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica al perfil abarroteros en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.....	108
Tabla 32: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica al perfil abarroteros en m1g1 y de manera global en m1g2.	108
Tabla 33: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica al perfil abarroteros en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.....	109
Tabla 34: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera específica al perfil abarroteros en m1g1 y de manera global en m1g2.....	109
Tabla 35: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera específica al perfil abarroteros en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.....	109
Tabla 36: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Food Service	111
Tabla 37: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Food Service y además eliminando productos vistos y no comprados.	111
Tabla 38: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Food Service.....	112
Tabla 39: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Food Service y además eliminando productos vistos y no comprados.	112
Tabla 40: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Food Service.....	112
Tabla 41: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Food Service y además eliminando productos vistos y no comprados.	113
Tabla 42: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica a Food Service en m1g1 y de manera global en m1g2.....	113
Tabla 43: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.	113
Tabla 44: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica a Food Service en m1g1 y de manera global en m1g2.	114
Tabla 45: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica a Food Service en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.....	114
Tabla 46: Test t para Productos distintos utilizando el modelo SVD calibrado de manera específica a Food Service en m1g1 y de manera global en m1g2.	114
Tabla 47: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera específica a Food Service en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.....	115

Tabla 48: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Golosineros.....	117
Tabla 49: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Golosineros y además eliminando productos vistos y no comprados.....	117
Tabla 50: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Golosineros	118
Tabla 51: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Golosineros y además eliminando productos vistos y no comprados.	118
Tabla 52: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Golosineros	118
Tabla 53: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Golosineros y además eliminando productos vistos y no comprados.	119
Tabla 54: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica a Golosineros en m1g1 y de manera global en m1g2.	119
Tabla 55: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica en m1g1 a Golosineros y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados. Fuente: Elaboración propia. ...	119
Tabla 56: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica a Golosineros en m1g1 y de manera global en m1g2.....	120
Tabla 57: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica a Golosineros en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.....	120
Tabla 58: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera específica a Golosineros en m1g1 y de manera global en m1g2. Fuente: Elaboración propia.	120
Tabla 59: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera específica a Golosineros en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.....	121
Tabla 60: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Limpieza	123
Tabla 61: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Limpieza y además eliminando productos vistos y no comprados.	124
Tabla 62: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Limpieza.....	124
Tabla 63: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Limpieza y además eliminando productos vistos y no comprados.	124
Tabla 64: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Limpieza.....	125
Tabla 65: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Limpieza y además eliminando productos vistos y no comprados.	125
Tabla 66: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica a Limpieza en m1g1 y de manera global en m1g2.....	125
Tabla 67: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica a Limpieza en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.	126
Tabla 68: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica a Limpieza en m1g1 y de manera global en m1g2.	126

Tabla 69: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica a Limpieza en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.	127
Tabla 70: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera a Limpieza específica en m1g1 y de manera global en m1g2.	127
Tabla 71: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera específica a Limpieza en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.	128
Tabla 72: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Panaderías	130
Tabla 73: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Panaderías y además eliminando productos vistos y no comprados.	131
Tabla 74: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Panaderías	131
Tabla 75: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Panaderías y además eliminando productos vistos y no comprados.	131
Tabla 76: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Panaderías	132
Tabla 77: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Panaderías y además eliminando productos vistos y no comprados.	132
Tabla 78: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica al perfil Panaderías en m1g1 y de manera global en m1g2.	132
Tabla 79: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica a Panaderías en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.	133
Tabla 80: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica a Panaderías en m1g1 y de manera global en m1g2.	133
Tabla 81: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica a Panaderías en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.	133
Tabla 82: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera específica a Panaderías en m1g1 y de manera global en m1g2.	134
Tabla 83: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera específica a Panaderías en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.	134
Tabla 84: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Panaderías Bodega	136
Tabla 85: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Panaderías Bodega y además eliminando productos vistos y no comprados.	136
Tabla 86: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Panaderías Bodega.	137
Tabla 87: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Panaderías Bodega y además eliminando productos vistos y no comprados.	137
Tabla 88: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Panaderías Bodega.	137
Tabla 89: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Panaderías Bodega y además eliminando productos vistos y no comprados.	138

Tabla 90: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica a Panaderías Bodega en m1g1 y de manera global en m1g2.....	138
Tabla 91: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica a Panaderías Bodega en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.....	138
Tabla 92: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica a Panaderías Bodega en m1g1 y de manera global en m1g2.	139
Tabla 93: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica a Panaderías Bodega en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.....	139
Tabla 94: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera específica a Panaderías Bodega en m1g1 y de manera global en m1g2.	139
Tabla 95: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera específica a Panaderías Bodega en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.....	140

ÍNDICE DE ILUSTRACIONES

Ilustración 1: Modelo de distribución de la empresa.	13
Ilustración 2: Ejemplo de una bodega en el Perú.	14
Ilustración 3: Ejemplo de un puesto de mercado del Perú.	14
Ilustración 4: Proceso de venta con pedido sugerido	17
Ilustración 5: Descomposición de la matriz R en valores singulares.	31
Ilustración 6: Descomposición de la Matriz R luego de reducción de valores nulos de S en su diagonal.....	31
Ilustración 7: Simplificación de la descomposición SVD.	32
Ilustración 8: Resumen de la metodología de trabajo. Fuente: Elaboración propia.	36

ÍNDICE DE GRÁFICOS

Gráfico 1: Peso en porcentaje de ventas del canal tradicional en la región.....	15
Gráfico 2: Proyección de la distribución socioeconómica del Perú (2016).	15
Gráfico 3: Evolución de las ventas por tipo de transacción.....	43
Gráfico 4: Porcentaje de aporte PS a la venta total. Fuente: Elaboración propia.	43
Gráfico 5: Monto total vendido por año por cada perfil, año 2017 hasta mediados de octubre.....	44
Gráfico 6: Participación de las ventas totales de cada perfil en el año 2016.....	45
Gráfico 7: Participación de cada perfil en el año 2017.....	45
Gráfico 8: Cantidad de boletas emitidas por perfil y año.	46
Gráfico 9: Participación de cada perfil en el número de boletas durante año 2016.	47
Gráfico 10: Participación de cada perfil en el número de boletas durante año 2017.....	47
Gráfico 11: Número de clientes por perfil y año.....	48

Gráfico 12: Monto total vendido por cada boca de salida hasta agosto del año 2017.....	49
Gráfico 13: Participación en ventas de cada boca de salida en el año 2017.	49
Gráfico 14: Porcentaje de clientes por cada boca de salida en el año 2017.	50
Gráfico 15: Corrección de outliers del dataset global. Fuente: Elaboración propia.	53
Gráfico 16: Corrección de outliers del perfil abarroteros.	93
Gráfico 17: Corrección de outliers del perfil aderezos.	94
Gráfico 18: Corrección de outliers para el perfil food service.	94
Gráfico 19: Corrección de outliers para el perfil golosinero.	95
Gráfico 20: Corrección de outliers para el perfil limpieza.	95
Gráfico 21: Corrección de outliers para el perfil panaderías bodega.	96
Gráfico 22: Corrección de outliers para el perfil panaderías.....	96
Gráfico 23: Corrección de outliers para el perfil varios.....	97
Gráfico 24: Corrección de outliers para el perfil sin etiqueta.	97
Gráfico 25: Promedio semanal del indicador de venta PS para una muestra de bodegas y puestos de mercado.	98
Gráfico 26: Promedio semanal de la tasa de efectividad para bodegas y puestos de mercado.	99
Gráfico 27: Promedio semanal del indicador de productos distintos para bodegas y puestos de mercado.	100
Gráfico 28: Promedio semanal del indicador de venta PS cuando se utilizan distintas posiciones.	101
Gráfico 29: Promedio semanal de la tasa de efectividad cuando se utilizan distintas posiciones.	101
Gráfico 30: Promedio semanal del indicador de productos distintos cuando se utilizan distintas posiciones.	102
Gráfico 31: Promedio semanal del indicador de venta PS para los grupos del perfil abarroteros.	104
Gráfico 32: Promedio semanal de la tasa de efectividad de los grupos del perfil abarrotero.	105
Gráfico 33 Promedio semanal de la cantidad de productos vendidos distintos de los grupos del perfil abarrotero.	105
Gráfico 34: Promedio semanal del indicador de venta PS en el perfil Food Service.	110
Gráfico 35: Promedio semanal de la tasa de efectividad en el perfil Food Service.	110
Gráfico 36: Promedio semanal de la cantidad de productos PS vendidos distintos en el perfil Food Service.....	111
Gráfico 37: Promedio semanal del indicador de venta PS del perfil Golosineros.....	116
Gráfico 38: Promedio semanal de la tasa de efectividad del perfil Golosineros.	116
Gráfico 39: Promedio semanal de la cantidad de productos vendidos distintos del perfil Golosineros.....	117
Gráfico 40: Promedio semanal del indicador de venta PS para el perfil Limpieza.	122
Gráfico 41: Promedio semanal de la tasa de efectividad para el perfil Limpieza.....	122
Gráfico 42: Promedio semanal de la cantidad de productos distintos en el perfil Limpieza que no se habían vendido en las 12 semanas previas.	123
Gráfico 43: Promedio semanal del indicador de ventas PS del perfil Panaderías.	129
Gráfico 44: Promedio semanal de la tasa de efectividad del perfil Panaderías.	129
Gráfico 45: Promedio semanal de la cantidad de productos PS vendidos distintos en perfil Panaderías.	130
Gráfico 46: Promedio semanal del indicador de venta PS del perfil Panaderías Bodega.	135

Gráfico 47: Promedio semanal de la tasa de efectividad del perfil Panaderías Bodega. 135
Gráfico 48: Promedio semanal de la cantidad de productos PS vendidos distintos para el perfil Panaderías Bodega. Fuente: Elaboración propia. 136

1. ANTECEDENTES GENERALES

1.1 Características de la empresa

El trabajo de título es realizado con información de una empresa multinacional que se desempeña en la industria del consumo masivo. Los análisis realizados en el presente trabajo se enmarcan en el contexto peruano, por lo que salvo la descripción general de la empresa, la información presentada corresponderá al mercado de dicho país.

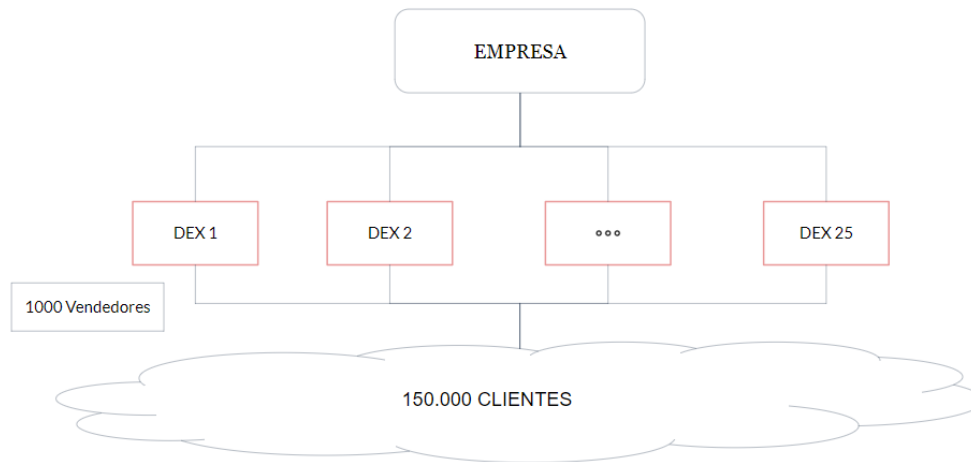
La compañía en sus operaciones de producción y comercialización cuenta con más de 5.000 empleados tanto en el Perú como en los demás países en donde participa. Para esto, tiene una cantidad no menor de plantas industriales distribuidas en países de Latinoamérica.

El número de marcas que gestiona la firma asciende a más de 100 que pueden ser encontradas en más de 23 países en el mundo. Estos productos pertenecen a 15 categorías distintas como por ejemplo las categorías de pastas, aceites, salsas, detergentes, galletas, harinas, entre otros.

Una de las ventajas competitivas que tiene la empresa es su estrategia que se centra en generar reconocimiento por parte de los consumidores. Esto lo logra contando con gamas de productos para todos los segmentos socioeconómicos de la población.

Gracias a que la firma cuenta con gamas de productos económicos, estándar y premium, logró gran penetración de mercado en el país. Donde cuenta con una red de venta de 25 distribuidores exclusivos y acuerdos con más de 150.000 bodegas y puestos de mercados que ayudan a tener una amplia cobertura geográfica. En las ilustraciones 2 y 3 se presenta lo que es una bodega y un puesto de mercado en el Perú.

Dado que aproximadamente son 150.000 bodegas y puestos de mercado que necesitan comprar productos, la empresa para el proceso de distribución utiliza distribuidores exclusivos (DEX). Las DEX acumulan una cantidad total de 1000 vendedores para atender a los clientes que son visitados 2 veces por semana por vendedores y productos distintos. El proceso macro se puede apreciar en la ilustración 1. Para incentivar el proceso, el salario de los vendedores cuenta con incentivos en que, si vende más, mayor será su salario.



*Ilustración 1: Modelo de distribución de la empresa.
Elaboración propia.*

En el Perú se cuenta con distintos competidores que corresponden a grandes empresas multinacionales.

1.2 Mercado y características

El mercado del consumo masivo en Perú mueve aproximadamente 15.000 millones de dólares por año, tiene como característica que la frecuencia de compra promedio de los peruanos se acerca a las 15 veces por mes y además se tiene que el ticket promedio de venta se encuentra entre 3 y 4 dólares. Otra de las principales características de este mercado es que se puede dividir en dos canales de ventas:

- 1) Canal moderno: Corresponde a las ventas realizadas en supermercados, hipermercados y comercio online. La cantidad de supermercados e hipermercados existentes en el país corresponden a 316 [1]. Las ventas realizadas por este tipo de canal corresponden al 33% de las ventas de la industria, es decir, corresponde a 3.720 millones de dólares.
- 2) Canal tradicional: Corresponde a las ventas realizadas por pequeñas bodegas y puestos de mercado, lugares muy similares al almacén de barrio en Chile. La cantidad de este tipo de puntos de venta es aproximadamente de 400.000 locales en el Perú. Este Canal tiene la característica de que posee el 67% de la participación en ventas de la industria, es decir, el mercado en el canal tradicional corresponde a aproximadamente a 7.553 millones de dólares [2]. En la ilustración 2 y 3 se pueden apreciar ejemplos de una bodega y puestos de mercado del Perú respectivamente.



*Ilustración 2: Ejemplo de una bodega en el Perú.
Fuente: Agencia Peruana de Noticias.*



*Ilustración 3: Ejemplo de un puesto de mercado del Perú.
Fuente: Mundoporlibre.com.*

En el contexto latinoamericano, tal como se puede apreciar en el gráfico 1, se puede apreciar que Perú es uno de los países que mayor importancia tiene el canal tradicional en ventas.




Gráfico 1: Peso en porcentaje de ventas del canal tradicional en la región.
Fuente: Kantar WorldPanel.

Existe diferencia entre el tipo de persona de la capital Lima y de todo el Perú dado que en Lima 7 de cada 10 personas [3] compra en canal tradicional y en el Perú el promedio es de 9 de cada 10 personas.

La importancia del canal tradicional del país se puede explicar por su distribución socioeconómica. Tal como se puede apreciar en el gráfico 2, un 60,6% de la población, pertenece a los segmentos socioeconómicos vulnerables D y E, donde los trabajos son mucho más inestables en que su salario es diario, variable y poco constante. Esta característica influye en el comportamiento de compra del shopper peruano, puesto que favorece a que realice compras más pequeñas, pero con frecuencia mayor.




Gráfico 2: Proyección de la distribución socioeconómica del Perú (2016).
Fuente: APEIM.

2. JUSTIFICACIÓN DEL PROYECTO

2.1 Ventajas del canal tradicional

Una de las ventajas del canal tradicional es que tiene una gran proporción de ventas en el país versus el canal moderno. A parte de eso, cabe destacar que la empresa guarda interés en el mercado tradicional porque el margen de las ventas realizadas a un puesto de mercado o bodega es mayor que el que se logra en el canal moderno. Esto es debido al poder de negociación que tiene muchas veces el canal moderno al tener mayor tamaño relativo versus a un pequeño puesto de mercado o bodega.

Otra de las ventajas es que el canal tradicional mejora la liquidez con respecto al canal moderno puesto que se paga a 7 días. Bastante distinto es realizar la venta a un supermercado o hipermercado que realiza el pago a 90 días.

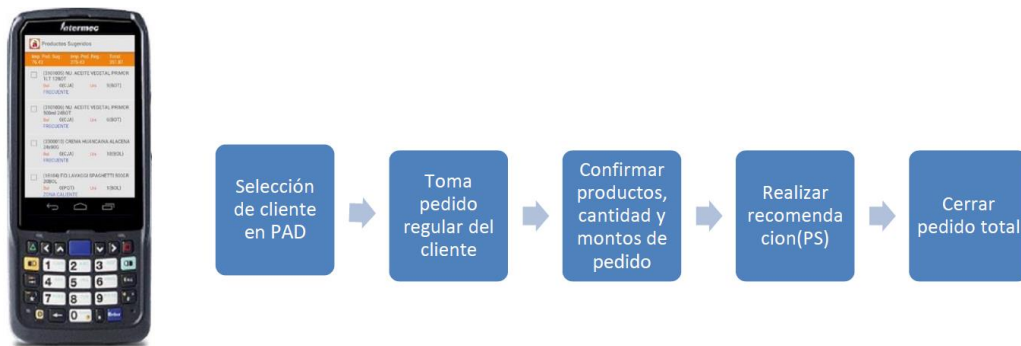
2.2 Problema en la distribución

Tal y como se describió anteriormente, la empresa por medio de sus DEX cuenta con 1000 vendedores que atienden a aproximadamente a 150.000 clientes, dos veces por semana por vendedores y productos distintos.

Esta proporción de clientes, vendedores y número de visitas a la semana genera que cada vendedor tenga que visitar a más de 50 clientes por día. El visitar a esa cantidad de clientes produce que cada vendedor cuente con menos de 7 minutos para realizar la venta lo que a su vez deriva en una peor calidad del proceso de venta.

Un proceso de venta de mala calidad tiende a reducir a los vendedores a meros cobradores y tomadores de pedido. Esto es que el vendedor no alcanza a ofrecer productos de su cartera y por lo tanto dificulta el crecimiento de sus ventas y por lo tanto el crecimiento de su salario. Ante este problema surge una oportunidad de mejora.

Esta mejora consiste en la implementación de un motor de recomendaciones que posterior a la confirmación del pedido por parte del cliente, sugiere productos que el cliente podría aceptar. Este proceso queda detallado en la ilustración 4.



*Ilustración 4: Proceso de venta con pedido sugerido
Fuente: Ignacio Díaz, (2017), memoria [4]*

2.3 Actual motor de recomendaciones utilizado

El actual motor de recomendaciones funciona por medio de un dispositivo PALM que al inicio de la semana se le cargan desde el sistema las sugerencias en base a sus transacciones pasadas. Este sistema descarga en el dispositivo una lista de productos a sugerir en un orden de prioridad en el que se ofrece el primero en la lista que no haya sido confirmada en la toma del pedido. Estas listas de prioridades de pedido sugerido se realizan en base a 3 estrategias comerciales:

- **Frecuentes:** Consiste en recomendar un producto que siempre suele estar en la canasta comprada pero que luego de realizar la confirmación de compra, no se encuentra. Entonces el propósito de esta estrategia es mantener el nivel de compras del cliente.
- **Asociados:** La recomendación en este tipo de estrategia se realizan mediante reglas de asociación entre productos de la canasta actual con las transacciones conjuntas del perfil de cliente al cual pertenece. El principal objetivo de esta estrategia es incrementar el mix de productos que compra habitualmente el cliente.
- **Perfil:** Los productos recomendados por este tipo de estrategia son los que se encuentran en la canasta promedio de los clientes de su perfil pero que no esté siendo pedido por el cliente. El propósito de esta estrategia también es aumentar el mix de productos del cliente, pero también tiene el propósito de potenciar su acercamiento al perfil al cual pertenece.

Actualmente el motor de recomendaciones utilizado por la compañía incrementa las ventas en un 5,1% que corresponden a 39,3 millones de dólares al año 2017. Por esto existe la motivación por intentar mejorar el motor, puesto que, dado el tamaño de la base de datos, se tiene la hipótesis de que el desarrollo de un nuevo modelo o estrategia que

involucre Machine Learning podría aumentar este porcentaje. En el caso en que se lograra un 1% de mejora en el incremento de las ventas, se lograría un aumento en las ventas de 7,7 millones de dólares. En el caso en que se lograra un 5% de mejora en el incremento de las ventas, esto se traduciría en 35 millones de dólares de venta incremental. En un caso revolucionario que se lograra un 10% de incremento en las ventas, esto significaría un aumento en las ventas de 70 millones de dólares.

2.4 Memoria realizada directamente relacionada

En el primer semestre del año 2017 en la memoria de Ignacio Diaz [4], se realizó un estudio que involucra la misma empresa y situación. Los resultados de esta memoria sirven como base para realizar la investigación. Entre los principales hallazgos encontrados en esta memoria se encuentran:

2.4.1 Hallazgos basados en la cantidad de recomendaciones por estrategia

En este ámbito se realizaron experimentos en los cuales no existieron diferencias significativas entre la cantidad de recomendaciones a realizar por estrategia y la efectividad en realizar la venta.

2.4.2 Hallazgos basados en la posición que tiene una estrategia con respecto a las demás

Anteriormente existía una estrategia más aparte de la estrategia frecuentes, perfil y asociados. Esta estrategia se llamaba zonas calientes, y dado que la efectividad que poseía era relativamente baja en este mercado, fue eliminada.

Es por esto que para los experimentos se consideraron 4 posiciones en las que se iba variando la posición de cada estrategia y evaluando su efectividad en la venta. Es decir, se varía el orden de visualización desplegada en el PAD de las recomendaciones según su estrategia.

El indicador utilizado para medir el rendimiento de cada estrategia fue la tasa de efectividad que se define como sigue:

$$Tasa\ de\ efectividad = \frac{N^{\circ}\ productos\ recomendados\ aceptados}{N^{\circ}\ productos\ recomendados\ visualizados} \quad (2.4.2.1)$$

Para tener una impresión del tamaño de la variación, se tiene que las efectividades promedio según posición para la estrategia frecuentes son:

Grupo	Efectividad Promedio	Desviación Estándar
Control (Posición 1)	5,1%	16,8%
Grupo 1 (Posición 2)	1,3%	8,7%
Grupo 2 (Posición 3)	4,8%	15,5%
Grupo 3 (Posición 4)	3,3%	12,7%

*Tabla 1: Efectividad según posición para la estrategia frecuentes.
Fuente: Memoria Ignacio Diaz [4].*

Para la estrategia perfil, se tienen:

Grupo	Efectividad Promedio	Desviación Estándar
Control (Posición 2)	3,8%	15,0%
Grupo 1 (Posición 3)	4,9%	16,2%
Grupo 2 (Posición 4)	1,7%	10,1%
Grupo 3 (Posición 1)	5,6%	15,3%

*Tabla 2: Efectividad según posición para la estrategia perfil.
Fuente: Memoria Ignacio Diaz [4].*

Para la estrategia asociados son:

Grupo	Efectividad Promedio	Desviación Estándar
Control (Posición 3)	4,5%	14,3%
Grupo 1 (Posición 4)	4,8%	13,8%
Grupo 2 (Posición 1)	5,1%	16,5%
Grupo 3 (Posición 2)	2,3%	10,1%

*Tabla 3: Efectividad según posición para la estrategia asociados.
Fuente: Memoria Ignacio Diaz [4].*

Si bien, la primera posición siempre tuvo mejor efectividad y la segunda posición nunca tuvo la siguiente mejor efectividad, se concluyen que si existen diferencias significativas cuando se varía la posición en función de los resultados de un test de ANOVA de un factor.

2.4.3 Hallazgos basados en la implementación de un filtro colaborativo

Finalmente, en la memoria de Ignacio Diaz, se implementó el algoritmo de filtro colaborativo de kNN¹ Basic que consiste en recomendar productos calculando similitudes y recomendando según las menores distancias.

Este experimento tuvo una duración de cuatro semanas y tuvo los siguientes resultados:

- Semana del 26 de diciembre del 2016:

Grupo	Efectividad Promedio	Desviación Estándar
Control	0%	0%
Filtro Colaborativo	0%	0%

*Tabla 4: Primera semana de experimentos de la implementación de un filtro colaborativo.
Fuente: Memoria Ignacio Diaz.*

- Semana del 02 de enero del 2017:

Grupo	Efectividad Promedio	Desviación Estándar
Control	0,8%	7,9%
Filtro Colaborativo	0,6%	7,7%

*Tabla 5: Segunda semana de experimentos de la implementación de un filtro colaborativo.
Fuente: Memoria Ignacio Diaz.*

- Semana del 09 de enero del 2017:

Grupo	Efectividad Promedio	Desviación Estándar
Control	0,9%	7,9%
Filtro Colaborativo	0,6%	7,6%

*Tabla 6: Tercera semana de experimentos de la implementación de un filtro colaborativo.
Fuente: Memoria Ignacio Diaz.*

¹K-Nearest Neighborhood

- Semana del 23 de enero del 2017:

Grupo	Efectividad Promedio	Desviación Estándar
Control	0,5%	4,1%
Filtro Colaborativo	0,6%	5,4%

Tabla 7: Cuarta semana de experimentos de la implementación de un filtro colaborativo.
Fuente: Memoria Ignacio Diaz.

En el experimento no se encuentran diferencias significativas en las 3 primeras semanas, pero en la semana del 23 de enero, se encuentra una diferencia significativa a un 90% de confianza. Englobando a todas las semanas, no se encuentran diferencias significativas.

Una de las hipótesis de esta memoria fue que, al contarse con una base de datos transaccional, utilizar un algoritmo de filtro colaborativo en base a contenido mejoraría la predicción de las recomendaciones porque se utilizaría más intensivamente los datos. Es esta una de las razones por las cuales fue utilizado el modelo kNN Basic.

2.5 Justificaciones adicionales

Dado que el filtro colaborativo utilizado en la memoria de Ignacio Diaz, solo fue utilizado en la última posición, se tuvo complicaciones para determinar su auténtica efectividad, dada la baja efectividad general de la posición utilizada.

Este algoritmo, fue utilizado solo en el perfil abarroteros de los datos, que es el mayoritario. Entonces, surge la duda si existen algunos perfiles más susceptibles a la sugerencia por filtro colaborativo.

Además, un problema que suelen tener los modelos que utilizan matrices de información de cliente vs productos, es que pierden precisión en la medida que aumenta la dispersión de la información. Es decir, que mientras más grande sea la matriz y más valores vacíos tenga, más imprecisa es la predicción [5].

Es por esto, que surge la oportunidad de buscar un algoritmo de filtro colaborativo que sea más específico para lidiar con la dispersión de la matriz de datos.

Las recomendaciones actuales que intentan aumentar el mix por parte de la compañía pueden o no haber sido comprados por el cliente en cierto periodo de tiempo atrás. Entonces se intentará con un modelo que recomiende estrictamente productos que no ha

comprado en el periodo a entrenar el modelo. El recomendar esto podría ayudar a aumentar el mix de productos que llevan los clientes.

Finalmente se tiene la hipótesis de que si se prueban distintos modelos de filtros colaborativos que ajusten más específicamente a los perfiles utilizados por la empresa, se va a tener un mejor rendimiento que la utilización de un modelo global.

3. DESCRIPCIÓN DEL PROYECTO

El presente proyecto busca diseñar y evaluar el algoritmo recomendador SVD cuyas siglas significan Singular Value Descomposition. ya sea de un modo que reemplace o complemente una estrategia de venta ya existente. Esto debido a que una recomendación en una cuarta posición tiene muy poca efectividad según la memoria de Ignacio Diaz. Esto puede deberse a una sobrecarga de recomendaciones que hace que el vendedor no siga ofreciendo productos para no saturar al cliente.

Dado el punto anterior, resulta muy interesante conocer el funcionamiento de los modelos de machine learning que puedan complementar el funcionamiento de una estrategia en lugar de agregar otra. A esto se le llama ensamblaje de modelos de recomendación en donde se busca complementar una estrategia con aspectos adicionales que van en favor de la estrategia como concepto.

En este caso, se quiere evaluar el impacto del modelo en la efectividad de la recomendación, en el flujo de ventas y cantidad de productos vendidos que no se habían vendido en cierta cantidad de tiempo.

El modelo SVD clásico procesa valoraciones de todos los clientes a los productos en una gran matriz. Este procesamiento permite encontrar el producto más idóneo a recomendar según el comportamiento propio y de sus símiles. Para el caso de la presente memoria, se utilizará como medida de valoración la frecuencia de compra de un producto en el tiempo.

Si se intenta comparar el objetivo del modelo SVD con el de la estrategia asociados se puede apreciar que existe mayor similitud que con la estrategia frecuentes, dado que SVD y asociados intentan aumentar el mix. De todos modos, la similitud estratégica sigue siendo mayor con el objetivo de la estrategia perfil, ya que el objetivo de asociados es el de sugerir un producto que tiene bastantes transacciones conjuntas en tickets de venta con algún producto que haya llevado el cliente. En cambio, la recomendación de la estrategia perfil, se encuentra más orientada a las características conjuntas de un grupo similar, tal y como lo realiza el modelo SVD.

Entonces, el presente proyecto consiste en primer lugar aprender sobre los sistemas de recomendación existentes para luego aplicar y evaluar el modelo SVD con mayor detalle aplicando la metodología Crisp-DM.

Los resultados del algoritmo se evaluarán por medio de experimentos que permitan medir el rendimiento del modelo comparado al sistema de asociaciones con el cual actualmente genera recomendaciones la empresa.

Además de evaluar el rendimiento de los modelos, se levantarán hipótesis que permitan obtener conocimiento sobre el comportamiento de los clientes frente a los modelos de recomendación.

4. OBJETIVOS

4.1 Objetivo general

Implementar y evaluar el modelo de recomendación SVD para aumentar la venta de productos vendidos por concepto de recomendaciones personalizadas.

4.2 Objetivos específicos

- Generar recomendaciones mediante el modelo de recomendación SVD para los perfiles de clientes más relevantes.
- Diseñar e implementar experimentos para testear el modelo de recomendación versus el actualmente utilizado.
- Medir si el modelo propuesto es más efectivo para la empresa.
- Concluir sobre la efectividad del modelo, su comportamiento con los datos e hipótesis trabajadas y proponer trabajos futuros que complementen aspectos no abordados por la presente memoria.

5. ALCANCES

Entre los alcances se encuentra que la memoria se realizará por medio de una empresa que vende soluciones de software a empresas, por lo que todo el proceso de venta se aprenderá a través de esta empresa. Esto es relevante puesto que el trabajo es realizado para una empresa y realidad peruana.

Para realizar las recomendaciones, se utilizarán periodos de tiempo del mismo tamaño que utiliza la empresa actualmente. Este periodo de tiempo corresponde a 12 semanas.

Los datos anteriores a las 12 semanas no serán considerados por el modelo. Es decir que se definirá un producto no comprado anteriormente por un cliente, cuando este último no lo ha comprado en las 12 semanas anteriores.

Se tiene en los datos que los clientes tienen como característica su boca de salida y perfil. La boca de salida es que tipo de negocio es, por ejemplo, un puesto de mercado o bodega. En cambio, el perfil es una clusterización de los clientes según su comportamiento de compra en él tiempo. Por esta misma razón se considerarán los 6 perfiles más relevantes para realizar los experimentos y evaluaciones. De todos modos, para efectos de la calibración global del modelo SVD, se utilizarán todos los clientes para tener un escenario de dispersión real de los datos.

Con respecto a las bocas de salida, se considerarán para comparar el comportamiento en experimentos de los puestos de mercado versus las bodegas.

Como la información procesada por el modelo corresponde a valoraciones de un cliente a un producto, no existe problema si para ciertos clientes su boca de salida no está definida.

El periodo contemplado para realizar experimentos contempla desde el 23 de octubre hasta el 24 de diciembre. Desde el 23 de octubre hasta el 19 de noviembre se realizan experimentos exploratorios que sirven para detectar potenciales problemas como, por ejemplo, que no todos los clientes compran productos efectivamente todas las semanas. Por lo que se debe considerar una mayor cantidad clientes para los grupos de control y experimentales.

6. RESULTADOS ESPERADOS

Los resultados que se esperan de esta memoria son los siguientes:

- Implementación de un modelo de recomendación SVD.
- Evaluación del modelo por medio de experimentos que determinen su efectividad en los 6 perfiles escogidos.
- Caracterización de los perfiles en cuanto al rendimiento de ambos modelos, se espera que con los experimentos se distingan cuáles son los perfiles en que el modelo funciona muy bien, regular o mal.
- Se espera obtener aprendizajes extra sobre el comportamiento de los clientes, por ejemplo, saber si los clientes con mayor ticket promedio son más susceptibles a la sugerencia de pedido.
- Conclusiones de cuáles podrían ser las oportunidades de mejora en la implementación de modelos de recomendación.

7. MARCO CONCEPTUAL

7.1 Sistemas de Recomendación

Cada vez es más común que distintos tipos de empresas tengan acceso a almacenar o acceder a grandes volúmenes de datos. Esto es fácilmente explicado debido a que en los últimos 10 años el precio por guardar cierto tamaño de datos es cada vez más barato.

Por supuesto que también la actual masividad del internet es otra variable que ha influido bastante para que cada vez a más empresas les resulte fácil registrar, traspasar y utilizar los datos. Con tan solo un chip, se puede solucionar el problema de la conexión. Por lo que con todo el volumen de datos que existe, surgió la oportunidad de que por medio de algoritmos computacionales se pudieran comenzar a reconocer patrones en los datos que se almacenaban, naciendo así, los primeros sistemas de recomendación.

Actualmente, los sistemas de recomendación pueden ser hallados en muchos lugares. Estos se pueden encontrar en la recomendación de un producto asociado a los intereses o características de un usuario en alguna red social [6], como también en la recomendación de una película afín a los gustos del cliente en una selección. Incluso los sistemas de recomendación se pueden encontrar en situaciones tan cotidianas como ir a comprar a un retail. Lugar donde una cámara reconoce los patrones de movimiento y de acuerdo a eso recomienda si enviar o no un vendedor para ayudar a que sea más probable la compra.

Toda la información en que se pueda procesar y analizar sus patrones se puede utilizar para realizar algún tipo de recomendación.

7.2 Tipos de sistemas de recomendación

Existen distintos tipos de modelos de recomendación que se diferencian en cómo es la información que utilizan. Los tres tipos de información más utilizadas son:

- Datos transaccionales de cada usuario:

Son datos del tipo que reconoce una transacción y la caracteriza con datos como ejemplo precio, producto, ubicación de la compra, edad del cliente, entre otras.

- Calificación de los productos por parte de los usuarios:

Son datos que los usuarios ingresan sobre sus preferencias. Esto por ejemplo se puede apreciar en las evaluaciones que los usuarios les dan a las películas que ven.

En el caso del ejemplo la información puede ser utilizada para que el algoritmo que se ocupe aprenda sobre las preferencias del usuario y pueda relacionarlo a otro grupo de personas que se comporte de manera similar a él. Logrando recomendaciones a partir de personas que tengan preferencias parecidas.

- Metadatos de productos o servicios:

Los metadatos son la información sobre los atributos que tiene cierto producto. Por ejemplo, que tan dulce puede ser algo, entre otras descripciones.

De acuerdo a lo presentado, para realizar las recomendaciones, actualmente los tres algoritmos más utilizados corresponden a:

- **Algoritmos de Filtros Colaborativos:**

Este tipo de algoritmo se caracteriza por utilizar el historial de interacciones que ha tenido el cliente con la empresa [7]. Por ejemplo, la información relacionada a una compra o también una calificación del cliente por algún servicio, etc.

La idea central de este tipo de sistema de recomendación, es que usuarios con preferencias similares en el pasado, tendrán preferencias similares en el futuro.

- **Algoritmos en Base al Contenido:**

Los algoritmos en base al contenido utilizan los metadatos de los productos o servicio [8].

Un ejemplo de estos sistemas de recomendación es cuando se utiliza la información de un usuario que se mueve por una página web, es decir, en qué lugares hace click. Entonces de acuerdo al comportamiento que tenga el usuario se puede ocupar un algoritmo que encuentre patrones de movimiento, lo compare a otros patrones similares y luego en base a eso, realice una recomendación.

- **Algoritmos Híbridos:**

Estos algoritmos son una combinación de los dos algoritmos mencionados anteriormente. La fortaleza de los algoritmos híbridos es que cuando algún algoritmo en particular presenta alguna deficiencia o debilidad, se utiliza en combinación con otro para aminorar el problema y potenciar sus fortalezas [9].

Dado que la base de datos a utilizar es transaccional, es decir, es un historial de interacciones que ha tenido el cliente con la empresa. Los algoritmos que se deben utilizar para realizar recomendaciones son los de filtros colaborativos.

7.3 Tipos de filtros colaborativos

Los filtros colaborativos se caracterizan por asociar usuarios o productos con sus similares, y en base a esto realizar una recomendación. Para lograr esto, como mencionamos anteriormente, se utilizan bases de datos que contienen interacciones del usuario con la empresa [10].

Actualmente los filtros colaborativos más utilizados son los que se detallan a continuación:

- Filtros colaborativos basados en la memoria: Se utilizan todas las interacciones de los usuarios con la empresa para realizar una recomendación.
- Filtros colaborativos basados en un modelo: Se utilizan las interacciones también, pero para construir un modelo que aprenda a hacer predicciones sin utilizar siempre toda la base de datos. El modelo SVD utilizado en la presente memoria pertenece a este grupo.
- Filtros colaborativos híbridos: Estos filtros utilizan más de una técnica de recomendación para realizar una predicción.

A continuación, se describirán con mayor detalle cada modelo explicando las ventajas y desventajas de cada uno.

7.3.1 Filtros colaborativos basados en la memoria.

Los filtros colaborativos basados en la memoria utilizan todas las interacciones del usuario con la empresa para generar predicciones, estos filtros pueden ser basados en los productos o basados en los usuarios.

Si bien, son relativamente simples en su aplicación, estos filtros colaborativos cuentan con la desventaja de que el tiempo de procesamiento es más lento al utilizar toda la data.

El algoritmo de los K-vecinos más cercanos es un ejemplo de un filtro colaborativo basado en la memoria. Fue desarrollado por Resnick et al. en Group Lens [11] siendo el primer filtrado colaborativo automatizado creado. En la memoria desarrollada Ignacio Díaz se generaron recomendaciones utilizando este modelo.

7.3.2 Filtros colaborativos basados en un modelo

Este tipo de filtro colaborativo utiliza los datos para aprender de ellos y así poder generar un modelo que es capaz de generar la recomendación sin utilizar necesariamente toda la información. Esto lo realiza dado que el diseño y desarrollo del motor permite al sistema aprender y reconocer patrones complejos de los datos. Logrando así, crear predicciones a través del modelo aprendido.

Entre las técnicas para crear recomendaciones a través de los filtros colaborativos basados en un modelo se encuentran los algoritmos de agrupamiento, métodos de descomposición matricial y métodos espectrales.

Ejemplos de algoritmos de agrupamientos son K-Means Clustering y el Co Clustering. De métodos de descomposición matricial se pueden encontrar la descomposición en valores singulares (SVD), SVD with implicit valuations (SVD++), Non-negative Matrix Factorization (NMF), entre otros [12].

Con respecto a los métodos espectrales, se tiene el Spectral Biclustering, algoritmos de Biparticionamiento, entre otros.

7.3.3 Filtros colaborativos híbridos

Estos filtros colaborativos pueden ser la combinación de los mencionados anteriormente y más. Entre las ventajas que tiene es que mejora el ajuste para situaciones más específicas, esto dado que el modelo es más flexible.

7.4 Modelo de recomendación SVD

7.4.1 Funcionamiento tradicional del modelo

La sigla SVD tiene por significado “Singular Value Decomposition”, esto es porque el presente modelo descompone en valores singulares la matriz de datos a procesar. Esto con el objeto de reducir la dimensionalidad del espacio usuario/productos. Esto fue propuesto por primera vez en Sarwar et al [13].

Al realizar la descomposición se obtiene una matriz más pequeña que tiene la menor pérdida de información posible. Las matrices resultantes de la descomposición guardan la información más relevante para grupos de cliente y productos similares, estos valores son información relevante que permiten al modelo generado realizar recomendaciones precisas.

Este modelo surge a partir de la dificultad existente en los modelos de filtrado tradicional por superar la escasez de datos en matrices dispersas.

El funcionamiento de este modelo consiste en descomponer una matriz de ratings de clientes y productos R : $m \times n$ en tres matrices de la forma:

$$R = USV^t \quad (7.4.1.1)$$

En que, U y V son matrices ortogonales formadas por vectores propios, y S es una matriz formada por los valores singulares de A en su diagonal principal ordenados de mayor a menor. Cabe destacar que la relación entre valor singular σ y valor propio λ es como se presenta a continuación:

$$\sigma = \sqrt[2]{\lambda} \quad (7.4.1.2)$$

Para realizar esta descomposición, en primer lugar, se multiplica la ecuación 7.4.1.1 por su matriz traspuesta, consiguiendo:

$$R^T R = VS^T S V^T \quad (7.4.1.3)$$

Dado que la matriz R tiene un valor determinado, multiplicarla por su matriz traspuesta nos brinda otra matriz con un valor dado. Entonces para continuar armando la descomposición de la matriz, se deben calcular los valores propios despejando λ como sigue:

$$\det(R^T R - \lambda I) = 0 \quad (7.4.1.4)$$

En donde I es la matriz identidad.

Una vez despejados los i valores propios, se calculan los vectores propios. Que son los que cumplen la siguiente relación:

$$RX = \lambda_i X \quad (7.4.1.5)$$

En donde X es el vector propio. Este sistema de ecuaciones se resuelve para cada λ calculado en 7.4.1.4.

Con los vectores propios calculados se arma la matriz V que no es más que una matriz en que cada una de sus columnas corresponde a un vector propio.


La matriz U se calcula multiplicando por V la ecuación 7.4.1.1 obteniendo lo siguiente:

$$CV = US \quad (7.4.1.6)$$

A partir de esta matriz se puede calcular U.


En la ilustración 5, se observa la estructura que presenta la descomposición SVD. En el caso de la presente memoria la matriz R es compuesta por los clientes en las filas y los productos en las columnas, tiene la misma estructura que en la imagen puesto que se tiene mayor cantidad de clientes versus los productos.

La matriz U en la ilustración 5 contiene vectores propios que guardan patrones de los clientes, la matriz V a su vez contiene vectores propios que guardan patrones respecto a los clientes y la matriz S a través de sus valores singulares captura patrones entre grupos de clientes y productos [14].



*Ilustración 5: Descomposición de la matriz R en valores singulares.
Fuente: Elaboración propia*

Los valores singulares que son 0 se reducirán, dado que toda la información importante se encuentra en los valores singulares mayores que 0. Esto aporta a que el procesamiento sea más expedito. El número k representa el número de valores singulares distintos y mayores que 0. Con esta reducción, los tamaños de las matrices de la ilustración 5 quedan como se aprecia en la ilustración 6.



*Ilustración 6: Descomposición de la Matriz R luego de reducción de valores nulos de S en su diagonal.
Fuente: Elaboración propia.*

Además de esto, la matriz se puede reducir más ordenando de mayor a menor los valores singulares de la matriz S y eliminando los valores singulares que se acerquen a 0, esto porque aportan poca información de las relaciones Cliente – Producto.

La descomposición SVD se realiza para poder obtener los valores singulares de la matriz Cliente–Producto, además también se realiza para tener la posibilidad de reducir la dimensión de la matriz S a la dimensión k . Con estas matrices de información ordenada y relacionada se puede elaborar una estrategia de recomendación de productos para clientes en base a recomendaciones de otros clientes.

La descomposición SVD es relevante, porque descomponiendo y reduciendo a los valores singulares se logran capturar los patrones de comportamientos más importantes de cada cliente con respecto a un grupo o familia de productos que tengan relación según las valoraciones de todos.

En palabras sencillas se podría decir que descomponer una matriz R en sus valores singulares es similar a agrupar todas las características, en un grupo de características esenciales.

Con la reducción de dimensionalidad realizada, la matriz R queda definida como se indica en la siguiente ecuación:

$$R_k = U_k S_k V_k^T \quad (7.4.1.7)$$

Con R_k de la ecuación también se podrían realizar recomendaciones con el modelo kNN. Pero el hecho de haber descompuesto la matriz y reducido representa la ventaja de que se capturan las relaciones entre los datos de manera más precisa que permite realizar predicciones más precisas también.

Para facilitar la comprensión de cómo se obtiene la recomendación a partir de la recomendación, la matriz S, se descompondrá en dos matrices diagonales que tendrán la raíz cuadrada del valor singular respectivo. Cada $S_k^{1/2}$ se multiplicará por U_k y V_k respectivamente, obteniendo así dos matrices que describen por si mismas las características de los clientes en el caso de $U_k S_k^{1/2}$ y las características de los productos en el caso $S_k^{1/2} V_k$ [15]. El detalle de lo explicado se puede observar en la ilustración 7:

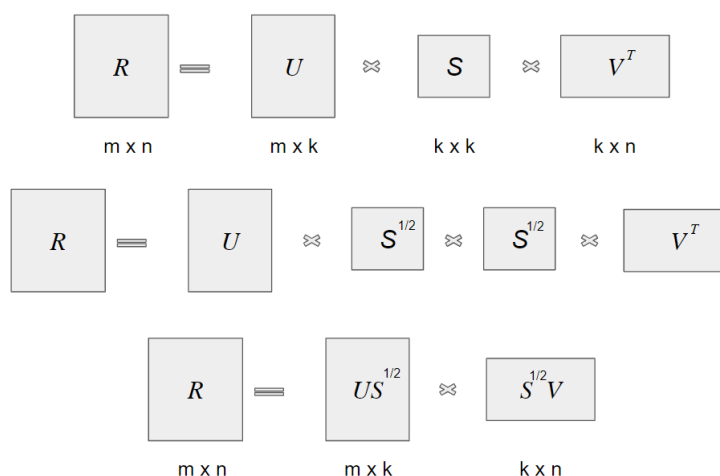


Ilustración 7: Simplificación de la descomposición SVD.
Fuente: Elaboración propia

A partir de este punto se puede realizar predicciones de valoración de un cliente i hacia un producto j multiplicando el producto punto de la i -ésima fila de $U_k S_k^{1/2}$ y la j -ésima columna $S_k^{1/2} V_k$, más el promedio de los ratings del usuario i . Es decir, la predicción se realiza a través del promedio de todas las valoraciones del cliente i más la suma del producto punto de las características del cliente i , con las características del producto j . Con todo esto, se puede obtener una predicción de la valoración del producto j por parte del cliente i . Esta predicción se define por medio de la siguiente formula:

$$\hat{r}_{i,j} = \bar{r}_i + U_k \sqrt{S_k^T}(i) \cdot \sqrt{S_k} V_k^T(j) \quad (7.4.1.8)$$

Este tipo de recomendación presenta el problema de que se indefine cuando el conocimiento de la matriz es parcial, es decir, cuando presenta celdas vacías.

Este problema se solucionaba pre-llenando los valores vacíos de la matriz, pero esto a su vez genera sesgos y problemas de predicción.

7.4.2 Funcionamiento corregido del modelo SVD

El problema enunciado en el punto anterior, lo solucionó Simon Funk [16] optimizando considerando una regularización. En este caso la predicción de la valoración se define realizando un producto punto entre los siguientes vectores:

$$\hat{r}_{i,j} = p_i^T q_j \quad (7.4.2.1)$$

En donde p_i y q_j corresponden a vectores k dimensionales de clientes y productos respectivamente, es decir $p_i^T = U_k \sqrt{S_k^T}(i)$ y $q_j = \sqrt{S_k} V_k^T(j)$. El desafío de esta proposición es aprender los valores que mejor representen los vectores de usuarios e ítems.

Estos parámetros se estiman utilizando el método de la gradiente descendente que busca minimizar la diferencia entre la predicción realizada por el algoritmo SVD y la valoración real del usuario.

En cada rating que pertenece al conjunto de entrenamiento, el modelo realiza la predicción $\hat{r}_{i,j}$ y luego a partir de la predicción calcula un error asociado que se define como sigue:

$$e_{i,j} = r_{i,j} - \hat{r}_{i,j} \quad (7.4.2.2)$$

Entonces la minimización que se debe realizar se define como sigue:

$$\min_{q^*, p^*} \sum_{r_{i,j} \in R_{\text{entrenamiento}}} e_{i,j}^2 + \lambda(\|q_j\|^2 + \|p_i\|^2) \quad (7.4.2.3)$$

En donde λ corresponde a una tasa regularización para evitar que la minimización caiga en mínimos locales.

Según la gradiente descendiente, se deben ir actualizando los parámetros p y q en la dirección opuesta a la gradiente según una tasa de aprendizaje I_{rate} definida previamente.

La actualización de parámetros según el método se define como sigue:

$$p_i \leftarrow p_i + I_{rate}(e_{i,j}q_j - \lambda p_i) \quad (7.4.2.4)$$

$$q_j \leftarrow q_j + I_{rate}(e_{i,j}p_i - \lambda q_j) \quad (7.4.2.5)$$

Según Simon Funk, los parámetros que obtienen mejores resultados son 0.001 para la tasa de aprendizaje I_{rate} y 0.02 para la tasa de regularización λ .

Esta corrección del modelo es muy relevante, puesto que, sin la corrección, los valores nulos se hubieran tenido que rellenar con promedios simples o cero, produciendo un sesgo mayor en la predicción. Entonces de este modo se realizan predicciones de valoración con el mínimo error, por lo que la recomendación para cada cliente consiste en elegir los 10 productos con mayor valoración esperada.

7.5 Indicadores para medir la calidad de los modelos

Para poder comparar, elegir e incluso aprender de los modelos de recomendaciones es necesario contar con métricas que permitan evaluar la efectividad de los mismos. En la presente memoria se utilizan el RMSE y el MAE. Para definir estos indicadores se utilizó el libro de G.Shani y Gunawardana[17].

7.5.1 Root mean squared error (RMSE)

Para un modelo recomendador, el RMSE utiliza las valoraciones conocidas del cliente i al producto j definida como $r_{i,j}$. Esta valoración conocida se utiliza para compararla con la valoración predicha por el modelo $\hat{r}_{i,j}$ y así estimar un indicador del error de predicción. Este indicador se define como sigue:

$$RMSE = \sqrt{\frac{1}{|N|} \sum_{i,j \in N} (\hat{r}_{i,j} - r_{i,j})^2} \quad (7.5.1.1)$$

7.5.2 Mean absolut error (MAE)

El MAE realiza lo mismo que el RMSE pero ligeramente de distinto modo. A continuación, se presenta su definición:

$$MAE = \frac{1}{|N|} \sum_{i,j \in N} |\hat{r}_{i,j} - r_{i,j}| \quad (7.5.2.1)$$

Como se puede observar, la única diferencia entre ambos indicadores es que el RMSE calcula el error al cuadrado y el MAE calcula el valor absoluto del error.

8. METODOLOGÍA

La metodología que se utiliza en la presente memoria se llama CRISP-DM y es ampliamente utilizada en proyectos de minería de datos con enfoque de negocios [18].

A continuación, se presenta un cuadro resumen de la metodología utilizada:

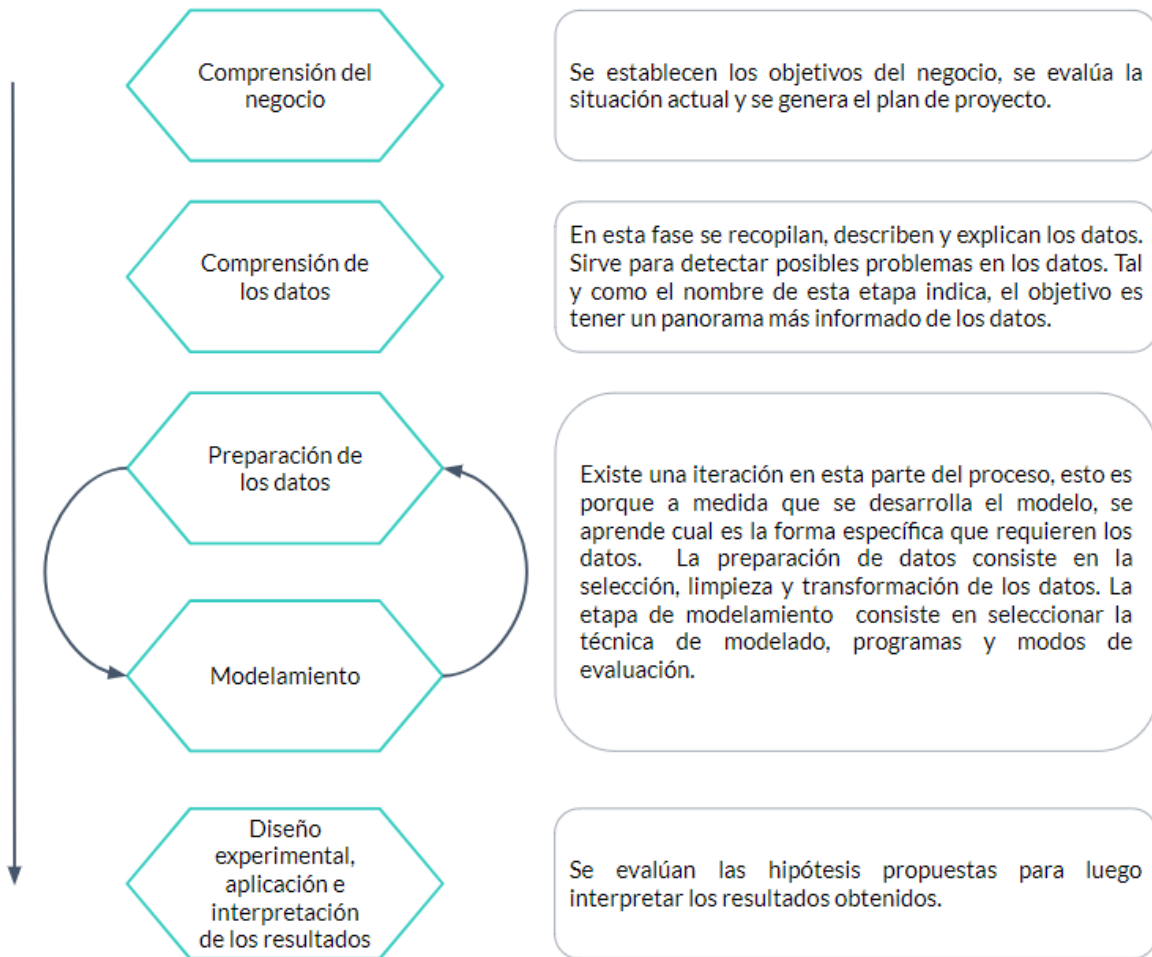


Ilustración 8: Resumen de la metodología de trabajo. Fuente: Elaboración propia.

La metodología consta de los siguientes pasos:

- **Comprensión del negocio:**

Esta etapa consiste en establecer los objetivos del negocio e identificar los factores contextuales del trabajo y el funcionamiento del proceso involucrado a nivel operativo y táctico. Esta fase es completada en los puntos anteriores de la presente memoria, por lo que no estará incluida en el desarrollo metodológico.

- **Comprensión de los datos:**

Esta fase busca el lograr familiarizarse con los datos teniendo ya presente los objetivos del negocio. Para esto se recopilan, describen y exploran datos. Con esta información se puede realizar una selección de variables más consciente de la importancia y posibles problemas.

- **Preparación de los datos:**

Una vez que se comprenden los datos, se procede a seleccionar las variables relevantes para el problema.

Luego de esto se continúa con la limpieza que consiste en detectar problemas en los datos como los campos vacíos o potenciales datos que podrían sesgar el resultado del modelo, como lo son los outliers. Estos datos se pueden eliminar como corregir según sea el caso.

Posteriormente a la selección y limpieza se sigue con la transformación. En esta etapa los datos se transformarán a la estructura necesaria para que puedan ser utilizados tanto por el software de procesamiento, como por el algoritmo. En esta etapa por ejemplo las palabras se transformarán en números, aparecerán datos binarios, etc.

El objetivo de toda la preparación de datos es lograr obtener un dataset procesable por el modelo a utilizar.

- **Modelamiento:**

En primer lugar, se debe seleccionar la técnica de modelado que se utilizará, luego se procederá con la construcción del modelo para finalmente realizar una evaluación del mismo con la base de datos transformada.

Se corrigen posibles errores y finalmente se generan recomendaciones.

- **Diseño experimental:**

Una vez que el modelo esté operativo, y luego del análisis exploratorio y descriptivo, se formularán diversas hipótesis para las cuales se definirán métricas con las cuales se puedan evaluar.

Luego se procederá a realizar un diseño muestral que permita concluir con significancia estadística sobre las hipótesis planteadas. Este diseño considerara grupos de control y experimentales.

- **Interpretación de resultados**

En esta etapa se cuantifican los indicadores de cada hipótesis propuesta en el diseño experimental, una vez cuantificados se estudia la significancia de su variación entre los grupos de control y experimentales para finalmente interpretar los resultados.

9. DESARROLLO METODOLÓGICO

9.1 Comprensión de los datos

9.1.1 Fuente de los datos

En la empresa intermediaria, se tiene una base de datos que se actualiza semana a semana con los datos desde Perú. Se tiene información transaccional desde inicios de enero del 2011 hasta la actualidad.

La información transaccional tiene una arquitectura de base de datos tipo estrella, en la cual, para disminuir el peso de la información de ventas, es compuesta solo por códigos de números. Por ejemplo, en vez de mostrar el nombre de un vendedor, indica un código que en otra tabla encuentra traducción. Es decir, puedo obtener la información decodificada llamando a las bases de datos respectivas de cada punta de la estrella.

Entre los datos que se pueden obtener se encuentra el número de la transacción, la fecha, el vendedor que realizó la venta, la sucursal desde donde se atiende al cliente, encuentra como el numero de la boleta, el código del cliente, el código del vendedor, el código del producto, el monto de la venta, las unidades vendidas, el margen de la venta, el peso de la venta, si un producto fue vendido por pedido sugerido, si en la transacción existe algún producto vendido por pedido sugerido, entre muchos otros datos.

Con el código del producto, se puede obtener el nombre del producto, su SKU, su categoría, entre otros. Lo mismo con el código del cliente, donde se puede acceder a que tipo de boca de salida es el cliente o cual perfil pertenece.

También se puede encontrar información histórica de las sugerencias de productos personalizadas en donde se puede saber si el producto fue visualizado y no comprado, como también saber a que estrategia corresponde la recomendación, entre otros.

9.1.2 Recopilación inicial de los datos

La recopilación inicial de datos consiste en aprender lo máximo de la base de datos para encontrar potenciales oportunidades de descripción y exploración.

A continuación, se realizará un pequeño sumario con todas las variables utilizadas en la presente memoria ya sea explorar, describir o procesar.

- **Date_id:** Código de la base transaccional con la cual se puede tener acceso al detalle de la fecha. Ya sea como formato fecha, día de la semana, etc. Por ejemplo, el 24 de diciembre tiene como date_id el número 2915.
- **week_id:** Identificador de la semana del año en que se registra la transacción. Por ejemplo, el 24 de diciembre tiene valor 201751.
- **numero_pedido:** Identificador del pedido.

El año 2017 tuvo aproximadamente 6,1 millones de pedidos distintos, es decir que alrededor de 508 mil pedidos distintos mensuales en promedio.

- **tran_id:** Identificador de transacción.

El año 2017 tuvo aproximadamente 8,2 millones de transacciones distintas. Es decir que en promedio se tienen 686 mil transacciones distintas mensuales.

- **Cli_id:** Código para identificar a los clientes. Ejemplo: 175680.
- **cli_nkey:** Identificador único del cliente. Es como una especie de SKU, pero de clientes. Ejemplo: 0001580378

Durante el año 2017 se tuvo que 162.550 clientes al menos realizaron una transacción.

- **cli_boca_salida:** Clasifica que tipo de cliente es. (ejemplo: Puesto de mercado, bodega, etc.)

En la base de datos se pueden encontrar 9 bocas de salida distintas, estas son: autoconsumo, bodega, golosina, impulso, mayorista abarrotes, mayorista especializado, otros, panaderías y puestos de mercado.

- **cli_etiqueta_perfil:** Identifica a cuál perfil pertenece el cliente.

Se tienen nueve perfiles: los abarroteros, aderezos, food service, golosineros, limpieza, mascotas, panaderías, panaderías bodega y el perfil “varios”.

- **vend_id:** Identificador del vendedor.

Durante el año 2017 se tuvo 1097 vendedores distintos entre todas las DEX.

- **codigo_sociedad_id:** Identificador de la DEX donde trabaja el vendedor.

Se tienen 25 DEX distintas.

- **meas_monto_bruto:** Define el monto de la transacción.

Se tiene que el monto promedio de un pedido a la semana es de 84 dólares.

- **meas_unidades:** Define la cantidad de unidades transadas.

A partir de las unidades y el monto bruto, se puede adquirir el precio bruto por unidad

- **cli_provincia_asignada:** Identifica la provincia donde se ubica el cliente.

Existen 196 provincias en el Perú.

- **cli_region_asignada:** Identifica la región donde se ubica el cliente.

Existen 25 regiones en el Perú.

- **cli_intensidad:** Clasifica el peso del producto.

Clasifica la intensidad del peso en alta, media o baja.

- **Prod_id:** Código de 4 dígitos para cada producto.

- **prod_nkey:** Identificador único del producto (SKU).

En el año 2017, se vendieron 1509 prod_nkey distintos.

- **prod_cod_categ:** Categoría a la cual pertenece el producto. (ejemplo: Galletas).

Se tienen 43 categorías de productos en la base de datos.

- **flag_producto_sugerido:** Indica si el producto fue comprado gracias al pedido sugerido.

Un 18% de los pedidos incluye un producto con pedido sugerido.

- **flag_producto_sugerido_tran:** Indica si en la transacción, se lleva al menos un producto con pedido sugerido.
- **flag_producto_sugerido_tran:** Indica si en la transacción, se lleva al menos un producto con pedido sugerido.
- **Llave_pedido_sugerido:** Esta variable es un código que conecta la base transaccional con la base de sugerido histórico. Esta variable sirve para saber por cual estrategia fue vendido el producto con PS.
- **flag_visualizacion:** En la base de sugerencias de productos historico, esta variable indica si el producto fue visualizado o no por el vendedor. Es decir, si el producto fue ofrecido al cliente.
- **Marca_nivel:** Indica en caracteres, el nombre de la estrategia a la cual corresponde la sugerencia. Esta puede ser frecuentes, perfil y asociado.
- **Nivel:** Indica el orden de la estrategia, por defecto frecuentes es la primera, perfil es la segunda y asociados la tercera.
- **Prioridad sugerido:** Indica el orden de las recomendaciones de productos en una misma estrategia en donde el que tiene mayor prioridad es porque tiene una mayor similitud con el comportamiento del cliente.

9.1.3 Análisis descriptivo

Para comenzar el análisis descriptivo, a continuación, se tiene el gráfico 3 que presenta las ventas de la compañía.




Gráfico 3: Evolución de las ventas por tipo de transacción.
Fuente: Elaboración propia.

En este gráfico se puede apreciar que el crecimiento de la venta de la empresa ha tendido a estancarse desde el año 2016.

Se puede apreciar también en el gráfico 4 que el pedido sugerido comenzó el año 2014 y que ha aumentado en el tiempo su porcentaje llegando incluso a un peak de 6,43% de aporte a la venta total.




Gráfico 4: Porcentaje de aporte PS a la venta total. Fuente: Elaboración propia.

Los clientes se clasifican en 9 perfiles distintos, estos a continuación se caracterizarán lo más posible debido a que el modelo SVD de la presente memoria se calibrará para cada perfil específico.

Primero que todo se tiene que en el gráfico 5 se presenta el monto en millones de dólares que representa cada perfil por cada año desde que existe el PS. Con respecto al crecimiento de este monto, se puede apreciar que todos salvo el perfil sin etiqueta han tenido crecimiento en las ventas en los años 2014, 2015 y 2016.

Referente a las ventas totales en dólares, se encontró que existe un perfil denominado “mascotas” que tiene una cantidad muy pequeña de ventas. Esto es porque la compañía se toma un tiempo de 6 meses para clasificar a un cliente en alguno de los 9 perfiles disponibles. Entonces, dado que durante un tiempo la empresa experimentó entrar a la industria de las comidas para mascotas, quedó una cantidad muy baja de registros en el sistema, que para efectos del trabajo, no serán considerados.

En el gráfico 5, también se ve que una no menor proporción de datos corresponde a perfiles sin etiqueta. Esta proporción de clientes, es así porque la empresa se toma un tiempo de 6 meses en clasificar el cliente en uno de los 9 perfiles utilizados, por lo que los clientes nuevos en el sistema se denominan como sin etiqueta hasta que cumplan 6 meses en él.




Gráfico 5: Monto total vendido por año por cada perfil, año 2017 hasta mediados de octubre.
Fuente: Elaboración propia.

En el gráfico 6 y gráfico 7 se tienen los porcentajes de la suma del monto vendido por cada perfil con respecto al total de las ventas de todos los perfiles durante el año 2016 y 2017 respectivamente. En estos gráficos se aprecia más claramente la supremacía de ventas del perfil abarroteros con respecto a los demás, que desde el año 2016 al 2017 aumenta su participación desde un 42% a un 47,8%. Este aumento de 5,8% lo hace principalmente en

base al decrecimiento del perfil sin etiqueta que disminuye de 14,8% hasta un 2,2% en participación, es decir, un decrecimiento del 12,6%.

Aparte del cambio que se da entre los años antes mencionado, todos los demás perfiles crecieron en participación. El perfil panaderías, lo hizo con un 1,8%, panaderías bodega con un 1,3%, varios con un 1,2%, limpieza con un 0,9%, food service lo hizo con un 0,9%, golosineros con un 0,5% y finalmente el que menos creció en participación fue el perfil aderezos con un 0,3%.

Cabe destacar que entre todos los perfiles que no son abarroteros acumulan una participación de 58% durante el 2016 y de 52,2% durante el 2017.




Gráfico 6: Participación de las ventas totales de cada perfil en el año 2016.
Fuente: Elaboración propia.




Gráfico 7: Participación de cada perfil en el año 2017.
Fuente: Elaboración propia.

En el gráfico 8 se puede dimensionar el número de boletas por año que se transan por cada perfil en los años 2014, 2015, 2016 y 2017. De esta información, se puede destacar que los perfiles aderezos, food service, golosinero, limpieza, panaderías, panaderías bodega y varios tienen crecimiento en el número de participaciones en los años 2014, 2015 y 2016. El perfil abarroteros tiene un decrecimiento en el año 2015 que se revierte en el año 2016.

El perfil sin etiqueta tiene un decrecimiento debido a la disminución de los clientes presentes en este perfil. El año 2017 tiene menor cantidad de boletas debido a que solo considera transacciones hasta el 15 de octubre.




Gráfico 8: Cantidad de boletas emitidas por perfil y año.
Fuente: Elaboración propia.

En el gráfico 9 y 10 se puede ver el comportamiento de la proporción de boletas emitidas al año por cada perfil con respecto al total. De estos gráficos se puede apreciar que el único perfil que decrece en la cantidad de boletas vendidas, es el perfil sin etiqueta, que lo hace en un 10,4%. Los demás gracias a disminución e incorporación de estas tiendas a los distintos perfiles, aumentan los abarroteros un 7%, los golosineros un 0,9%, las panaderías bodega un 0,8%, las panaderías un 0,6%, el perfil food service un 0,4%, el perfil varios un 0,3%, limpieza un 0,3% y finalmente el perfil aderezos un 0,1%.

Participación de cada perfil en boletas en el año 2016



Gráfico 9: Participación de cada perfil en el número de boletas durante año 2016.
Fuente: Elaboración propia

Participación de cada perfil en boletas en el año 2017




Gráfico 10: Participación de cada perfil en el número de boletas durante año 2017.
Fuente: Elaboración propia.

En el gráfico 11 se expone como ha ido variando la cantidad de clientes por cada perfil, en general todos los perfiles han aumentado la cantidad de clientes en el tiempo, pero en el gráfico específicamente se puede destacar el gran aumento de los clientes pertenecientes al perfil abarroteros y la gran disminución de los clientes en el perfil sin etiqueta.

Con respecto al total, se tiene que el total de clientes en el año 2014 fue de 160.355, en el año 2015 fue de 166.998, en el año 2016 fue de 169.391 y en el año 2017 existe una disminución a 157.287. Podrían ser variadas las explicaciones del porqué disminuyó la cantidad de clientes en el último año. Las afirmaciones más probables pueden ser que la disminución del perfil sin etiqueta se debió no solo a que pasaron a ser de otros perfiles, sino que fueron nuevas tiendas que no encontraron subsistencia y cerraron sus

operaciones. Además, otra afirmación posible es que como aún no se acaba el año 2017, pueden existir empresas nuevas que comiencen sus operaciones en este periodo final que se contabilizaron en los años anteriores y en el 2017 no. Como también pueden existir empresas que solo realizan transacciones en la última fracción del año.

Para descartar las afirmaciones del periodo final, se contaron los clientes de los 4 años, pero solo considerando desde enero hasta septiembre, se obtuvieron que los números obtenidos fueron 152.734 para el año 2014, 161.040 para el año 2015, 163.106 para el año 2016 y 157145 para el año 2017. Con esto se descartan las afirmaciones relacionadas a que en el final de año se existiese una cantidad considerable de clientes que hiciera que se equiparase el número de clientes. Es por esto que la afirmación más probable es porque parte de los clientes sin etiqueta del año 2017, cerraron sus operaciones antes que se les clasificara en algún perfil.

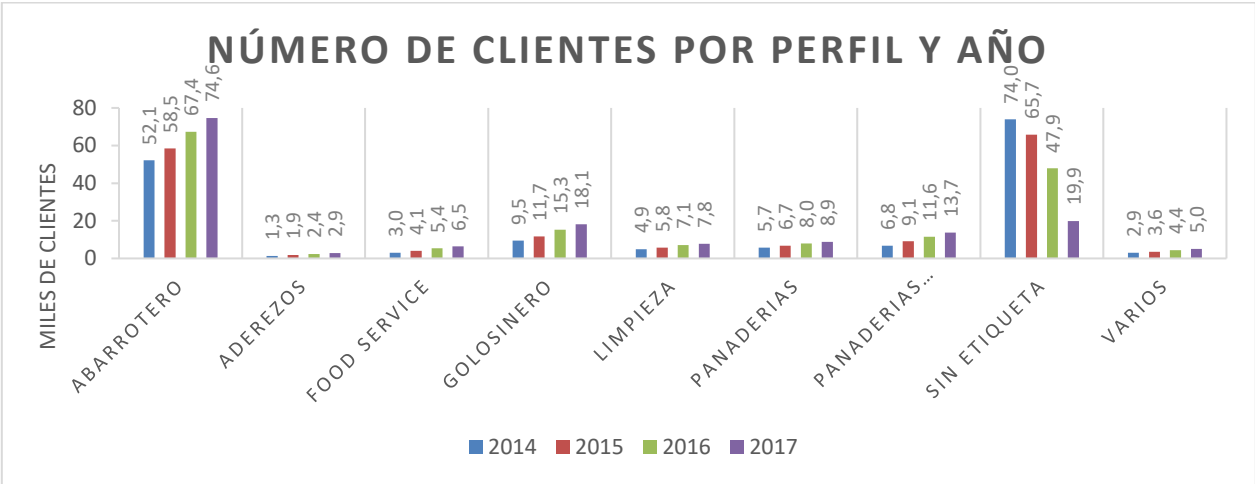


Gráfico 11: Número de clientes por perfil y año.
Elaboración propia.

El gráfico 12 presenta la cantidad de dinero total vendido por cada boca de salida desde el año 2015 hasta agosto del año 2017. Con respecto a esta información, se tiene que una cantidad de 1.657.937 dólares no tiene etiqueta, por lo que serán limpiados de la base de datos. Cabe destacar que estos clientes que no tienen etiqueta son clientes más nuevos que aún no se les clasifica.

El tipo impulso, solo vendió 427 dólares en esa cantidad de tiempo, por lo que no será considerado en lo que resta del estudio tampoco.



Gráfico 12: Monto total vendido por cada boca de salida hasta agosto del año 2017.
Elaboración propia.

También se puede apreciar que la categoría golosinas y otros tienen una proporción muy pequeña con respecto a las demás. Se revisaron los datos del año 2017 para comprobar si alguna de estas bocas de salida desaparecía o tendía a la extinción. En el gráfico 13 están explicitadas los porcentajes de participación cada una de las bocas de salida en donde las golosinas y otros siguen teniendo una participación muy pequeña, es por esto que serán eliminadas del estudio.




Gráfico 13: Participación en ventas de cada boca de salida en el año 2017.
Elaboración propia.

En el gráfico 14 se encuentra la distribución de los clientes en cada tipo de boca de salida. Se puede apreciar que el tipo de tienda que más clientes tiene son las bodegas, que son pequeñas tiendas que venden distintos tipos de producto. Estas tiendas representan el 50,2% del total, es tal su masividad que Lima será la sede del encuentro internacional de negocios bodegueros en donde participarán líderes de Argentina, Paraguay, Uruguay, Ecuador y Perú.

Las siguientes bocas de salidas más relevantes son los puestos de mercado y boca de salidas de autoconsumo que tienen una participación de 15,6% y 14,6% respectivamente.



Gráfico 14: Porcentaje de clientes por cada boca de salida en el año 2017.
Fuente: Elaboración propia.

9.2 Preparación de los datos

9.2.1 Selección de datos

Según el gráfico 14 presentado en la descripción de los datos, se tiene que el 93,9% de las boletas emitidas se concentran en solo 6 perfiles. Es por esto que para acotar el trabajo de memoria, la evaluación experimental no se realizará para el perfil sin etiqueta, varios y aderezos.

Como se utiliza un motor de recomendación utilizado en recomendar películas de cine, se necesita por estructura una base de datos en que se tengan las valoraciones de cada cliente por cada película vista para luego recomendar.

La base de datos utilizada por la empresa no tiene valoraciones de los clientes por los productos, y en el caso que los tuviera, no sería un indicador lo suficientemente objetivo como lo es el cuantificar la frecuencia de compra de cierto producto por el determinado cliente. Esto quiere decir que si en un periodo de tiempo, el cliente compra muchas veces determinado producto, es porque ese producto en particular, es muy importante para él, obteniendo así un indicador de la valoración bastante más objetivo que la percepción de un cliente sobre un producto.

Un posible problema que podría tener esta manera de evaluar la importancia del producto para el cliente, es por la existencia de clientes que compran mayores cantidades del producto y más alejados en el tiempo.

De todos modos, para la presente memoria, esto no se considerará un problema, dado que es un problema semejante a la persona que sea exigente con todas las películas, dando evaluaciones en promedio más bajas. Es decir, que sin importar que su “escala de evaluación” sea más baja, de igual manera se le hará una recomendación que maximice la “evaluación esperada del cliente por el producto”. Entendiéndose evaluación por frecuencia de compra del producto.

Entonces, las variables a utilizar serán las que identifican al cliente, al producto, a la transacción y la que caracteriza el perfil.

9.2.2 Limpieza y transformación de los datos

Esta es una etapa conjunta puesto que el proceso de ir limpiando y transformando los datos es iterativo en este caso.

En la base de datos, existen valores que son negativos y corresponden a notas de crédito. Estas notas de crédito son transacciones que aumentan el número de la valoración del cliente al producto pero que realmente no significan una compra real del producto por parte del cliente. Entonces, considerarla significa sesgar la valoración por lo que, para poder contrarrestar este problema, solo se considerarán las ventas de productos por valores mayores a cero.

A continuación, en la tabla 8 se presenta la matriz de valoraciones resultante donde se puede observar por ejemplo que el cliente 5 perteneciente al perfil de limpieza ha comprado 11 veces en 12 semanas el producto 4337 y 4460, es decir, son productos muy valorados para él.

Cliente	Producto	Valoración	Perfil
4	9770	1	ABARROTERO
4	9771	1	ABARROTERO
4	9776	1	ABARROTERO
4	9780	1	ABARROTERO
4	9781	1	ABARROTERO
4	9792	1	ABARROTERO
5	86	4	LIMPIEZA
5	763	2	LIMPIEZA
5	1505	4	LIMPIEZA
5	1506	3	LIMPIEZA
5	4337	11	LIMPIEZA
5	4346	6	LIMPIEZA
5	4347	6	LIMPIEZA
5	4349	3	LIMPIEZA
5	4350	4	LIMPIEZA
5	4460	11	LIMPIEZA

Tabla 8: Matriz de valoraciones de los clientes por los productos del dataset completo. Fuente: Elaboración propia.

Esta matriz contiene las valoraciones de las últimas 12 semanas, que es el periodo que contempla el modelo actual de la empresa para realizar las recomendaciones.

De todos modos, este periodo de tiempo no es muy grande ni muy pequeño, porque si este se aumenta mucho, las recomendaciones tendrían menos variación semana a semana. En el caso contrario, si se disminuye más el periodo, podría arriesgar el tener falta de información. De este modo se pondera dinamismo e información.

En este modelo es importante el periodo de tiempo establecido, puesto que, si una tienda compra un producto una sola vez y luego en las 12 semanas no lo vuelve a comprar, es porque probablemente no le gustó el producto y es importante que el sistema recoja que es un producto que no se le debe recomendar a los clientes similares a él.

Como en la presente memoria se quiere estudiar el comportamiento del modelo de recomendación SVD para cada perfil en específico y para el modelo en su forma global, antes de continuar con limpiezas extras, se obtendrán 9 archivos extras correspondientes a las valoraciones específicas para cada perfil. De ahora en adelante, el dataset completo de todas las valoraciones serán llamadas “Valoraciones del modelo global”.

Esta matriz contiene 4.7 millones de filas de datos en donde el valor máximo de valoración que se tiene, es 75, con media 1,765.

Que existan valoraciones entre 1 y 75 y con baja media es un problema, puesto tiene valores muy extremos. Estos son muy pocos casos en que el cliente es visitado más de una vez a la semana. Para simplicidad del modelo se preferirá que las evaluaciones se encuentren en una escala razonable.

Para arreglar el problema se realiza un análisis de outliers, en el que los valores extremos no son eliminados, sino que son corregidos con un valor superior a la máxima evaluación sin contar outliers. Esto puesto que eliminar outliers significa eliminar productos extremadamente valiosos para cierto cliente. La eliminación de este producto tan valioso muy probablemente haría que el sistema de recomendación le sugiera ese mismo producto en primera prioridad, por lo que es importante que esta información sea capturada por el modelo.

Se puede apreciar en el gráfico 15 la corrección de outliers del dataset global. En esta corrección, todos los valores extremos son eliminados dejando Na's en su posición en la matriz. Luego se buscan los Na's y se remplazan por la valoración 4, que en este caso sería un valor más alto que la máxima evaluación del cliente por algún producto no considerando a los outliers. En este caso, se corrigieron los valores mayores al percentil 75.




Gráfico 15: Corrección de outliers del dataset global. Fuente: Elaboración propia.

El mismo proceso es realizado para la data dividida en los perfiles, obteniendo medidas de evaluación más específico a su propia dispersión. Los gráficos se pueden encontrar en anexos. A continuación, se presenta en la tabla 9 un cuadro resumen que indica la valoración máxima que tendrá el conjunto de datos según los outliers corregidos a partir de cierto percentil.

Perfil	Valoración máxima corregida	Percentil	Cantidad de filas de datos	Valoración máxima sin corrección	Valoración media
Global	4	75	4,7 millones	75	1,76
Abarroteros	4	75	3,4 millones	75	1,73
Aderezos	4	75	28.319	37	2,14
Food service	4	75	114.621	56	2,03
Golosineros	4	75	403.006	29	1,76
Limpieza	4	75	180.002	40	1,68
Panaderías bodega	7	75	159.331	44	2,33
Panaderías	4	75	205.035	59	1,91
Varios	4	75	142.444	50	1,81
Sin etiqueta	4	95	71.976	36	1,38

Tabla 9: Información de los datos de cada perfil. Fuente: Elaboración propia.

De todos los casos expuestos, el más complicado de los 9 perfiles es el del gráfico 42 de anexos del perfil golosineros. Esto porque las valoraciones en este perfil son muy bajas e iguales, es decir, que los clientes rara vez compran más de una vez un producto. Para lograr tener valoraciones sobre 1, se tiene la opción de aumentar el tiempo de 12 semanas que se tiene para reunir estas valoraciones, o corregir outliers a un nivel de percentil mayor. Es por esto que se decide corregir los valores mayores al percentil 95, obteniendo una valoración máxima de 3.

Dada estas transformaciones y la definición de entre que escalas de evaluaciones se encuentran las valoraciones, los datos quedan listos para ser procesados por el modelo.

9.3 Modelamiento del sistema de recomendación

9.3.1 Selección de técnica de modelado y construcción

El sistema de recomendación utilizado en la presente memoria es el SVD debido a su capacidad de relacionar datos con la reducción de dimensionalidad vista en el marco teórico.

La construcción del modelo se realizará mediante la documentación de Surprise, una librería de Python desarrollada en el año 2017 por Nicolas Hug, Machine learning Phd of the research institute in computer science of Toulouse.

Dado que la estructura de los datos transformados puede ser utilizada en más de un modelo de recomendación por medio de Python. Surge la idea de comparar el rendimiento teórico de los otros modelos también.

Los modelos con los que se compararán la precisión de las predicciones serán con modelo SVD, el SVD++, Slope One, NMF y Co Clustering model.

9.3.2 Descripción de la comparación con otros modelos

La comparación con los demás modelos consiste en predecir las valoraciones del set de datos que ya tienen valoración. Por ejemplo, si un cliente i da una valoración j por los productos k , se utilizarán. Se utilizarán las valoraciones de todos los clientes sin incluir a i para predecir las valoraciones j en los productos k que valoró el cliente.

Entonces, entre las valoraciones que se tiene y las predichas por cada modelo se tendrá un error que será capturados por los indicadores MAE y RMSE.

Los trainset, para efectos de evaluación entre los distintos modelos, se harán utilizando una validación cruzada de 3 partes. Para la generación de recomendaciones para la etapa experimental se utilizará una validación cruzada en 5 partes.

9.3.3 Construcción del modelo SVD

La aplicación del modelo es a través de python. La documentación y algoritmo pueden ser encontrados en la página de surprise en github.

Los parámetros utilizados para la realización de este modelo fue considerar la sugerencia de Simon Funk de definir en 0,001 la tasa de aprendizaje l_{rate} y en 0.02 la tasa de

regularización λ . También se definió el número máximo de iteraciones del modelo de la gradiente descendiente en 30.

Se realizará una validación cruzada de 5 iteraciones en que la dataset es dividida en 5 partes iguales en la cuales el experimento irá iterando utilizando una parte para testing y las otras 4 para training. Cuando cada una de las 5 partes hayan sido utilizadas como testing, el experimento termina.

Por último, se configura el modelo arroje las 10 predicciones con mayor valoración esperada para cada cliente i .

9.3.4 Comparación del modelo SVD con similares

A continuación, en las tablas 10 y 11 se encuentran los resultados del MAE y RMSE utilizando una validación cruzada en 3 partes para diversos modelos similares en cada perfil de datos. Además se calibrará el modelo para el dataset considerando a todos los perfiles juntos, el conjunto completo de datos es referido como “Global”. Los datos en negro corresponden a los valores más bajos de cada perfil. Además, en c

En la tabla 10 se puede apreciar que, para efectos del MAE, las mejores precisiones para cada perfil se encuentran principalmente en el modelo de recomendación SVD++.

En la tabla 11, para efectos del RMSE, se tiene que los menores valores se encuentran en su mayoría en el modelo SVD.

Dado que, en ambos, no existe una diferencia significativa en sus indicadores, se confirma que tiene sentido utilizar el modelo SVD para realizar las predicciones en el diseño experimental.

El algoritmo SVD utilizado en el dataset movielens [19], documento que guarda 100.000 evaluaciones de 1 a 5 aplicadas a 9.000 películas por 600 usuarios tiene un RMSE de 0,9342 y un MAE 0,7357. Estos valores son menores que los presentados en la tabla 11 y 12, pero es debido a que la evaluación no es de 1 a 12, si no que de 1 a 5, esta diferencia es lo que reduce el nivel de error. De todos modos, teniendo una escala de evaluación dos veces más amplia que el movielens, el RMSE y MAE del dataset de la presente memoria no varía lo suficiente como para concluir que tiene mal rendimiento.

MAE	Abarrotero	Aderezos	Food Service	Golosinero	Limpieza	Panadería Bodega	Panadería	Varios	Sin Etiqueta	Global
Predictor Normal	1,6299	1,6902	1,6663	1,6224	1,497	1,568	1,6764	1,7644	0,4739	1,6283
SVD	0,9573	1,0553	1,0724	0,9008	0,9147	1,2651	1,0672	1,1223	0,2965	0,9653
SVD++	1,0112	0,9957	1,0415	0,9205	0,9011	1,2398	1,0417	1,1147	0,2789	1,001
Slope One	1,032	1,024	1,0713	0,9818	0,9543	1,2528	1,0857	1,1463	0,2753	1,0408
NMF	0,9784	1,0409	1,0644	0,9114	0,911	1,249	1,0685	1,1233	0,2365	0,992
Co Clustering	1,0429	1,0666	1,1049	0,9965	0,9751	1,2597	1,1161	1,1705	0,2561	1,055

Tabla 10: MAE de cada modelo en cada perfil. Elaboración propia.

RMSE	Abarrotero	Aderezo	Food Service	Golosinero	Limpieza	Panadería Bodega	Panadería	Varios	Sin Etiqueta	Global
Predictor Normal	2,1094	2,2159	2,1693	2,1069	1,9794	2,0234	2,1713	2,377	0,6944	2,1148
SVD	1,3494	1,4009	1,4179	1,2353	1,2463	1,6387	1,4123	1,5998	0,4708	1,3737
SVD++	1,4568	1,382	1,4329	1,3125	1,2758	1,6537	1,4309	1,6345	0,4578	1,4631
Slope One	1,3499	1,4174	1,4275	1,3028	1,2831	1,6343	1,4253	1,614	0,4885	1,3667
NMF	1,3135	1,5249	1,4912	1,2688	1,2733	1,6902	1,4619	1,6432	0,4805	1,3447
Co Clustering	1,359	1,5243	1,5076	1,3292	1,3129	1,657	1,487	1,6521	0,499	1,3862

Tabla 11: RMSE de cada modelo en cada perfil. Elaboración propia.

Se puede apreciar, que los modelos tienen un rendimiento muy similar tanto para el perfil abarroteros como para el dataset global. Esto es debido al gran porcentaje de los datos que representa el perfil abarroteros sobre el total.

Se observa de todos modos que el modelo calibrado de manera global al contener a todos los demás perfiles, tiene una distorsión que hace que tenga ligeramente un peor MAE y RMSE que los indicadores de los abarroteros. Esto se encuentra alineado con la hipótesis de que un modelo calibrado de manera específica, tiene mejor rendimiento experimental que uno calibrado de manera global.

9.3.5 Generación de recomendaciones

Dependiendo del perfil en que se ejecuta, el modelo demora en procesar entre 5 minutos en el caso del perfil limpieza a 8 horas en el perfil abarroteros. Estos fueron procesados en un Intel i7 de 2.60 Ghz con 16 gb de RAM, siendo esta ultima el principal cuello de botella en el procesamiento.

Por falta de recursos no fue posible ejecutar el modelo para el dataset global en un ordenador de escritorio sin realizar muestreo. De todos modos, gracias al acceso a uno de los servidores utilizados para data mining en la Universidad de Chile, se logró procesar el dataset completo en alrededor de 45 min.

En la tabla 12 se puede apreciar la estructura con la cual se obtienen las recomendaciones, en la cual para cada conjunto de datos se agrupan los clientes y a su derecha 10 recomendaciones ordenadas según su valoración esperada, en donde R1 representa el producto con mayor valoración esperada de las diez. Cabe destacar, que los resultados del modelo son recomendaciones de productos no comprados por el cliente en el periodo que se contempla.

Código de cliente	Producto Rec. 1	Producto Rec. 2	Producto Rec. 3	Producto Rec. 4	Producto Rec. 5	Producto Rec.6	Producto Rec. 7	Producto Rec. 8	Producto Rec. 9	Producto Rec. 10
6	4566	4044	8478	8904	4222	8295	4560	586	4552	53
43	4116	4562	9145	8168	8351	7945	4059	4058	9645	4050
78	4347	5025	906	8330	4743	9164	902	4971	8419	8925
88	3807	9048	9569	9136	4222	7964	9145	9150	9402	8357
103	4560	8295	4553	4971	4223	4221	4572	4043	4573	631
154	411	4337	8424	8474	9134	4016	4958	8821	4743	8331
156	382	4060	4824	4949	4959	4364	8415	9568	8904	4107
172	4551	4566	469	9625	4217	4213	8351	8357	4560	575
205	593	4849	4562	8330	7935	8508	8510	4193	4566	3783
240	4192	4236	4319	4462	4963	9569	4016	8925	4561	647
253	3807	9569	9165	4219	8331	8425	8428	4551	9385	4218

Tabla 12: Códigos de productos recomendados para el perfil panadería. Elaboración propia.

9.4 Diseño Experimental

9.4.1 Descripción del experimento e indicadores.

Para medir la real efectividad de los modelos empleados, se debe realizar un experimento que determine si existen diferencias significativas entre grupos experimentales y de control de cada hipótesis.

Se medirá el desempeño del modelo en 3 ámbitos distintos que brinden la oportunidad de caracterizarlo. Para esto se utilizarán tres indicadores para evaluar las hipótesis que se propondrán. En primer lugar, se tiene el indicador de venta PS que se define como:

$$\text{Tasa de venta PS} = \frac{\text{Cantidad de venta con PS del cliente } i \text{ en el perfil } j \text{ en la semana } k}{\text{Cantidad de venta total del cliente } i \text{ en el perfil } j \text{ en la semana } k} \quad (9.4.1.1)$$

Este indicador controlará el cambio entre la proporción de ventas con pedido sugerido que se tienen entre los grupos de control y tratamiento.

El segundo indicador, será el mismo utilizado en la memoria de la Ignacio Diaz, tiene por nombre tasa de efectividad y se define como sigue:

$$\text{Tasa de efectividad} = \frac{\text{Cantidad de productos PS aceptados del cliente } i, \text{ en el perfil } j, \text{ en la semana } k}{\text{Cantidad de productos visualizados por el cliente } i, \text{ en el perfil } j, \text{ en la semana } k} \quad (9.4.1.2)$$

Este indicador, tal y como su nombre sugiere, sirve para medir la efectividad de la recomendación en las estrategias.

Finalmente, se tiene el indicador de cantidad de productos PS distintos vendidos que se define como sigue:

“Cantidad de productos PS aceptados que no habían sido comprados en las últimas 12 semanas por el cliente i , en el perfil j , en la semana k ”

Este último indicador no es una tasa puesto que la fracción de productos que se vende por PS versus los visualizados, ya es una tasa bastante pequeña. Si esta tasa se le limitaba a solo los productos distintos, se prestaba para que los análisis fueran más complejos debido a lo pequeño del número. El indicador expresado como esta, permite un análisis más simplificado del comportamiento macro de los productos distintos vendidos.

La posición de venta de las recomendaciones por defecto será la segunda. Para los experimentos en que se testeé la posición, se variará.

9.4.2 Descripción de la construcción de grupos de control y experimental

Las muestras probabilísticas que determinan los grupos de control y experimental serán escogidas en base a la similitud que tengan en los indicadores de tasa de venta PS y efectividad.

Asumiendo un nivel de confianza del 95% y un 5% de margen de error, el tamaño de muestra óptimo para realizar los grupos de control y experimental es de 384 personas por grupo.

En una primera iteración del experimento se testeó con grupos de control de 400 clientes. En esta iteración se tuvo problemas con la significancia, dado que no todos los clientes compran todas las semanas. Por lo que, para evitar cualquier tipo de problema de significancia de los datos, se construyeron los grupos con 700 clientes cada uno.

Para realizar el muestreo lo más aleatorio posible, se separaron los clientes según su perfil, luego se ordenaron de mayor a menor según ambos indicadores. Después se selecciona una cantidad de clientes en torno a la media de los indicadores. Esta cantidad tiene que ser lo suficientemente grande para que se puedan extraer todos los grupos necesarios para el perfil. Por ejemplo, si en el perfil abarroteros se necesitan 5 grupos de 700 personas, se escogen 3500 clientes en torno a la media de los indicadores. Luego en esa misma lista se enumeran iterativamente del 1 al 5, los 2800 clientes en que el número que le toco entre los 5, corresponde al grupo determinado. De este modo se logró que todos los grupos tengan indicadores muy similares y sin romper la aleatoriedad.

9.4.3 Aprendizajes de la fase de prueba del experimento

Paralelo a la construcción formal del experimento, se levantó una fase de prueba en la cual se encontraron aprendizajes relevantes para el experimento.

En esta iteración se encontró que no todos los clientes realizan transacciones durante una semana, este problema le quita significancia al experimento si la muestra de datos se construye de manera justa. De esta manera surgió el aprendizaje explicado anteriormente de considerar 700 clientes por grupo.

También se encontró que las recomendaciones del modelo SVD tienen muy pocas variaciones, de una semana a otra, máximo varían 2 productos en la lista a recomendar. De todos modos, este no es un problema que tenga únicamente el modelo SVD, También lo enfrenta la estrategia perfil de la empresa.

En esta primera iteración, solo se logran ventas en el primer periodo, luego de esto es ínfima o nula la venta. Se cree que esto pueda deberse a que ofrece productos distintos

que son iguales todas las semanas, es decir, contradice la componente de novedad de la recomendación.

Para ver si realmente existe este problema, se realizará un experimento paralelo en que se eliminarán los visualizados y no comprados de la lista de recomendación.

A continuación, se describirán las hipótesis que se evaluarán en esta memoria. Estas se pueden dividir principalmente en 3 grupos y para efectos prácticos, se abreviará el indicador de venta PS como Venta PS, la tasa de efectividad como Efectividad y el indicador de productos distintos como Productos distintos.

9.4.4 Hipótesis generales

1. *"El indicador i es mejor para el modelo SVD global que para el modelo predeterminado utilizado por la empresa" Para $i = \{Venta\ PS, Efectividad, Productos\ distintos\}$.*

Esta hipótesis responde a la pregunta de si el modelo SVD realiza mejores recomendaciones que el modelo utilizado por la empresa, ocupando todo el dataset, es decir, sin agrupar las compras por perfil de clientes.

Para evaluar este comportamiento general, el grupo experimental es construido en base a la unión de todos los grupos de control de las hipótesis explicadas a continuación en el punto 9.4.6 que testean el comportamiento del modelo SVD calibrado a cada perfil versus el modelo SVD calibrado de manera global.

El grupo de control para esta hipótesis corresponde a la unión de todos los grupos de control que se utilizarán en las hipótesis 9.4.5 que evalúan el desempeño del modelo SVD calibrado a cada perfil versus el desempeño del modelo utilizado por la empresa.

Todo esto se puede realizar, puesto que, al tener indicadores muy similares, y ser mezclados en la misma proporción, pondera los indicadores de igual manera y permite una comparación adecuada que brinda una visión del panorama general del modelo.

2. *"El indicador i es mayor en las bodegas que en los puestos de mercado utilizando modelo SVD para el dataset global" Para $i = \{Venta\ PS, Efectividad, Productos\ distintos\}$.*

Dado que las dos bocas de salida más importantes son las bodegas y puestos de mercado, es que se quiere describir si existe mayor susceptibilidad a la sugerencia de pedido por parte de alguna.

La muestra de este experimento al igual que en las hipótesis anteriores consiste en tomar una muestra por perfiles de los 4200 clientes que fueron utilizados para ser testeados por el modelo global. Esta selección está condicionada en que el grupo experimental de 700 solo tendrán clientes con bocas de salida bodega. Lo mismo con el grupo de control que a su vez estará condicionado para que los clientes sean de la boca de salida puesto de mercado.

3. *"El indicador i es mejor para el modelo SVD global cuando la recomendación se utiliza en la posición de la primera estrategia que cuando se realiza en la segunda" Para $i = \{Venta PS, Efectividad, Productos distintos\}$.*

En la memoria relacionada de Ignacio Diaz, se puede encontrar que el orden de las estrategias en que se realizan las recomendaciones, tiene incidencia significativa en los indicadores de venta. Como el modelo propuesto solo recomienda productos que no ha comprado el cliente, se sitúa en la segunda estrategia de tres. Es por esto que en esta hipótesis se quiere probar que estando en primer lugar de las recomendaciones, los indicadores podrían aumentar más aún. Y que estando en el último lugar, estos bajarían.

Para esta hipótesis, la muestra probabilística para el grupo de control consiste en tomar 700 clientes de los grupos de control de las hipótesis 9.4.6 en donde se evalúa un grupo experimental con el modelo SVD ajustado a cada perfil versus un grupo de control del mismo modelo SVD, pero ajustado globalmente.

Además, se toma una nueva muestra de 700 clientes con los indicadores de venta PS y tasa de efectividad similares, pero que serán evaluados utilizando el modelo global en el primer lugar de las estrategias.

4. *"El indicador i es peor para el modelo SVD global cuando la recomendación se utiliza en la tercera estrategia que cuando se realiza en la segunda" Para $i = \{Venta PS, Efectividad, Productos distintos\}$.*

Es prácticamente igual que la hipótesis anterior, utiliza el mismo grupo de control anterior, pero el grupo experimental son 700 clientes nuevos que son evaluados utilizando el modelo global, pero tercera en el orden de estrategias.

9.4.5 Hipótesis referidas al rendimiento del modelo propuesto versus el utilizado por la empresa.

Este grupo cuenta con 6 hipótesis que se evaluarán para los 3 indicadores por separado, es decir, se experimentará con 18 hipótesis en total. La finalidad de este conjunto de hipótesis es evaluar la efectividad del modelo propuesto por la memoria comparado al motor de recomendaciones utilizado actualmente por la empresa.

Como son 6 hipótesis que se evalúan para 3 indicadores distintos, los grupos de tres hipótesis semejantes pueden compartir la muestra probabilística de 700 clientes para el grupo de control y 700 clientes para el grupo experimental. Cabe destacar que si la hipótesis corresponde a algún perfil específico, la muestra pertenecerá a ese perfil también.

Dado que se comprobará el comportamiento del modelo si se considera la eliminación de los productos visualizados y no comprados, se añadirá un nuevo grupo experimental de 700 clientes.

Entonces, en este grupo de 18 hipótesis se utilizarán un total de 4200 clientes para el grupo de control y 8400 clientes para el grupo experimental.

A continuación, se escribirán en detalle las hipótesis:

1. *“El modelo de recomendación SVD aumenta el indicador i con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil ABARROTADOS.” Para $i = \{Venta PS, Efectividad, Productos distintos\}$.*
2. *“El modelo de recomendación SVD aumenta el indicador i con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil FOOD SERVICE.” Para $i = \{Venta PS, Efectividad, Productos distintos\}$.*
3. *“El modelo de recomendación SVD aumenta el indicador i con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil GOLOSINEROS.” Para $i = \{Venta PS, Efectividad, Productos distintos\}$.*
4. *“El modelo de recomendación SVD aumenta el indicador i con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil LIMPIEZA.” Para $i = \{Venta PS, Efectividad, Productos distintos\}$.*
5. *“El modelo de recomendación SVD aumenta el indicador i con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil PANADERÍAS BODEGA.” Para $i = \{Venta PS, Efectividad, Productos distintos\}$.*

6. *“El modelo de recomendación SVD aumenta el indicador i con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil PANADERÍAS.” Para $i = \{Venta PS, Efectividad, Productos distintos\}$.*

9.4.6 Hipótesis referidas al rendimiento del modelo propuesto por perfil versus el mismo modelo ajustado de manera global.

Este grupo también cuenta con 18 hipótesis a partir de 6 principales que son evaluadas para 3 indicadores de manera separada.

Como se compara el rendimiento de los modelos ajustados para cada perfil versus un modelo ajustado de manera global, se utiliza para el grupo experimental la misma muestra por perfil que en el grupo de hipótesis anteriores. Para el grupo de control se define una nueva muestra de 700 clientes para cada perfil en los cuales se utiliza el modelo ajustado de manera global. Este nuevo grupo de 700 clientes por perfil también puede ser utilizados para medir las hipótesis de los tres indicadores propuestos.

Entonces en total, este grupo de hipótesis reutiliza el grupo experimental del grupo de hipótesis 9.4.4, que son 4200 en total y además requiere de una nueva muestra independiente de 4200 clientes más.

Las hipótesis son las siguientes:

1. *“El indicador i es mejor para los modelos de recomendación SVD en el perfil ABARROTEROS, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.” Para $i = \{Venta PS, Efectividad, Productos distintos\}$.*
2. *“El indicador i es mejor para los modelos de recomendación SVD en el perfil FOOD SERVICE, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.” Para $i = \{Venta PS, Efectividad, Productos distintos\}$.*
3. *“El indicador i es mejor para los modelos de recomendación SVD en el perfil GOLOSINEROS, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.” Para $i = \{Venta PS, Efectividad, Productos distintos\}$.*
4. *“El indicador i es mejor para los modelos de recomendación SVD en el perfil LIMPIEZA, que si se utiliza un modelo SVD ajustado a la data global que haga*

recomendaciones para todos los perfiles.” Para $i = \{Venta\ PS, Efectividad, Productos\ distintos\}$.

5. *“El indicador i es mejor para los modelos de recomendación SVD en el perfil PANADERÍAS BODEGA, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.” Para $i = \{Venta\ PS, Efectividad, Productos\ distintos\}$.*
6. *“El indicador i es mejor para los modelos de recomendación SVD en el perfil PANADERÍAS, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.” Para $i = \{Venta\ PS, Efectividad, Productos\ distintos\}$.*

9.5 Evaluación de resultados

9.5.1 Explicación inicial de la evaluación

Para simplificar la exposición de los resultados y poder agruparlos según interés, se presentarán los resultados según los perfiles respectivos de clientes. A partir de esto, se irá concluyendo respecto a las distintas hipótesis formuladas.

Para facilitar además la interpretación intuitiva del comportamiento de los distintos grupos experimentales, se desplegarán los resultados de todos los grupos experimentales en un mismo gráfico por cada indicador.

En cada gráfico, el periodo comprendido entre la semana 44 hasta la 47 del año corresponde al comportamiento previo de los clientes al experimento y desde la semana 48 a la semana 51 del año corresponde a los comportamientos que tienen los clientes con el experimento funcionando. El inicio de la semana 44 corresponde al lunes 30 de octubre del año 2017, el inicio de la semana 48 es el 27 de noviembre del año 2017 y el fin de la semana 51 es el domingo 24 de diciembre del 2017, fecha en que termina el experimento.

La leyenda de los gráficos está compuesta por abreviaciones, estas pueden ser directas como gc que representa al grupo de control, y menos directas como m1g1 que habla sobre el modelo y grupo al cual hace referencia.

Se considerarán de grupos g1, g2 que hacen referencia a si el modelo se calibró de manera específica a su perfil o se hizo de manera global a todo el dataset.

También se escribirá de modelo 1 m1 y modelo 2 m2 haciendo referencia a que en el modelo 2 se realizará una etapa de post procesado en que se eliminan los productos

visualizados y no comprados para cada uno de los periodos de experimentos Además en el modelo m2, en la semana 48 se recomendaron los productos que fueron visualizados y aceptados en las anteriores 4 semanas con el fin de generar adopción del producto. Pero luego de esta semana se determinó quitar este apoyo y solo mantener la eliminación de los visualizados y no comprados. El modelo m1 es el que no presenta las diferencias que se aplican en el modelo m2.

Dado que en general en las semanas 48 y 49, las recomendaciones variaron poco. Se decidió no volver a procesar los datos de las 12 semanas anteriores en la semana 50. Sino que se decidió recomendar a partir de los 10 productos obtenidos de la semana 49. Es decir, se eliminan las dos recomendaciones con más alta prioridad de la semana 49 para dejar como primeras dos a la tercera y cuarta de la semana 49. Lo mismo en la semana 51 en que se eliminan las primera y segunda de la semana 50 para que la quinta y sexta de la semana 49, sean recomendadas en primer lugar.

De este modo se espera que este mayor dinamismo forzado incentive a la recomendación de productos.

La hipótesis de manera semanal se considerará validada si para el indicador respectivo, existe diferencia estadística significativa con un 90% o 95% de confianza según un test t de una cola. Se escribirá la confianza en 90% y 95% para que se pueda apreciar el grado de diferencia estadística que existe según el caso. En cualquier otro caso, no se validará la hipótesis.

Como son 4 periodos de experimento, se considerará validada la hipótesis de manera general a las 4 semanas a evaluar si se cumplen las siguientes consideraciones:

- En 3 periodos o más, el indicador de interés es mayor significativamente.
- En 2 periodos el indicador de interés tiene significancia estadística, pero en un periodo no existe diferencia estadística y en el otro, el indicador de la hipótesis nula es mayor significativamente que el indicador de interés.
- En 1 periodo la hipótesis se válida para el indicador respectivo, pero en los otros 3 periodos no se puede rechazar la hipótesis de que sean iguales
- En los casos en que exista igual cantidad de validados que casos en que el indicador contrario es mayor que el indicador de interés, no se validará la hipótesis para el periodo completo.

Entonces, a modo de resumen se tiene que el significado de la leyenda es el siguiente:

- Gc: Corresponde al grupo de control que no realiza experimento en ningún momento.
- M1g1: Grupo experimental que realiza recomendaciones con el modelo calibrado de manera específica al perfil trabajado en las 12 semanas. En este grupo no se elimina ni realiza ninguna modificación de la recomendación.
- M1g2: Grupo experimental que realiza recomendaciones con el modelo calibrado de manera global, es decir utilizando todo el conjunto de datos en las 12 semanas. En este grupo no se elimina ni realiza ninguna modificación de la recomendación.
- M2g1: Grupo experimental que realiza recomendaciones con el modelo calibrado de manera específica al perfil, pero que apoya al modelo a partir de la eliminación de productos visualizados y no comprados, etc.
- M2g2: Grupo experimental que realiza recomendaciones con el modelo calibrado de manera global utilizando toda la información de las 12 semanas. Además se apoya el modelo a partir de la eliminación de visualizados y no comprados, etc.

9.5.2 Resultados para la hipótesis que compara el modelo ajustado de manera global con el usado por la empresa.

En esta sección se evaluará la hipótesis 9.4.6.1. esto porque los modelos calibrados de manera global m1g2 y m2g2 tuvieron malos resultados en todos los perfiles, con esto no se tiene ningún riesgo en asegurar que no se valida la hipótesis.

La hipótesis 9.4.6.1 dice:

“El indicador i es mejor para los modelos de recomendación SVD en el perfil ABARROTEROS, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.” Para $i = \{Venta\ PS, Efectividad, Productos\ distintos\}$.

Para el modelo 1, es decir, utilizando los grupos m1g2 de los experimentos realizados. Se tiene que para el indicador de venta PS, en el 100% de los periodos y perfiles, el valor del indicador es significativamente menor que los grupos de control con 95% de confianza. Para la tasa de efectividad, también se tiene que el 100% de los periodos y perfiles tiene un valor menor que los grupos de control con 95% de confianza. Para el indicador relacionado a los productos distintos se tiene que, en los 6 perfiles, en un 79,16% de los casos, el valor de m1g2 es significativamente menor que el grupo de control. En el 20,8% de los casos restantes, solo se puede decir que no tienen diferencia significativa.

Dada las proporciones de los perfiles con respecto al sistema como se expuso en el análisis descriptivo, se tiene que el perfil abarroteros, es un buen indicador del sistema en general. En este caso, ningún indicador de m1g2 supera al grupo de control en los Gráfico 31, Gráfico 32 y Gráfico 33 del perfil abarroteros.

Para el modelo 2 donde se comparará el grupo m2g2 con los grupos de control, se tiene para el indicador de venta PS en el 91,6% de los casos es significativamente menor que indicador del grupo de control. En el 8,3% de los casos restante el indicador de venta PS supera significativamente al grupo de control. Lamentablemente ninguno de estos casos positivos es en el grupo de control, y ambos se encuentran en la semana 48 que es la semana que recibió la ayuda de además recomendar los productos que habían sido aceptados por PS las 4 semanas anteriores.

Para la tasa de efectividad se tiene en el 100% de los casos el indicador para el grupo m2g2 es significativamente menor que el grupo de control con 95% de confianza

Con respecto al indicador de productos distintos, se tiene que en el 87,5% de los casos el grupo m2g2 es significativamente menor que el grupo de control con un 95% de confianza.

Solo en un 8,3% de los casos, es decir en dos casos, no fue significativamente menor y en el 4,1%, es decir, 1 caso, fue significativamente mayor que el grupo de control. Este caso también fue en la semana 48 y no en el perfil abarroteros.

Es por todo esto que no se valida la hipótesis de que el modelo calibrado de manera global, es significativamente mejor que el modelo utilizado por la empresa en los indicadores venta PS, efectividad y productos distintos.

9.5.3 Resultados para las hipótesis que comparan el rendimiento de las bodegas versus los puestos de mercado.

La primera hipótesis corresponde a:

- *“El indicador venta PS es mayor en las bodegas que en los puestos de mercado utilizando modelo SVD para el dataset global”*

En el Gráfico 25 del anexo B, se puede observar la evolución del comportamiento previo y posterior al experimento que tiene el indicador de venta PS para un grupo experimental conformado por bodegas y un grupo de control compuesto por puestos de mercado.

El test t aplicado a los resultados de las 4 semanas de experimentos arroja que no se puede rechazar la hipótesis nula a un 95% de confianza de que no existe diferencia entre la venta

PS de las bodegas y puestos de mercado. En la Tabla 15 del anexo B se encuentra adjunto el test t realizado.

Esta es una conclusión esperable dado los malos resultados del modelo calibrado de manera global en general.

La segunda hipótesis relacionada al indicador de Efectividad es:

- *“El indicador Efectividad es mayor en las bodegas que en los puestos de mercado utilizando modelo SVD para el dataset global”.*

En el Gráfico 26 del anexo B se puede observar el comportamiento en el tiempo del indicador Efectividad para los puestos de mercados y bodegas. La principal diferencia entre ambos se dio en la semana 48 en el que los puestos de mercado, el modelo SVD tiene mayor efectividad.

Considerando todos los periodos en que se realizó el experimento, y dado que los grupos de control y experimental fueron construidos según el indicador Venta PS y Productos Distintos de las 4 semanas anteriores al experimento, se realiza un test t para el indicador Efectividad que considera una diferencia hipotética de 0,01 entre las medias. Esto porque en los 4 periodos de control de las dos muestras se aprecia una diferencia consistente de 0,01 tal y como se observa en el Gráfico 26.

Entonces según el test t que se encuentra en la Tabla 16 del anexo B, se tiene que no existen diferencias significativas entre la efectividad del modelo SVD en las Bodegas y Puestos de mercado utilizando el modelo SVD.

La tercera hipótesis relacionada al indicador productos distintos es:

- *“El indicador Productos Distintos es mayor en las bodegas que en los puestos de mercado utilizando modelo SVD para el dataset global”.*

En el Gráfico 27, se puede apreciar la evolución del indicador de productos distintos para los clientes bodega y los clientes puestos de mercado. En las 4 semanas anteriores al experimento, las muestras son similares.

Según el test t de los 4 periodos, no existe diferencia significativa del modelo SVD en el indicador de Productos distintos. El test se encuentra adjunto en la Tabla 17 del anexo B.

9.5.4 Resultados del experimento cuando se alterna la posición de la estrategia

En los Gráfico 28, Gráfico 29, Gráfico 30 del anexo B se encuentran las evoluciones de las muestras utilizadas para los tres indicadores utilizados. En estos mismos gráficos, los grupos de datos “posición 1” corresponden a la muestra de clientes a los cuales se les recomendaron productos utilizando el modelo SVD, pero en primera posición con respecto a las otras estrategias. Los grupos de datos “posición 2” son el lugar donde se realiza las recomendaciones del modelo SVD por defecto en esta memoria, es decir en la segunda ubicación. Por último, el grupo “posición 3” corresponde al grupo en que su recomendación como estrategia se encontró en el último lugar.

La primera hipótesis referente a la posición es la siguiente:

- *"El indicador Venta PS es mejor para el modelo SVD global cuando la recomendación se utiliza en la posición de la primera estrategia que cuando se realiza en la segunda".*

Con respecto a esta hipótesis, según el test t se puede apreciar en la Tabla 18, que no se presentan diferencias significativas entre ambos grupos.

- *"El indicador Efectividad es mejor para el modelo SVD global cuando la recomendación se utiliza en la posición de la primera estrategia que cuando se realiza en la segunda".*

Del mismo modo que la hipótesis anterior, no se tienen diferencias significativas entre posiciones tal y como se puede apreciar en la Tabla 19.

- *"El indicador Productos Distintos es mejor para el modelo SVD global cuando la recomendación se utiliza en la posición de la primera estrategia que cuando se realiza en la segunda".*

En la Tabla 20 del anexo B se puede observar que no existen diferencias significativas entre las posiciones 1 y 2 de las recomendaciones para el indicador productos distintos.

Las siguientes 3 hipótesis que comparan el rendimiento de los indicadores en la segunda y tercera posición. La primera hipótesis es:

- *"El indicador Venta PS es peor para el modelo SVD global cuando la recomendación se utiliza en la tercera estrategia que cuando se realiza en la segunda".*

Según la Tabla 21 del anexo B, no existen diferencias significativas entre la posición 3 y la segunda.

- *"El indicador Efectividad es peor para el modelo SVD global cuando la recomendación se utiliza en la tercera estrategia que cuando se realiza en la segunda".*

Del mismo modo que la tabla anterior, en la Tabla 22 se puede apreciar que no existen diferencias significativas entre la posición 2 y la 3.

- *"El indicador Productos distintos es peor para el modelo SVD global cuando la recomendación se utiliza en la tercera estrategia que cuando se realiza en la segunda".*

En la Tabla 23 tampoco se rechaza la hipótesis nula entre la posición 2 y 3.

9.5.5 Resultados de las hipótesis referidas al rendimiento del modelo propuesto versus el utilizado por la empresa.

1) Resultados para el perfil Abarroteros

En los Gráfico 31Gráfico 32Gráfico 33 del anexo B se puede apreciar el comportamiento de 8 semanas de los grupos experimentales y de control para los indicadores Venta PS, Efectividad y productos distintos. De estas 8 semanas, solo las últimas 4 son las que se realizó el experimento.

La hipótesis relacionada al primer indicador es:

- *"El modelo de recomendación SVD aumenta el indicador Venta PS con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil ABARROTOS."*

De esta hipótesis, considerando los 4 periodos en que se realiza el experimento se tiene en las Tabla 24 Tabla 25 del anexo B que se rechaza la hipótesis nula con un 95% de confianza

de que el modelo SVD y el utilizado por la empresa tienen el mismo rendimiento, ya sea considerando o no los productos vistos y no comprados.

Para este perfil, el modelo SVD no aumenta la venta PS.

La hipótesis relacionada al segundo indicador es:

- *“El modelo de recomendación SVD aumenta el indicador Efectividad con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil ABARROTEROS.”*

En esta hipótesis, considerando los 4 periodos se tiene en las Tabla 26 Tabla 27 que también se rechaza la hipótesis nula con un 95% de confianza de que no son iguales, pero también en favor del modelo utilizado por la empresa.

Por lo que se puede concluir que el modelo SVD no aumenta el indicador efectividad para este perfil.

La hipótesis relacionada el último indicador es:

- *“El modelo de recomendación SVD aumenta el indicador Productos Distintos con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil ABARROTEROS.”*

En el test t realizado para esta hipótesis se tiene que existe diferencia estadísticamente significativa, pero a favor del grupo de control. Con esto entonces no se puede decir que el modelo SVD mejora el indicador Productos distintos.

En general, se puede apreciar que cuando se ayuda al modelo m2 eliminando los productos visualizados y no comprados, el desempeño mejora un poco, no superando al grupo de control.

En general el modelo SVD no arrojó buenos resultados para el perfil abarroteros, esto dado que ningún grupo experimental tuvo mejor resultado que el grupo de control, pese a tener un comportamiento similar en el pasado.

2) Resultados para el perfil Food Service

La hipótesis relacionada al indicador venta PS es:

- *“El modelo de recomendación SVD aumenta el indicador Venta PS con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil FOOD SERVICE.”*

Para esta hipótesis, según las Tabla 36 y Tabla 37 del anexo B, se tiene que se rechaza la hipótesis nula con un 95% de confianza de que SVD y el modelo utilizado por la empresa tienen el mismo rendimiento, pero en favor del grupo de control. Es decir que el modelo SVD no incrementa el indicador Venta PS.

Algo interesante ocurre en el indicador de venta PS en el periodo inicial del experimento en el caso m2 que recibe la ayuda de eliminar los visualizados y no comprados. En este primer periodo además se recomendaron productos que si habían sido aceptados con anterioridad, por lo que se podría tomar una recomendación híbrida entre el modelo de recomendación SVD y el motor de recomendaciones utilizado por la compañía.

Lo interesante que ocurre es que el indicador de venta PS en el primer periodo para el grupo calibrado específicamente al perfil es significativamente mayor con un 95% de confianza que el grupo de control tal y como se aprecia en el Gráfico 34 del anexo B.

La hipótesis correspondiente al indicador Efectividad es:

- *“El modelo de recomendación SVD aumenta el indicador Efectividad con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil FOOD SERVICE.”*

En esta hipótesis, según la Tabla 38 y Tabla 39 del anexo B, se tiene que el grupo de control no tiene el mismo rendimiento que los grupos experimentales. Es decir que se rechaza la hipótesis nula, pero en favor del grupo de control con un 95% de confianza. De esto se concluye que el modelo SVD no incrementa el indicador Efectividad con respecto a modelo que utiliza la compañía.

En el Gráfico 35 de los anexos, se puede apreciar el comportamiento de los grupos experimentales y control con respecto a la hipótesis propuesta.

La hipótesis referida al indicador productos distintos es:

- *“El modelo de recomendación SVD aumenta el indicador Productos Distintos con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil FOOD SERVICE.”*

Según las Tabla 40 y Tabla 41 del anexo B, se puede apreciar que el modelo SVD tampoco tiene buen rendimiento para el indicador productos distintos en el perfil Food Service. Esto porque el grupo de control es significativamente mayor con un 95% de confianza que los grupos experimentales.

En el Gráfico 36 de los anexos, se puede apreciar el comportamiento del grupo de control y experimental con respecto a la hipótesis propuesta al indicador Productos Distintos.

3) Resultados para el perfil Golosineros

La primera de las tres hipótesis relacionadas al perfil es la siguiente:

- *“El modelo de recomendación SVD aumenta el indicador Venta PS con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil GOLOSINEROS.”*

El comportamiento de Venta PS para el perfil Golosineros no fue bueno, en las Tabla 48 y Tabla 49 del anexo B, se puede apreciar que el grupo de control es mayor que el grupo experimental y además se rechaza la hipótesis nula con un 95% de confianza de que ambos son iguales.

En el Gráfico 37 de anexos se puede apreciar el comportamiento promedio del indicador venta PS para los grupos experimentales y de control en las semanas de experimento.

La siguiente hipótesis relacionada al indicador Efectividad, es el siguiente:

- *“El modelo de recomendación SVD aumenta el indicador Efectividad con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil GOLOSINEROS.”*

Al igual que en el indicador anterior, el grupo experimental efectividad es menor que el grupo de control y se rechaza la hipótesis nula de que son iguales con un 95% de confianza según el test t realizado en las Tabla 50 y Tabla 51 del Anexo B.

En el Gráfico 38 de anexos se puede apreciar el comportamiento promedio semanal de los grupos experimentales y de control que testean el indicador Efectividad.

Finalmente, la hipótesis para el indicador Productos Distintos es:

- *“El modelo de recomendación SVD aumenta el indicador Productos Distintos con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil GOLOSINEROS.”*

Al igual que en los anteriores, el test t tiene un mal rendimiento para el perfil Golosineros en el indicador Productos Distintos, el grupo de control es mayor con un 95% de confianza y se rechaza la hipótesis nula como se aprecia en las Tabla 52 y Tabla 53 del Anexo B.

En el Gráfico 39 de anexos, se puede apreciar la evolución semanal del indicador Productos Distintos para los grupos experimentales y de control.

4) Resultados para el perfil Limpieza

La hipótesis referida al indicador Venta PS para este perfil es:

- *“El modelo de recomendación SVD aumenta el indicador Venta PS con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil LIMPIEZA.”*

Para este indicador se tiene que en promedio el grupo de control es mayor al grupo experimental, pero a diferencia de los demás perfiles, la diferencia es mucho menor. Aunque de todos modos se rechaza la hipótesis nula de que tiene el mismo rendimiento con un 95% de confianza. Esto se puede comprobar en las Tabla 60 Tabla 61 del Anexo B.

En el Gráfico 40 de los anexos, se puede apreciar la evolución semanal del indicador Venta PS para los grupos experimental y de control.

La hipótesis para el siguiente indicador es:

- *“El modelo de recomendación SVD aumenta el indicador Efectividad con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil LIMPIEZA.”*

En el caso del modelo m1 en donde el modelo no recibe ayuda ninguna, se tiene que el promedio del indicador en el grupo de control es mayor al del grupo experimental, en la Tabla 62 del anexo B se tiene que la hipótesis nula de este experimento no se puede rechazar, es decir que estadísticamente tienen el mismo rendimiento.

Para el caso del modelo m2 en donde recibe ayuda de no recomendar productos que han sido rechazados es distinto, puesto que según la Tabla 63 del Anexo B, se rechaza la hipótesis nula de que ambos tienen el mismo rendimiento en favor del grupo de control con un 95% de confianza.

En el Gráfico 41 de anexos se puede apreciar la evolución semanal del indicador Efectividad de cada grupo experimental y grupo de control

La hipótesis para el indicador de Productos Distintos es:

- *“El modelo de recomendación SVD aumenta el indicador Efectividad con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil LIMPIEZA.”*

Este caso es muy interesante, puesto que en el modelo no ayudado como ayudado, el grupo experimental tiene mayor promedio. Según el test t de la Tabla 64 de anexos, se rechaza la hipótesis nula de que tienen el mismo rendimiento para el modelo no ayudado en favor del grupo experimental con un 95% de confianza y no se rechaza la hipótesis nula de la Tabla 65 de anexos de que ambas muestra son iguales para el modelo en que se eliminan los casos vistos y no comprados. En general el modelo SVD tiene un buen rendimiento en este perfil.

En el Gráfico 42 del anexo B, se puede apreciar la evolución semanal del indicador Productos Distintos para los grupos experimental y de control.

5) Resultados para el perfil Panaderías

La hipótesis referida al indicador Venta PS es:

- *“El modelo de recomendación SVD aumenta el indicador Venta PS con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil PANADERÍAS.”*

Para esta hipótesis, el indicador en promedio para el grupo experimental es bastante menor que para el grupo de control. En las Tabla 72 Tabla 73 del Anexo B se puede apreciar que se rechaza la hipótesis nula con un 95% de confianza de que ambos grupos tienen el mismo rendimiento.

En el Gráfico 43 de anexos se puede apreciar la evolución de los grupos experimental y de control para el indicador Venta PS.

La hipótesis que trata el indicador Efectividad para este perfil es el siguiente:

- *“El modelo de recomendación SVD aumenta el indicador Efectividad con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil PANADERÍAS.”*

Para el indicador efectividad también se tiene que en promedio el indicador es mayor para el grupo de control. Esta diferencia es significativa debido que se rechaza la hipótesis nula como se puede apreciar en las Tabla 74 y Tabla 75 del Anexo B.

En el Gráfico 44 se puede apreciar la evolución del indicador Efectividad para sus distintos grupos experimental y de control.

La hipótesis que explica el ultimo indicador para el perfil es:

- *“El modelo de recomendación SVD aumenta el indicador Productos Distintos con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil PANADERÍAS.”*

Para este caso se tiene que para el modelo que no tiene ninguna ayuda, el promedio del indicador para el grupo de control es mayor significativamente según la Tabla 76 del Anexo B. En el caso del modelo que tiene la etapa de post procesado se tiene que el indicador Productos Distintos es mayor que el grupo experimental, pero el test de la Tabla 77 de anexos indica que no se puede rechazar la hipótesis nula de que ambos tienen el mismo rendimiento con 95% de confianza.

En el Gráfico 45 se puede observar la evolución del indicador Productos distintos para los grupos experimentales y de control.

6) Resultados para el perfil Panaderías Bodega

Para el caso de la primera hipótesis se tiene:

- *“El modelo de recomendación SVD aumenta el indicador Venta PS con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil PANADERÍAS BODEGA.”*

Para este indicador se tiene que el grupo de control es mayor en promedio que el grupo experimental y además según las Tabla 84 y Tabla 85 del Anexos B, se tiene que la

diferencia de rendimientos es significativa con un 95% de confianza, Entonces se rechaza la hipótesis nula de que los indicadores son iguales para ambos grupos.

La evolución del indicador para sus distintos grupos experimentales y de control, se puede encontrar en el Gráfico 46 de anexos.

La hipótesis referida al indicador Efectividad, es como sigue:

- *“El modelo de recomendación SVD aumenta el indicador Efectividad con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil PANADERÍAS BODEGA.”*

Al igual que en el caso anterior, se tiene que el grupo de control tiene en promedio un mayor valor que el grupo experimental. Además, como se puede apreciar en las Tabla 86 y Tabla 87 de anexos, esta diferencia es significativa con un 95% de confianza.

En el Gráfico 47 de anexos se puede encontrar la evolución de los grupos experimentales y de control para el indicador efectividad.

Finalmente, la hipótesis relacionada al indicador de Productos Distintos es:

- *“El modelo de recomendación SVD aumenta el indicador Productos Distintos con respecto al modelo de asociaciones utilizado actualmente por la compañía en el perfil PANADERÍAS BODEGA.”*

En este caso se tiene que para el modelo que no presenta ayuda, el promedio del valor del grupo de control es mayor que el valor promedio del valor del grupo experimental, pero estadísticamente no se puede rechazar la hipótesis nula como se puede apreciar en la Tabla 88 del Anexo B.

Para el caso del modelo m2 que presenta post procesado, se tiene que el promedio del valor del grupo experimental es mayor que el promedio del valor del grupo de control. Pero de igual manera que el caso anterior, no existe diferencia significativa como se puede apreciar en la Tabla 89 del Anexo B.

En el Gráfico 48 se aprecia la evolución de los grupos experimentales y de control para el indicador Productos Distintos.

7) Resumen Resultados

A continuación, en la Tabla 13, se adjunta un cuadro resumen con los resultados de los experimentos de las hipótesis referidas al rendimiento del modelo propuesto versus el utilizado por la empresa.

Se puede apreciar que el modelo utilizado por la empresa en general tiene mejor rendimiento en la mayoría de indicadores y perfiles. El único perfil que se comportó distinto, fue limpieza que si bien, tuvo menor cantidad de venta en dinero, logró vender mayor cantidad de productos distintos.

Modelo perfil	Venta PS	Efectividad	Productos Distintos
Abarroteros m1	Control	Control	Control
Abarroteros m2	Control	Control	Control
Food Service m1	Control	Control	Control
Food Service m2	Control	Control	Control
Golosineros m1	Control	Control	Control
Golosineros m2	Control	Control	Control
Limpieza m1	Control	Sin diferencia	Experimental
Limpieza m2	Control	Control	Sin diferencia
Panaderías m1	Control	Control	Control
Panaderías m2	Control	Control	Sin diferencia
Panaderías Bodega m1	Control	Control	Sin diferencia
Panaderías Bodega m2	Control	Control	Sin diferencia

Tabla 13: Resumen resultados modelo SVD vs Modelo utilizado por la empresa.
Fuente: Elaboración propia.

9.5.6 Resultados de las hipótesis referidas al rendimiento del modelo propuesto por perfil versus el mismo modelo ajustado de manera global.

1) Resultados para el perfil abarroteros

La primera de las 3 hipótesis que se ven para los abarroteros en este ámbito es:

- “El indicador Venta PS es mejor para los modelos de recomendación SVD en el perfil ABARROTEROS, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.”

Según las Tabla 30 y Tabla 31 del anexo B se puede apreciar que pese a que el indicador Venta PS en promedio es mayor en las 4 semanas del experimento, esto no es suficiente para que las diferencias sean significativamente mayores, tanto para el modelo ayudado como para el que no.

Entonces para esta hipótesis no se rechaza la hipótesis nula de que tanto el modelo SVD calibrado específicamente al perfil abarroteros como el modelo SVD calibrado a la data global, tienen el mismo rendimiento.

- *“El indicador Efectividad es mejor para los modelos de recomendación SVD en el perfil ABARROTEROS, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.”*

En las Tabla 32 y Tabla 33 del anexo B se apreciar que no existe diferencia significativa entre las recomendaciones de un modelo calibrado de manera específica al perfil o de manera global. Por lo que no se rechaza la hipótesis nula de que ambos tienen el mismo rendimiento para el indicador Efectividad.

- *“El indicador Productos Distintos es mejor para los modelos de recomendación SVD en el perfil ABARROTEROS, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.”*

Para el indicador Productos distintos tampoco se tienen diferencias significativas según las Tabla 34 y Tabla 35 del anexo B. Entonces no se rechaza la hipótesis nula.

2) Resultados para el perfil Food Service

La hipótesis para el primer indicador es como sigue:

- *“El indicador Venta PS es mejor para los modelos de recomendación SVD en el perfil FOOD SERVICE, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.”*

En la Tabla 42 del anexo B, se puede apreciar que con confianza del 90% es significativamente mayor el modelo de recomendación SVD calibrado al perfil. Rechazando la hipótesis nula que dice que no hay diferencia.

En la Tabla 43 se encuentra el test t para el modelo en que recibe la ayuda de eliminar los productos visualizados y no comprados, también se rechaza la hipótesis nula con confianza del 95%.

La hipótesis en el indicador efectividad es:

- *“El indicador Efectividad es mejor para los modelos de recomendación SVD en el perfil FOOD SERVICE, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.”*

Según Tabla 44 del anexo B, donde se realizó el test t para el modelo sin ninguna mejora, no se puede rechazar la hipótesis nula de que ambos rendimientos son iguales. Sin embargo, cuando se eliminan los visualizados y no comprados en m2, se puede rechazar la hipótesis nula a favor de que un modelo calibrado específicamente al perfil food service, realiza mejores recomendaciones que uno calibrado de manera global a la data. Esto se puede apreciar en la Tabla 45 del anexo B.

Por último, la hipótesis para el indicador Productos Distintos es:

- *“El indicador Productos Distintos es mejor para los modelos de recomendación SVD en el perfil FOOD SERVICE, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.”*

En la Tabla 46, para el modelo m1, no se puede rechazar la hipótesis nula, teniendo ambos el mismo rendimiento.

Sin embargo, en la Tabla 47 del Anexo B se tiene que se puede rechazar la hipótesis nula de que ambos tienen el mismo rendimiento con una confianza del 90% en el modelo que presenta post procesado.

3) Resultados para el perfil Golosineros

La hipótesis relacionada al indicador Venta PS de este indicador es:

- *“El indicador Venta PS es mejor para los modelos de recomendación SVD en el perfil GOLOSINEROS, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.”*

En la Tabla 54 y Tabla 55 de los anexos, se puede apreciar que tanto para los modelos 1 y 2, no existe diferencia estadística entre el grupo de control en el indicador de venta PS. Es decir que no se puede rechazar la hipótesis nula de que el modelo calibrado al perfil específico Golosineros vende más.

La hipótesis referente al indicador Efectividad es:

- *“El indicador Efectividad es mejor para los modelos de recomendación SVD en el perfil GOLOSINEROS, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.”*

En las Tabla 56 y Tabla 57 de los anexo, se puede observar que se puede rechazar la hipótesis nula con un 95% de confianza para los modelos que reciben y no reciben post-procesado. Es decir que para el modelo calibrado específicamente al perfil tiene más efectividad que uno calibrado de manera global.

La última hipótesis del perfil Golosineros es:

- *“El indicador Productos Distintos es mejor para los modelos de recomendación SVD en el perfil GOLOSINEROS, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.”*

En las Tabla 58 y Tabla 59 de los anexos, al igual que para la tasa de efectividad, se tiene que se puede rechazar la hipótesis nula de que el indicador de productos distintos, el modelo SVD calibrado específicamente al perfil vende más productos distintos que uno calibrado de manera global.

4) Resultados para el perfil Limpieza

La hipótesis relacionada al indicador Venta PS de este indicador es:

- *“El indicador Venta PS es mejor para los modelos de recomendación SVD en el perfil LIMPIEZA, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.”*

Para el presente indicador se tiene que tanto para el modelo que se eliminan los vistos y no comprados, como en el que no se eliminan estas recomendaciones, se tiene que se rechaza la hipótesis nula con 95% de confianza. El detalle se puede encontrar en las Tabla

66 y Tabla 67 de anexos. Es decir, que el modelo SVD calibrado específicamente al perfil limpieza vende más que calibrado de manera global.

La hipótesis referente al indicador Efectividad es:

- *“El indicador Efectividad es mejor para los modelos de recomendación SVD en el perfil LIMPIEZA, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.”*

Para el indicador Efectividad se puede observar en las Tabla 68 y Tabla 69 que se puede rechazar la hipótesis nula en favor de la alternativa en que el indicador es mayor para el perfil calibrado de manera específica que cuando se utiliza el modelo SVD calibrado de manera global. Esto se cumple tanto para el modelo ayudado, como el que no.

La hipótesis relacionada al indicador Productos Distintos es:

- *“El indicador Productos Distintos es mejor para los modelos de recomendación SVD en el perfil LIMPIEZA, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.”*

Del mismo modo que para los indicadores Venta PS y Efectividad, se tiene que para Productos Distintos se rechaza la hipótesis nula con 95% de confianza de que no existe diferencia en el indicador si se utiliza el modelo SVD calibrado específicamente al perfil o no. Esto se puede apreciar en las Tabla 70 y Tabla 71 de los anexos.

5) Resultados para el perfil Panaderías

La hipótesis relacionada al indicador Venta PS de este indicador es:

- *“El indicador Venta PS es mejor para los modelos de recomendación SVD en el perfil PANADERIAS, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.”*

En las Tabla 78 y Tabla 79 de los anexos se puede apreciar que no existe diferencia significativa en el rendimiento en el indicador de Venta PS si se utiliza el modelo SVD calibrado específicamente al perfil Panaderías.

La hipótesis referente al indicador Efectividad es:

- *“El indicador Efectividad es mejor para los modelos de recomendación SVD en el perfil PANADERIAS, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.”*

De igual modo, se puede observar en las Tabla 80 y Tabla 81 de los anexos que no existe diferencia significativa entre utilizar el modelo SVD ajustado específicamente al perfil que utilizarlo calibrado de manera global.

La última hipótesis del perfil Panaderías es:

- *“El indicador Productos Distintos es mejor para los modelos de recomendación SVD en el perfil PANADERIAS, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.”*

En esta hipótesis se puede apreciar en la Tabla 82 de anexos que para el modelo que no recibe ayuda de eliminación de productos vistos y no comprados no existe diferencia significativa entre un modelo calibrado de manera específica al perfil y otro modelo que no.

Para el caso en que se eliminan los productos vistos por los clientes y no comprados, se observa en la Tabla 83 que se rechaza la hipótesis nula con un 95% de confianza. Es decir, para este último caso, el modelo calibrado de manera específica al perfil panaderías, vende mayor cantidad de producto distintos.

6) Resultados para el perfil Panaderías Bodega

La hipótesis relacionada al indicador Venta PS de este indicador es:

- *“El indicador Venta PS es mejor para los modelos de recomendación SVD en el perfil PANADERIAS BODEGA, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.”*

Al igual que en el perfil Panaderías, se puede apreciar que no existe diferencia significativa en el rendimiento en el indicador de Venta PS si se utiliza el modelo SVD calibrado específicamente al perfil Panaderías Bodega. Esto se puede observar en las Tabla 90 y Tabla 91 de los anexos.

La hipótesis referente al indicador Efectividad es:

- *“El indicador Efectividad es mejor para los modelos de recomendación SVD en el perfil PANADERIAS BODEGA, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.”*

De igual modo, se puede observar en las Tabla 92 y Tabla 93 de anexos que no existe diferencia significativa en utilizar el modelo SVD ajustado específicamente al perfil.

Finalmente, la última hipótesis del perfil Panaderías Bodega es:

- *“El indicador Productos Distintos es mejor para los modelos de recomendación SVD en el perfil PANADERIAS BODEGA, que si se utiliza un modelo SVD ajustado a la data global que haga recomendaciones para todos los perfiles.”*

Siguiendo la misma tendencia que el Perfil Panaderías, se tiene que en el perfil Panaderías Bodega no se puede rechazar la hipótesis nula de que son iguales los indicadores para los modelos calibrados de manera específica y global. Esto se puede observar en la Tabla 94.

Para el caso en que se eliminan los productos vistos y no comprados, se puede observar en la Tabla 95 que si se puede rechazar la hipótesis nula de que no existe diferencia con un 95% de confianza.

7) Resumen de resultados de las hipótesis referidas al rendimiento del modelo propuesto por perfil versus el mismo modelo ajustado de manera global.

En la Tabla 14 se puede apreciar que en ningún caso, un perfil calibrado de manera global tiene mejor rendimiento que uno calibrado de manera específica al perfil.

Los tres perfiles más grandes en la tabla son abarroteros con un 48% de participación, luego panaderías con un 14% de participación y en tercer lugar, el perfil panaderías bodega, con un 11% de participación. En estos tres perfiles se observa que no existe diferencia si el modelo no es ayudado eliminando los vistos y no eliminados.

Modelo perfil	Venta PS	Efectividad	Productos Distintos
Abarroteros m1	Sin diferencia	Sin diferencia	Sin diferencia
Abarroteros m2	Sin diferencia	Sin diferencia	Sin diferencia
Food Service m1	Perfil	Sin diferencia	Sin diferencia
Food Service m2	Perfil	Perfil	Perfil
Golosineros m1	Sin diferencia	Perfil	Perfil
Golosineros m2	Sin diferencia	Perfil	Perfil
Limpieza m1	Perfil	Perfil	Perfil
Limpieza m2	Perfil	Perfil	Perfil
Panaderías m1	Sin diferencia	Sin diferencia	Sin diferencia
Panaderías m2	Sin diferencia	Sin diferencia	Perfil
Panaderías Bodega m1	Sin diferencia	Sin diferencia	Sin diferencia
Panaderías Bodega m2	Sin diferencia	Sin diferencia	Perfil

*Tabla 14: Resumen de calibración global vs específica.
Fuente: Elaboración propia.*

10. CONCLUSIONES

En general se puede observar en los resultados que un modelo calibrado de manera ajustada a cada perfil funciona de manera más adecuada que un modelo calibrado de manera global. Esto puede deberse al tamaño de los datos procesados, dado que independiente del perfil en el cual se aplicaron las recomendaciones ajustadas de manera global, siempre tuvieron malos resultados.

En el caso contrario, si se observa en qué casos el modelo funcionó de mejor manera según el indicador de productos vendidos distintos, se encuentra que lo hace en el perfil limpieza, la característica que tiene este perfil es que además de tener menor cantidad de clientes, tiene menor cantidad de participación en boletas. Estas son las dos principales variables que determinan el tamaño del archivo a procesar.

En este pequeño perfil, se tiene que el modelo SVD calibrado específicamente al perfil Limpieza vendió en promedio 6 veces más productos distintos que el grupo de control. Si bien, este número se ve muy grande, es porque el n de productos distintos vendidos tanto para el grupo de control como experimental es muy bajo. La mayor venta la logró sin eliminar los productos vistos y no comprados, lo cual puede indicar que re-sugerir productos no necesariamente es algo que no aporta.

Si bien, el perfil Limpieza vendió mayor cantidad de productos distintos y con la misma efectividad, lo hizo con un monto de venta más bajo, lo cual es porque los productos recomendados, eran de menor valor que los productos recomendados por el utilizado por la empresa. Interesante sería evaluar un modelo más reducido en productos que solo recomiende productos de alto valor y no repetidos.

Uno de los problemas a la hora de recomendar productos, fueron los productos iguales, pero en distinto formato, por ejemplo, en la base de datos se pueden encontrar un código de productos que representa a un producto unitario, otro código que representa a un pack doble y otro que representa una caja de 30. Esto sin contar los productos iguales que tienen una presentación distinta como por ejemplo harina de 1, 5 o 10 kgs.

Esto es un problema puesto que si un cliente compra un producto en su formato de caja de 10 unidades y luego se le ofrece el mismo producto pero unitario, es probable que sea desestimada la recomendación. Esto último hace que existan perfiles de clientes más heterogéneos que compran formatos de productos dependiendo del tamaño de su tienda.

Respecto a lo último, se tiene que a mayor N de clientes, existe mayor heterogeneidad entre ellos también, se observa en los resultados que mientras más global es la calibración del modelo, más impreciso es, por lo que puede ser necesario considerar agrupar los productos iguales pero en distinto formato.

El modelo SVD es comúnmente utilizado para recomendar películas de cine, Simon Funk lo estrenó en la competencia de Netflix en que se competía cual era el mejor modelo de recomendaciones de películas. Es por esto que probablemente fue un error asumir los parámetros de aprendizaje y regularización que se encuentran sugeridos. Además, en archivos más grandes, probablemente faltaron iteraciones de la optimización.

Sarwar en su caso de estudio [13] prueba el modelo SVD para recomendar películas y para recomendar productos en el e-commerce. Los resultados de sus predicciones son consistentemente más erróneos en el e-commerce que en el cine. Esto lo explica diciendo que la matriz de valoraciones para recomendar en el cine es mucho más densa que la matriz que intenta recomendar para el comercio electrónico.

Sarwar finaliza su estudio diciendo “Se requiere trabajo futuro para entender exactamente por qué SVD funciona bien para algunas aplicaciones de recomendación y menos bien para otras”.

En la presente memoria se pensaba que la solución de Funk [16] a la falta de densidad de la matriz sería suficiente, pero no fue así en muchos casos.

11. RECOMENDACIONES

Se recomienda a la empresa experimentar el modelo SVD para los perfiles limpieza y golosineros, pero no de manera absoluta, si no que realizando una recomendación de 10 productos cada dos meses y que se vayan implantando uno por uno cada semana en la estrategia perfil. Es decir que la estrategia perfil recomiende dos productos, de los cuales uno provenga de la estrategia misma, y la segunda del modelo SVD.

Esto le daría a la estrategia perfil variación semana a semana a la estrategia, esto último puesto que varían muy lentamente las sugerencias que se realizan a los clientes. La inclusión de estos productos le daría dinamismo a sus recomendaciones que podría terminar en vender productos que no se habían vendido antes con un costo y riesgo bajo, dado que solo sería una recomendación dentro de la estrategia, y además solo se procesaría cada dos meses.

Se recomienda además realizar un análisis de productos similares, es decir crear una manera de identificar por un código más general a productos que son iguales entre sí, pero en distinto formato. A partir de este análisis se puede evaluar el comportamiento de un cliente frente a la recomendación de un mismo producto en otro formato, o analizar de manera más limpia el comportamiento de los clientes frente a recomendaciones de productos de gamas más alta.

Si se quiere explotar el área de venta de productos distintos, se recomienda además acompañar la recomendación con aspectos que apoyen la venta del cliente. Es decir, complementar la venta del producto no comprado antes por el cliente con un cartel o sticker que le indique a su público que tiene el producto nuevo. Con esto se apoyaría a la venta del mismo producto, facilitando la recompra en el futuro.

Finalmente se recomienda revisar el perfil de cliente Abarroteros, puesto que si bien, describe de buena manera un gran grupo de clientes, parece ser muy heterogéneo. Clasificarlos en segmentos A B C debería ser suficiente para obtener grupos más homogéneos.

12. TRABAJO FUTURO

Existen diversos trabajos futuros que pueden complementar el desarrollo de esta memoria y que además pueden brindar conocimiento a la universidad:

- Realizar un estudio de los parámetros ideales con los que el modelo SVD podría funcionar bien en un set de datos transaccional.
- Evaluar el modelo SVD utilizando solo los productos que marginan mayor utilidad, esto simplificaría el modelo y obligaría a realizar un análisis previo de selección de productos de alto valor. La selección de estos productos permitiría eliminar la repetición de productos en distintos formatos. Además para el correcto aprendizaje del modelo, sería necesario agrupar los productos repetidos para evitar que se recomiende un producto que compra ya en otro formato.
- Analizar el comportamiento de los clientes de alto valor versus los clientes de bajo valor, entendiéndose como clientes de alto valor quienes utilizan mucho el PS y con alto margen y los de bajo valor los que no utilizan el PS o lo hacen con bajo margen. Entender esto podría brindar insights de activación de PS en clientes que no suele utilizarse, como también mostrar insights de obtención de margen en clientes importantes.
- Evaluar el impacto de complementar la sugerencia de pedido con campañas locales de activación de venta de nuevos productos en pequeñas bodegas y puestos de mercado.
- Se puede desarrollar otro modelo de machine learning en el cual se compare su rendimiento con el modelo SVD o kNN que pueda entregar aprendizaje sobre el comportamiento de los modelos en un set de datos transaccional
- Se puede desarrollar el mismo modelo, en otro tipo datos, como en una aplicación web, etc.

13. BIBLIOGRAFÍA

- [1] Peru Retail, “¿Cómo se está desarrollando el sector de supermercados en el Perú? [En Línea. Disponible: <http://www.peru-retail.com/como-esta-desarrollando-sector-supermercados-peru/> [Fecha de consulta: 10 de junio]
- [2] Peru Retail, “Ventas del sector de supermercados crecería 7% este 2018 en Perú” [En Línea. Disponible: <https://www.peru-retail.com/ventas-sector-supermercados-creceria-2018-peru/> [Fecha de consulta: 10 de junio]
- [3] Asociación peruana de empresas de consumo masivo (APECOM), [En línea]. Disponible: <http://apecomperu.com/cencosud-pondra-enfasis-para-su-crecimiento-en-peru/> [Fecha de consulta: 10 de junio]
- [4] Días, I. (2017) “Evaluación y mejora de un motor de recomendaciones aplicado a un proveedor de consumo masivo en canal tradicional”, Memoria, Universidad de Chile.
- [5] Kurucz, M. Benczúr, A. Csalogány, K. (2007). “Methods for large scale SVD with missing values”, Proc. 13th ACM SIGKDD Conf. KDD Cup and Workshop, pp. 31–38.
- [6] Levandoski, J. Eldawy, A. Ekstrand, M. Mokbel, M. Ludwig, Riedl, M (2013), “RecBench: Benchmarks for Evaluating Performance of Recommender System Architectures,” University of Minnesota, pp. 911–920.
- [7] Ekstrand, M. (2010), “Collaborative Filtering Recommender Systems” Found.Trends® Human–Computer Interact., vol. 4, no. 2, pp. 81–173.
- [8] Burke, R. “Integrating Knowledge-based and Collaborative-filtering Recommender Systems,” University of California, pp. 69–72, 1999.
- [9] Molina, M. “Sistema de recomendación híbrido para la predicción de calificaciones en Yelp.com”, Universidad Politécnica de Madrid, Departamento de Lenguajes y Sistemas Informáticos e Ingeniería de Software, pp 10-21, 2016.
- [10] Gershman A., Meisels A., Luke K., Rokach L., Schclar A. and Sturm A. (2010). “A Decision Tree Based Recommender System”, University of the Negev - Department of Information Systems Engineering.

[11] Resnick P., Iacovou N., Suchak M., Bergstrom P. and Riedl J. (1994) “GroupLens: An Open Architecture for Collaborative Filtering of Netnews”. In Proceedings of CSCW '94, Chapel Hill, NC.

[12] Torres N. (2015), “Sistemas de recomendación basados en métodos de filtrado colaborativo”, Memoria, Universidad Técnica Federico Santa María- Departamento de informática.

[13] Sarwar B., Karypis G., Konstan J., Riedl J. “Application of Dimensionality Reduction in Recommender System-A Case Study”, University of Minnesota - Department of Computer Science and Engineering.

[14] Cline A., Dhillon A. “Computation of the Singular Value Decomposition”, University of Texas.

[15] Ramírez, C. A. (2018). “Algoritmo SVD aplicado a los sistemas de recomendación en el comercio”, TIA, 6(1), pp. 18-27.

[16] Funk S. (2006). “Netflix Update: Try This At Home”.

[17] Shani G. and Gunawardana A. (2011), “Evaluating recommendation systems,” *Recomm. Syst. Handb.*, pp. 257–298.

[18] Azevedo A. and Santos M. (2008), “KDD, semma and CRISP-DM: A parallel overview”, Conference on Data Mining, Amsterdam, The Netherland.

[19] F. Maxwell Harper and Joseph A. Konstan. 2015. “The MovieLens Datasets: History and Context”, *ACM Transactions on Interactive Intelligent Systems*.

[20] Florás D. (2015), “Modelo de Recomendación de productos aplicado a una empresa de cupones online”, Memoria, Universidad de Chile - Facultad de Ciencias Físicas y Matemáticas.

[21] Roco C. (2010), “Modelo predictivo para el aumento de consumo de tarjeta de crédito sobre el análisis de comportamiento transaccional de cliente de una institución financiera”, Memoria, Universidad de Chile - Facultad de Ciencias Físicas y Matemáticas.

[22] Figueroa T. (2009) “Modelo predictivo de quiebres de stock en un supermercado”, Memoria, Universidad de Chile - Facultad de Ciencias Físicas y Matemáticas.

[23] Breese J. S., Heckerman D. and Kadie C., (1998) “Emperical analysis of predictive algorithms for collaborative filtering”. In Fourteenth Conference on Uncertainty in Artificial Intelligence.

[24] Castro J. (2012) “Un nuevo modelo ponderado para Sistemas de Recomendación Basados en Contenido con medidas de contingencia y entropía”, Memoria, Universidad de Jaén, Departamento de Informática.

14. ANEXOS

Anexo A: Corrección de outliers en los perfiles




Gráfico 16: Corrección de outliers del perfil abarroteros.
Fuente: Elaboración propia.




Gráfico 17: Corrección de outliers del perfil aderezos.
Fuente: Elaboración propia.




Gráfico 18: Corrección de outliers para el perfil food service.
Fuente: Elaboración propia.




Gráfico 19: Corrección de outliers para el perfil golosinero.
Fuente: Elaboración propia.




Gráfico 20: Corrección de outliers para el perfil limpieza.
Fuente: Elaboración propia.




Gráfico 21: Corrección de outliers para el perfil panaderías bodega.
Fuente: Elaboración propia.




Gráfico 22: Corrección de outliers para el perfil panaderías.
Fuente: Elaboración propia




Gráfico 23: Corrección de outliers para el perfil varios.
 Fuente: Elaboración propia.




Gráfico 24: Corrección de outliers para el perfil sin etiqueta.
 Fuente: Elaboración propia.

Anexo B: Gráficos de las hipótesis evaluadas

I. Comportamiento de las bodegas versus los puestos de mercado

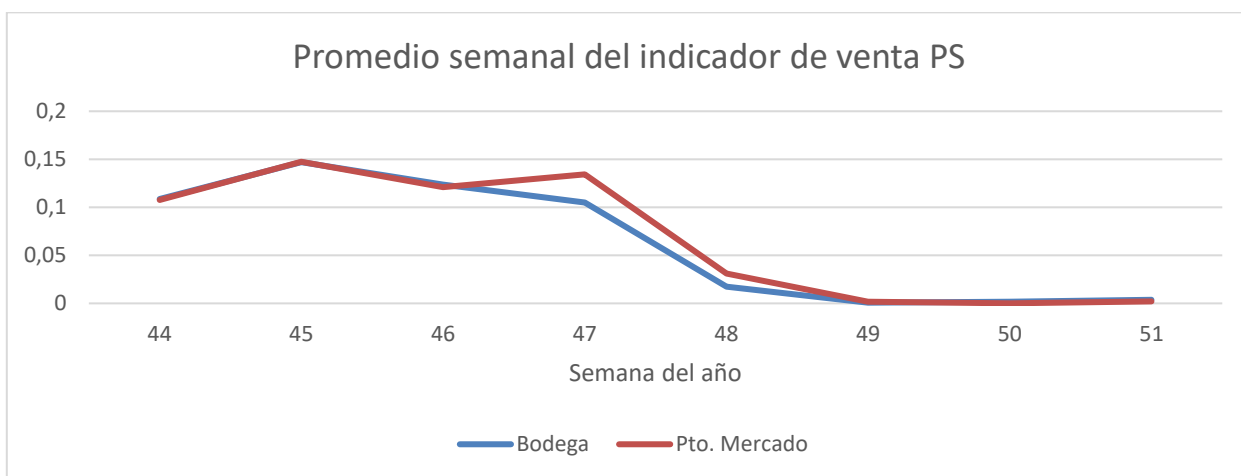


Gráfico 25: Promedio semanal del indicador de venta PS para una muestra de bodegas y puestos de mercado.
Fuente: Elaboración propia.

	Puestos de mercado	Bodegas
Media	0.00879681	0.00583666
Varianza	0.00101844	0.00067157
Grados de libertad	1392	
Estadístico t	1.90101447	
P(T<=t) dos colas	0.05750648	
Valor crítico de t (dos colas)	1.96166966	

Tabla 15: Test t para venta PS entre Bodegas y Puestos de Mercado.
Elaboración propia.




Gráfico 26: Promedio semanal de la tasa de efectividad para bodegas y puestos de mercado.
Fuente: Elaboración propia.

	Puestos de mercado	Bodegas
Media	0.02172621	0.01315158
Varianza	0.00521748	0.00349855
Varianza agrupada	0.00435986	
Diferencia hipotética de las medias	0.01	
Grados de libertad	1395	
Estadístico t	-0.4034191	
P(T<=t) dos colas	0.68670171	
Valor crítico de t (dos colas)	1.96166599	

Tabla 16: Test t para Efectividad entre Bodegas y Puestos de Mercado.
Elaboración propia.




Gráfico 27: Promedio semanal del indicador de productos distintos para bodegas y puestos de mercado.
Fuente: Elaboración propia.

	Variable 1	Variable 2
Media	0.00286944	0.00142857
Varianza	0.00071015	0.00035561
Varianza agrupada	0.0005325	
Grados de libertad	1395	
Estadístico t	1.16689923	
P(T<=t) dos colas	0.2434505	
Valor crítico de t (dos colas)	1.96166599	

Tabla 17: Test t para el indicador Productos Distintos entre Bodegas y Puestos de Mercado.
Fuente: Elaboración propia.

II. Comportamiento de la recomendación según posición de la estrategia.




Gráfico 28: Promedio semanal del indicador de venta PS cuando se utilizan distintas posiciones.
Fuente: Elaboración propia.




Gráfico 29: Promedio semanal de la tasa de efectividad cuando se utilizan distintas posiciones.
Fuente: Elaboración propia.




Gráfico 30: Promedio semanal del indicador de productos distintos cuando se utilizan distintas posiciones.
Fuente: Elaboración propia.

	Posición 2	Posición 1
Media	0.00037568	0.00054354
Varianza	6.142E-05	0.00010926
Varianza agrupada	8.5339E-05	
Grados de libertad	1398	
Estadístico t	-0.3399385	
P(T<=t) dos colas	0.7339539	
Valor crítico de t (dos colas)	1.96166233	

Tabla 18: Test t para Venta PS entre la posición 1 y la posición 2.
Fuente: Elaboración propia.

	Posición 2	Posición 1
Media	0.00035714	0.00071429
Varianza	8.9286E-05	0.00017832
Varianza agrupada	0.0001338	
Grados de libertad	1398	
Estadístico t	-0.5776258	
P(T<=t) dos colas	0.56360981	
Valor crítico de t (dos colas)	1.96166233	

Tabla 19: Test t para Efectividad entre la posición 1 y la posición 2.
Fuente: Elaboración propia.

	<i>Posición 2</i>	<i>Posición 1</i>
Media	0.00071429	0.00071429
Varianza	0.00017832	0.00017832
Varianza agrupada	0.00017832	
Grados de libertad	1398	
Estadístico t	0	
P(T<=t) dos colas	1	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 20: Test t para Productos distintos entre la posición 1 y la posición 2.
Fuente: Elaboración propia.*

	<i>Posición 2</i>	<i>Posición 3</i>
Media	0.00037568	1.6214E-05
Varianza	6.142E-05	1.8403E-07
Varianza agrupada	3.0802E-05	
Grados de libertad	1398	
Estadístico t	1.211717	
P(T<=t) dos colas	0.22582549	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 21: Test t para Venta PS entre la posición 2 y la posición 3.
Fuente: Elaboración propia.*

	<i>Variable 1</i>	<i>Variable 2</i>
Media	0.00035714	0.00035714
Varianza	8.9286E-05	8.9286E-05
Varianza agrupada	8.9286E-05	
Grados de libertad	1398	
P(T<=t) dos colas	1	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 22: Test t para Efectividad entre la posición 2 y la posición 3.
Fuente: Elaboración propia.*

	Variable 1	Variable 2
Media	0.00071429	0.00035714
Varianza	0.00017832	8.9286E-05
Varianza agrupada	0.0001338	
Grados de libertad	1398	
Estadístico t	0.57762579	
P(T<=t) dos colas	0.56360981	
Valor crítico de t (dos colas)	1.96166233	

Tabla 23: Test t para Productos distintos entre la posición 2 y la posición 3.
Fuente: Elaboración propia.

III. Gráficos y tablas del comportamiento del modelo en el perfil Abarroteros.




Gráfico 31: Promedio semanal del indicador de venta PS para los grupos del perfil abarroteros.
Fuente: Elaboración propia.




Gráfico 32: Promedio semanal de la tasa de efectividad de los grupos del perfil abarrotero.
Fuente: Elaboración propia.




Gráfico 33 Promedio semanal de la cantidad de productos vendidos distintos de los grupos del perfil abarrotero.
Fuente: Elaboración propia.

	<i>Grupo de control</i>	<i>Grupo m1g1</i>
Media	0.04252378	0.00048668
Varianza	0.00519067	9.5089E-05
Varianza agrupada	0.0026374	
Grados de libertad	1395	
Estadístico t	15.2972037	
P(T<=t) dos colas	5.9404E-49	
Valor crítico de t (dos colas)	1.96166599	

*Tabla 24: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Abarroteros
Fuente: Elaboración propia.*

	<i>Grupo de control</i>	<i>Grupo m2g1</i>
Media	0.04252378	0.00848163
Varianza	0.00519067	0.00100149
Varianza agrupada	0.00310666	
Grados de libertad	1385	
Estadístico t	11.3729341	
P(T<=t) dos colas	1.0248E-28	
Valor crítico de t (dos colas)	1.96167829	

*Tabla 25: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Abarroteros y además eliminando productos vistos y no comprados.
Fuente: Elaboración propia.*

	<i>Grupo de control</i>	<i>Grupo m1g1</i>
Media	0.11367834	0.00107143
Varianza	0.03424596	0.00026709
Varianza agrupada	0.01721999	
Grados de libertad	1395	
Estadístico t	16.0367287	
P(T<=t) dos colas	3.0056E-53	
Valor crítico de t (dos colas)	1.96166599	

*Tabla 26: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Abarroteros
Fuente: Elaboración propia.*

	<i>Grupo de control</i>	<i>m2g1</i>
Media	0.11367834	0.0192029
Varianza	0.03424596	0.00471054
Varianza agrupada	0.01955289	
Grados de libertad	1385	
Estadístico t	12.5810284	
P(T<=t) dos colas	1.8989E-34	
Valor crítico de t (dos colas)	1.96167829	

Tabla 27: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Abarroteros y además eliminando productos vistos y no comprados.

Fuente: Elaboración propia.

	<i>Grupo de control</i>	<i>Grupo m1g1</i>
Media	0.01542324	0.00107143
Varianza	0.00398233	0.00026709
Varianza agrupada	0.00212071	
Grados de libertad	1395	
Estadístico t	5.82415479	
P(T<=t) dos colas	7.1156E-09	
Valor crítico de t (dos colas)	1.96166599	

Tabla 28: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Abarroteros

Fuente: Elaboración propia.

	<i>Grupo de control</i>	<i>Grupo m2g1</i>
Media	0.01542324	0.00398551
Varianza	0.00398233	0.00152618
Varianza agrupada	0.00276046	
Grados de libertad	1385	
Estadístico t	4.05370227	
P(T<=t) dos colas	5.3218E-05	
Valor crítico de t (dos colas)	1.96167829	

Tabla 29: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Abarroteros y además eliminando productos vistos y no comprados.

Fuente: Elaboración propia.

	Grupo m1g2	Grupo m1g1
Media	0.00023271	0.00048668
Varianza	2.0015E-05	9.5089E-05
Varianza agrupada	5.7552E-05	
Grados de libertad	1398	
Estadístico t	-0.6262906	
P(T<=t) dos colas	0.53122663	
Valor crítico de t (dos colas)	1.96166233	

Tabla 30: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica al perfil abarroteros en m1g1 y de manera global en m1g2.

Fuente: Elaboración propia.

	Grupo m2g2	Grupo m2g1
Media	0.00711879	0.00848163
Varianza	0.00082048	0.00100149
Varianza agrupada	0.00091033	
Grados de libertad	1388	
Estadístico t	-0.8420018	
P(T<=t) dos colas	0.39993201	
Valor crítico de t (dos colas)	1.96167458	

Tabla 31: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica al perfil abarroteros en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.

Fuente: Elaboración propia.

	Grupo m1g2	Grupo m1g1
Media	0.00035714	0.00107143
Varianza	8.9286E-05	0.00026709
Varianza agrupada	0.00017819	
Grados de libertad	1398	
Estadístico t	-1.0010747	
P(T<=t) dos colas	0.31696394	
Valor crítico de t (dos colas)	1.96166233	

Tabla 32: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica al perfil abarroteros en m1g1 y de manera global en m1g2.

Fuente: Elaboración propia.

	Grupo m2g2	Grupo m2g1
Media	0.01821429	0.0192029
Varianza	0.00438184	0.00471054
Varianza agrupada	0.004545	
Grados de libertad	1388	
Estadístico t	-0.2733539	
P(T<=t) dos colas	0.78462185	
Valor crítico de t (dos colas)	1.96167458	

Tabla 33: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica al perfil abarroteros en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.

Fuente: Elaboración propia.

	Grupo m1g2	Grupo m1g1
Media	0.00071429	0.00107143
Varianza	0.00017832	0.00026709
Varianza agrupada	0.0002227	
Grados de libertad	1398	
		-
Estadístico t	0.44772631	
P(T<=t) dos colas	0.6544201	
Valor crítico de t (dos colas)	1.96166233	

Tabla 34: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera específica al perfil abarroteros en m1g1 y de manera global en m1g2.

Fuente: Elaboración propia.

	Grupo m2g2	Variable 2
Media	0.00214286	0.00398551
Varianza	0.00053188	0.00152618
Varianza agrupada	0.00102545	
Grados de libertad	1388	
		-
Estadístico t	1.07263422	
P(T<=t) dos colas	0.28362172	
Valor crítico de t (dos colas)	1.96167458	

Tabla 35: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera específica al perfil abarroteros en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.

Fuente: Elaboración propia.

IV. Gráficos y tablas del comportamiento del modelo en el perfil Food Service.




Gráfico 34: Promedio semanal del indicador de venta PS en el perfil Food Service.
Fuente: Elaboración propia.




Gráfico 35: Promedio semanal de la tasa de efectividad en el perfil Food Service.
Fuente: Elaboración propia




Gráfico 36: Promedio semanal de la cantidad de productos PS vendidos distintos en el perfil Food Service.
Fuente: Elaboración propia.

	Grupo control	Grupo m1g1
Media	0.02013929	0.00214854
Varianza	0.00397508	0.00058031
Varianza agrupada	0.00227769	
Grados de libertad	1398	
Estadístico t	7.05238332	
P(T<=t) dos colas	2.7569E-12	
Valor crítico de t (dos colas)	1.96166233	

Tabla 36: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Food Service
Fuente: Elaboración propia.

	Grupo Control	Grupo m2g1
Media	0.02013929	0.00740507
Varianza	0.00397508	0.00142328
Varianza agrupada	0.00269918	
Grados de libertad	1398	
Estadístico t	4.5855397	
P(T<=t) dos colas	4.9329E-06	
Valor crítico de t (dos colas)	1.96166233	

Tabla 37: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Food Service y además eliminando productos vistos y no comprados.
Fuente: Elaboración propia.

	<i>Grupo de control</i>	<i>Grupo m1g1</i>
Media	0.04244046	0.00142857
Varianza	0.01950024	0.00035561
Varianza agrupada	0.00992792	
Grados de libertad	1398	
Estadístico t	7.70042319	
P(T<=t) dos colas	2.5518E-14	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 38: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Food Service
Fuente: Elaboración propia.*

	<i>Grupo de control</i>	<i>Grupo m2g1</i>
Media	0.04244046	0.00642857
Varianza	0.01950024	0.00889996
Varianza agrupada	0.0142001	
Grados de libertad	1398	
Estadístico t	5.65371976	
P(T<=t) dos colas	1.9008E-08	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 39: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Food Service y además eliminando productos vistos y no comprados.
Fuente: Elaboración propia.*

	<i>Grupo de control</i>	<i>Grupo m1g1</i>
Media	0.00535714	0.00178571
Varianza	0.00131246	0.0006227
Varianza agrupada	0.00096758	
Grados de libertad	1398	
Estadístico t	2.14799008	
P(T<=t) dos colas	0.03188596	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 40: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Food Service
Fuente: Elaboración propia.*

	<i>Grupo de control</i>	<i>Grupo m2g1</i>
Media	0.00535714	0.00178571
Varianza	0.00131246	0.00044387
Varianza agrupada	0.00087817	
Grados de libertad	1398	
Estadístico t	2.25469208	
P(T<=t) dos colas	0.02430688	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 41: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Food Service y además eliminando productos vistos y no comprados.
Fuente: Elaboración propia.*

	<i>Grupo m1g2</i>	<i>Grupo m1g1</i>
Media	0.00048139	0.00214854
Varianza	0.0001	0.00058031
Varianza agrupada	0.00034015	
Grados de libertad	1398	
Estadístico t	-1.6910984	
P(T<=t) una cola	0.04552046	
Valor crítico de t (una cola)	1.64594432	
P(T<=t) dos colas	0.09104091	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 42: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica a Food Service en m1g1 y de manera global en m1g2.
Fuente: Elaboración propia.*

	<i>Grupo m2g2</i>	<i>Grupo m2g1</i>
Media	0.00346407	0.00740507
Varianza	0.00069071	0.00142328
Varianza agrupada	0.00105699	
Grados de libertad	1398	
Estadístico t	-2.2677981	
P(T<=t) dos colas	0.02349357	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 43: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.
Fuente: Elaboración propia.*

	Grupo m1g2	Grupo m1g1
Media	0.00071429	0.00142857
Varianza	0.00017832	0.00035561
Varianza agrupada	0.00026696	
Grados de libertad	1398	
		-
Estadístico t	0.81786278	
P(T<=t) dos colas	0.41357492	
Valor crítico de t (dos colas)	1.96166233	

Tabla 44: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica a Food Service en m1g1 y de manera global en m1g2.
Fuente: Elaboración propia.

	Grupo m2g2	Grupo m2g1
Media	0.00285714	0.01
Varianza	0.00088596	0.00280579
Varianza agrupada	0.00184588	
Grados de libertad	1398	
Estadístico t	-3.1103168	
P(T<=t) dos colas	0.00190665	
Valor crítico de t (dos colas)	1.96166233	

Tabla 45: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica a Food Service en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.
Fuente: Elaboración propia.

	Grupo m1g2	Grupo m1g1
Media	0.00071429	0.00178571
Varianza	0.00017832	0.0006227
Varianza agrupada	0.00040051	
Grados de libertad	1398	
		-
Estadístico t	1.00159337	
P(T<=t) dos colas	0.31671335	
Valor crítico de t (dos colas)	1.96166233	

Tabla 46: Test t para Productos distintos utilizando el modelo SVD calibrado de manera específica a Food Service en m1g1 y de manera global en m1g2.
Fuente: Elaboración propia.

	<i>Grupo m2g2</i>	<i>Grupo m2g1</i>
Media	0.00035714	0.00178571
Varianza	8.9286E-05	0.00044387
Varianza agrupada	0.00026658	
Grados de libertad	1398	
Estadístico t	-1.6369008	
P(T<=t) una cola	0.05093813	
Valor crítico de t (una cola)	1.64594432	
P(T<=t) dos colas	0.10187627	
Valor crítico de t (dos colas)	1.96166233	

Tabla 47: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera específica a Food Service en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.

Fuente: Elaboración propia.

V. Gráficos y tablas del comportamiento del modelo en el perfil Golosineros.




Gráfico 37: Promedio semanal del indicador de venta PS del perfil Golosineros. Fuente: Elaboración propia.




Gráfico 38: Promedio semanal de la tasa de efectividad del perfil Golosineros. Fuente: Elaboración propia.




Gráfico 39: Promedio semanal de la cantidad de productos vendidos distintos del perfil Golosineros.
Fuente: Elaboración propia.

	Grupo control	Grupo m1g1
Media	0.02376989	0.00126982
Varianza	0.00406873	0.00014035
Varianza agrupada	0.00210454	
Grados de libertad	1398	
Estadístico t	9.17569687	
P(T<=t) dos colas	1.5629E-19	
Valor crítico de t (dos colas)	1.96166233	

Tabla 48: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Golosineros.
Fuente: Elaboración propia.

	Grupo control	Grupo m2g1
Media	0.02376989	0.00622514
Varianza	0.00406873	0.00107248
Varianza agrupada	0.0025706	
Grados de libertad	1398	
Estadístico t	6.47386382	
P(T<=t) dos colas	1.319E-10	
Valor crítico de t (dos colas)	1.96166233	

Tabla 49: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Golosineros y además eliminando productos vistos y no comprados.
Fuente: Elaboración propia.

	<i>Grupo control</i>	<i>Grupo m1g1</i>
Media	0.06002975	0.00428571
Varianza	0.01828081	0.00123339
Varianza agrupada	0.0097571	
Grados de libertad	1398	
Estadístico t	10.5577662	
P(T<=t) dos colas	4.0092E-25	
Valor crítico de t (dos colas)	1.96166233	

Tabla 50: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Golosineros
Fuente: Elaboración propia.

	<i>Grupo control</i>	<i>Grupo m2g1</i>
Media	0.06002975	0.01857143
Varianza	0.01828081	0.00533733
Varianza agrupada	0.01180907	
Grados de libertad	1398	
Estadístico t	7.13736493	
P(T<=t) dos colas	1.5235E-12	
Valor crítico de t (dos colas)	1.96166233	

Tabla 51: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Golosineros y además eliminando productos vistos y no comprados.
Fuente: Elaboración propia.

	<i>Grupo control</i>	<i>Grupo m1g1</i>
Media	0.01142857	0.00428571
Varianza	0.00308809	0.00123339
Varianza agrupada	0.00216074	
Grados de libertad	1398	
Estadístico t	2.87478088	
P(T<=t) dos colas	0.00410429	
Valor crítico de t (dos colas)	1.96166233	

Tabla 52: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Golosineros
Fuente: Elaboración propia.

	Grupo control	Grupo m2g1
Media	0.01142857	0.00964286
Varianza	0.00308809	0.0026787
Varianza agrupada	0.00288339	
Grados de libertad	1398	
Estadístico t	0.62214862	
P(T<=t) dos colas	0.5339456	
Valor crítico de t (dos colas)	1.96166233	

Tabla 53: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Golosineros y además eliminando productos vistos y no comprados.

Fuente: Elaboración propia.

	Grupo m1g2	Grupo m1g1
Media	3.5122E-05	0.00126982
Varianza	8.6224E-07	7.3655E-05
Varianza agrupada	3.7285E-05	
Grados de libertad	1397	
		-
Estadístico t	3.78160186	
P(T<=t) dos colas	0.0001624	
Valor crítico de t (dos colas)	1.96166355	

Tabla 54: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica a Golosineros en m1g1 y de manera global en m1g2.

Fuente: Elaboración propia.

	Grupo m2g2	Grupo m2g1
Media	0.00418689	0.00622514
Varianza	0.00059037	0.00107248
Varianza agrupada	0.00083142	
Grados de libertad	1398	
		-
Estadístico t	1.32245314	
P(T<=t) una cola	0.0931168	
Valor crítico de t (una cola)	1.64594432	
P(T<=t) dos colas	0.18623361	
Valor crítico de t (dos colas)	1.96166233	

Tabla 55: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica en m1g1 a Golosineros y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.

Fuente: Elaboración propia.

	Grupo m1g2	Grupo m1g1
Media	0.00035765	0.00428571
Varianza	8.9413E-05	0.00123339
Varianza agrupada	0.00066181	
Grados de libertad	1397	
		-
Estadístico t	2.85554567	
P(T<=t) dos colas	0.00435982	
Valor crítico de t (dos colas)	1.96166355	

Tabla 56: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica a Golosineros en m1g1 y de manera global en m1g2.
Fuente: Elaboración propia.

	Grupo m2g2	Grupo m2g1
Media	0.00732143	0.01875
Varianza	0.00175694	0.00292146
Varianza agrupada	0.0023392	
Grados de libertad	1398	
		-
Estadístico t	4.42071033	
P(T<=t) dos colas	1.0598E-05	
Valor crítico de t (dos colas)	1.96166233	

Tabla 57: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica a Golosineros en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.
Fuente: Elaboración propia.

	Grupo m1g2	Grupo m1g1
Media	0.00035765	0.00428571
Varianza	8.9413E-05	0.00123339
Varianza agrupada	0.00066181	
Grados de libertad	1397	
		-
Estadístico t	2.85554567	
P(T<=t) dos colas	0.00435982	
Valor crítico de t (dos colas)	1.96166355	

Tabla 58: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera específica a Golosineros en m1g1 y de manera global en m1g2. Fuente: Elaboración propia.

	<i>Grupo m2g2</i>	<i>Grupo m2g1</i>
Media	0.00035714	0.00964286
Varianza	8.9286E-05	0.0026787
Varianza agrupada	0.00138399	
Grados de libertad	1398	
Estadístico t	-4.6696301	
P(T<=t) dos colas	3.3074E-06	
Valor crítico de t (dos colas)	1.96166233	

Tabla 59: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera específica a Golosineros en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.

Fuente: Elaboración propia.

VI. Gráficos y tablas del comportamiento del modelo en el perfil Limpieza.




Gráfico 40: Promedio semanal del indicador de venta PS para el perfil Limpieza.
Fuente: Elaboración propia.




Gráfico 41: Promedio semanal de la tasa de efectividad para el perfil Limpieza.
Fuente: Elaboración propia.




Gráfico 42: Promedio semanal de la cantidad de productos distintos en el perfil Limpieza que no se habían vendido en las 12 semanas previas.
Fuente: Elaboración propia.

	Grupo control	Grupo m1g1
Media	0.01867336	0.01266114
Varianza	0.00405196	0.00204861
Varianza agrupada	0.00305029	
Grados de libertad	1398	
Valor crítico de t (una cola)	1.64594432	
P(T<=t) dos colas	0.04188191	
Valor crítico de t (dos colas)	1.96166233	

Tabla 60: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Limpieza
Fuente: Elaboración propia.

	<i>Grupo control</i>	<i>Grupo m2g1</i>
Media	0.01867336	0.00556389
Varianza	0.00405196	0.00071297
Varianza agrupada	0.00238247	
Grados de libertad	1398	
Estadístico t	5.02464855	
P(T<=t) dos colas	5.6948E-07	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 61: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Limpieza y además eliminando productos vistos y no comprados.
Fuente: Elaboración propia.*

	<i>Grupo control</i>	<i>Grupo m1g1</i>
Media	0.03439032	0.02797021
Varianza	0.01040458	0.0091787
Varianza agrupada	0.00979164	
Grados de libertad	1398	
Estadístico t	1.21380408	
P(T<=t) dos colas	0.22502756	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 62: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Limpieza
Fuente: Elaboración propia.*

	<i>Grupo control</i>	<i>Grupo m2g1</i>
Media	0.03439032	0.012869
Varianza	0.01040458	0.00298458
Varianza agrupada	0.00669458	
Grados de libertad	1398	
Estadístico t	4.92086388	
P(T<=t) dos colas	9.6385E-07	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 63: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Limpieza y además eliminando productos vistos y no comprados.
Fuente: Elaboración propia.*

	<i>Grupo control</i>	<i>Grupo m1g1</i>
Media	0.005	0.03142857
Varianza	0.00122675	0.01099223
Varianza agrupada	0.00610949	
Grados de libertad	1398	
		-
Estadístico t	6.32564943	
P(T<=t) dos colas	3.3867E-10	
Valor crítico de t (dos colas)	1.96166233	

Tabla 64: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Limpieza. Fuente: Elaboración propia.

	<i>Grupo control</i>	<i>Grupo m2g1</i>
Media	0.005	0.01071429
Varianza	0.00122675	0.00274627
Varianza agrupada	0.00198651	
Grados de libertad	1398	
		-
Estadístico t	2.39855924	
P(T<=t) dos colas	0.01659007	
Valor crítico de t (dos colas)	1.96166233	

Tabla 65: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Limpieza y además eliminando productos vistos y no comprados. Fuente: Elaboración propia.

	<i>Grupo m1g2</i>	<i>Grupo m1g1</i>
Media	0.00026529	0.01266114
Varianza	3.2163E-05	0.00204861
Varianza agrupada	0.00104039	
Grados de libertad	1398	
		-
Estadístico t	7.18973344	
P(T<=t) dos colas	1.0537E-12	
Valor crítico de t (dos colas)	1.96166233	

Tabla 66: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica a Limpieza en m1g1 y de manera global en m1g2. Fuente: Elaboración propia.

	Grupo m2g2	Grupo m2g1
Media	0.002677	0.00556389
Varianza	0.00060005	0.00035483
Varianza agrupada	0.00047744	
Grados de libertad	1398	
		-
Estadístico t	2.47174323	
P(T<=t) dos colas	0.01356398	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 67: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica a Limpieza en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.
Fuente: Elaboración propia.*

	Grupo m1g2	Grupo m1g1
Media	0.00071429	0.02797021
Varianza	0.00017832	0.0091787
Varianza agrupada	0.00467851	
Grados de libertad	1398	
		-
Estadístico t	7.45489146	
P(T<=t) dos colas	1.5706E-13	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 68: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica a Limpieza en m1g1 y de manera global en m1g2.
Fuente: Elaboración propia.*

	Grupo m2g2	Grupo m2g1
Media	0.00607143	0.012869
Varianza	0.00197489	0.00298458
Varianza agrupada	0.00247973	
Grados de libertad	1398	
		-
Estadístico t	2.55379127	
P(T<=t) una cola	0.00538052	
Valor crítico de t (una cola)	1.64594432	
P(T<=t) dos colas	0.01076104	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 69: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica a Limpieza en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.
Fuente: Elaboración propia.*

	Grupo m1g2	Grupo m1g1
Media	0.00071429	0.03142857
Varianza	0.00017832	0.01099223
Varianza agrupada	0.00558527	
Grados de libertad	1398	
		-
Estadístico t	7.68868673	
P(T<=t) dos colas	2.7867E-14	
Valor crítico de t (dos colas)	1.96166233	


*Tabla 70: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera a Limpieza específica en m1g1 y de manera global en m1g2.
Fuente: Elaboración propia.*

	<i>Grupo m2g2</i>	<i>Grupo m2g1</i>
Media	0	0.01071429
Varianza	0	0.00274627
Varianza agrupada	0.00137314	
Grados de libertad	1398	
		-
Estadístico t	5.40929433	
P(T<=t) dos colas	7.4343E-08	
Valor crítico de t (dos colas)	1.96166233	


Tabla 71: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera específica a Limpieza en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.

Fuente: Elaboración propia.

VII. Gráficos y tablas del comportamiento del modelo en el perfil Panaderías.



*Gráfico 43: Promedio semanal del indicador de ventas PS del perfil Panaderías.
Fuente: Elaboración propia.*



*Gráfico 44: Promedio semanal de la tasa de efectividad del perfil Panaderías.
Fuente: Elaboración propia.*




Gráfico 45: Promedio semanal de la cantidad de productos PS vendidos distintos en perfil Panaderías.
Fuente: Elaboración propia.

	Grupo de control	Grupo m1g1
Media	0.0319055	0.00038968
Varianza	0.00940063	9.0003E-05
Varianza agrupada	0.00474532	
Grados de libertad	1398	
Estadístico t	8.55913974	
P(T<=t) dos colas	2.9487E-17	
Valor crítico de t (dos colas)	1.96166233	

Tabla 72: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Panaderías
Fuente: Elaboración propia.

	<i>Grupo de control</i>	<i>Grupo m2g1</i>
Media	0.0319055	0.00675689
Varianza	0.00940063	0.00119044
Varianza agrupada	0.00529553	
Grados de libertad	1398	
Estadístico t	6.46536526	
P(T<=t) dos colas	1.393E-10	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 73: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Panaderías y además eliminando productos vistos y no comprados.
Fuente: Elaboración propia.*

	<i>Grupo de control</i>	<i>Grupo m1g1</i>
Media	0.05416664	0.00035714
Varianza	0.02116739	8.9286E-05
Varianza agrupada	0.01062834	
Grados de libertad	1398	
Estadístico t	9.76473063	
P(T<=t) dos colas	7.81E-22	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 74: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Panaderías
Fuente: Elaboración propia.*

	<i>Grupo de control</i>	<i>Grupo m2g1</i>
Media	0.05416664	0.01065475
Varianza	0.02116739	0.00286924
Varianza agrupada	0.01201832	
Grados de libertad	1398	
Estadístico t	7.42540491	
P(T<=t) dos colas	1.9467E-13	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 75: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Panaderías y además eliminando productos vistos y no comprados.
Fuente: Elaboración propia.*

	<i>Grupo de control</i>	<i>Grupo m1g1</i>
Media	0.00428571	0.00035714
Varianza	0.00123339	8.9286E-05
Varianza agrupada	0.00066134	
Grados de libertad	1398	
Estadístico t	2.8579605	
P(T<=t) dos colas	0.00432692	
Valor crítico de t (dos colas)	1.96166233	

Tabla 76: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Panaderías
Fuente: Elaboración propia.

	<i>Grupo de control</i>	<i>Grupo m2g1</i>
Media	0.00428571	0.00321429
Varianza	0.00123339	0.00079437
Varianza agrupada	0.00101388	
Grados de libertad	1398	
Estadístico t	0.6295105	
P(T<=t) dos colas	0.52911776	
Valor crítico de t (dos colas)	1.96166233	

Tabla 77: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Panaderías y además eliminando productos vistos y no comprados.
Fuente: Elaboración propia.

	<i>Grupo m1g2</i>	<i>Grupo m1g1</i>
Media	0.00103386	0.00038968
Varianza	0.00023845	9.0003E-05
Varianza agrupada	0.00016422	
Grados de libertad	1398	
Estadístico t	0.94041956	
P(T<=t) dos colas	0.34716485	
Valor crítico de t (dos colas)	1.96166233	

Tabla 78: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica al perfil Panaderías en m1g1 y de manera global en m1g2.
Fuente: Elaboración propia.

	Grupo m2g2	Grupo m2g1
Media	0.00861611	0.00675689
Varianza	0.00501944	0.00119044
Varianza agrupada	0.00310494	
Grados de libertad	1398	
Estadístico t	0.62421875	
P(T<=t) dos colas	0.53258578	
Valor crítico de t (dos colas)	1.96166233	

Tabla 79: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica a Panaderías en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.
Fuente: Elaboración propia.

	Grupo m1g2	Grupo m1g1
Media	0.00142857	0.00035714
Varianza	0.00035561	8.9286E-05
Varianza agrupada	0.00022245	
Grados de libertad	1398	
Estadístico t	1.34394998	
P(T<=t) dos colas	0.17918263	
Valor crítico de t (dos colas)	1.96166233	

Tabla 80: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica a Panaderías en m1g1 y de manera global en m1g2.
Fuente: Elaboración propia.

	Grupo m2g2	Grupo m2g1
Media	0.00707143	0.01065475
Varianza	0.001706	0.00286924
Varianza agrupada	0.00228762	
Grados de libertad	1398	
Estadístico t	-1.401611	
P(T<=t) una cola	0.0806267	
Valor crítico de t (una cola)	1.64594432	
P(T<=t) dos colas	0.16125341	
Valor crítico de t (dos colas)	1.96166233	

Tabla 81: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica a Panaderías en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.
Fuente: Elaboración propia.

	<i>Grupo m1g2</i>	<i>Grupo m1g1</i>
Media	0.00142857	0.00035714
Varianza	0.00035561	8.9286E-05
Varianza agrupada	0.00022245	
Grados de libertad	1398	
Estadístico t	1.34394998	
P(T<=t) dos colas	0.17918263	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 82: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera específica a Panaderías en m1g1 y de manera global en m1g2.
Fuente: Elaboración propia.*

	<i>Grupo m2g2</i>	<i>Grupo m2g1</i>
Media	0.00035714	0.00321429
Varianza	8.9286E-05	0.00079437
Varianza agrupada	0.00044183	
Grados de libertad	1398	
Estadístico t	-2.5429528	
P(T<=t) dos colas	0.01109903	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 83: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera específica a Panaderías en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.
Fuente: Elaboración propia.*

VIII. Gráficos y tablas del comportamiento del modelo en el perfil Panaderías Bodega.




Gráfico 46: Promedio semanal del indicador de venta PS del perfil Panaderías Bodega.
Fuente: Elaboración propia.




Gráfico 47: Promedio semanal de la tasa de efectividad del perfil Panaderías Bodega.
Fuente: Elaboración propia.




Gráfico 48: Promedio semanal de la cantidad de productos PS vendidos distintos para el perfil Panaderías Bodega.
Fuente: Elaboración propia.

	Grupo de control	Grupo m1g1
Media	0.03316286	0.00089314
Varianza	0.00742313	0.00020038
Varianza agrupada	0.00381175	
Grados de libertad	1398	
Estadístico t	9.77837452	
P(T<=t) dos colas	6.8849E-22	
Valor crítico de t (dos colas)	1.96166233	

Tabla 84: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Panaderías Bodega
Fuente: Elaboración propia.

	Grupo de control	Grupo m2g1
Media	0.03316286	0.01355646
Varianza	0.00742313	0.00272692
Varianza agrupada	0.00507502	
Grados de libertad	1398	
Estadístico t	5.14887889	
P(T<=t) dos colas	2.9944E-07	
Valor crítico de t (dos colas)	1.96166233	

Tabla 85: Test t para Venta PS utilizando modelo SVD calibrado específicamente al perfil Panaderías Bodega y además eliminando productos vistos y no comprados.
Fuente: Elaboración propia.

	<i>Grupo de control</i>	<i>Grupo m1g1</i>
Media	0.06404168	0.00107143
Varianza	0.02811943	0.00026709
Varianza agrupada	0.01419326	
Grados de libertad	1398	
Estadístico t	9.88845222	
P(T<=t) dos colas	2.4761E-22	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 86: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Panaderías Bodega.
Fuente: Elaboración propia.*

	<i>Grupo de control</i>	<i>Grupo m2g1</i>
Media	0.06404168	0.01571429
Varianza	0.02811943	0.00360246
Varianza agrupada	0.01586095	
Grados de libertad	1398	
Estadístico t	7.17898189	
P(T<=t) dos colas	1.1368E-12	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 87: Test t para Efectividad utilizando modelo SVD calibrado específicamente al perfil Panaderías Bodega y además eliminando productos vistos y no comprados.
Fuente: Elaboración propia.*

	<i>Grupo de control</i>	<i>Grupo m1g1</i>
Media	0.00321429	0.00142857
Varianza	0.00079437	0.00035561
Varianza agrupada	0.00057499	
Grados de libertad	1398	
Estadístico t	1.39320482	
P(T<=t) una cola	0.08188967	
P(T<=t) dos colas	0.16377934	

*Tabla 88: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Panaderías Bodega.
Fuente: Elaboración propia.*

	<i>Grupo de control</i>	<i>Grupo m2g1</i>
Media	0.00321429	0.00357143
Varianza	0.00079437	0.00088136
Varianza agrupada	0.00083787	
Grados de libertad	1398	
Estadístico t	-0.2308279	
P(T<=t) dos colas	0.81748231	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 89: Test t para Productos Distintos utilizando modelo SVD calibrado específicamente al perfil Panaderías Bodega y además eliminando productos vistos y no comprados.
Fuente: Elaboración propia.*

	<i>Grupo m1g2</i>	<i>Grupo m1g1</i>
Media	0.00106982	0.00089314
Varianza	0.00026638	0.00020038
Varianza agrupada	0.00023338	
Grados de libertad	1398	
Estadístico t	0.21636518	
P(T<=t) dos colas	0.82873467	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 90: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica a Panaderías Bodega en m1g1 y de manera global en m1g2.
Fuente: Elaboración propia.*

	<i>Grupo m2g2</i>	<i>Grupo m2g1</i>
Media	0.01278289	0.01355646
Varianza	0.00295502	0.00272692
Varianza agrupada	0.00284097	
Grados de libertad	1398	
Estadístico t	-0.2715196	
P(T<=t) dos colas	0.78603155	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 91: Test t para Venta PS utilizando el modelo SVD calibrado de manera específica a Panaderías Bodega en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.
Fuente: Elaboración propia.*

	<i>Grupo m1g2</i>	<i>Grupo m1g1</i>
Media	0.00071429	0.00107143
Varianza	0.00017832	0.00026709
Varianza agrupada	0.0002227	
Grados de libertad	1398	
Estadístico t	-0.4477263	
P(T<=t) dos colas	0.6544201	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 92: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica a Panaderías Bodega en m1g1 y de manera global en m1g2.
Fuente: Elaboración propia.*

	<i>Grupo m2g2</i>	<i>Grupo m2g1</i>
Media	0.01196429	0.01571429
Varianza	0.00300848	0.00360246
Varianza agrupada	0.00330547	
Grados de libertad	1398	
Estadístico t	-1.2202505	
P(T<=t) dos colas	0.22257573	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 93: Test t para Efectividad utilizando el modelo SVD calibrado de manera específica a Panaderías Bodega en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.
Fuente: Elaboración propia.*

	<i>Grupo m1g2</i>	<i>Grupo m1g1</i>
Media	0.00071429	0.00142857
Varianza	0.00017832	0.00035561
Varianza agrupada	0.00026696	
Grados de libertad	1398	
Estadístico t	-0.8178628	
P(T<=t) dos colas	0.41357492	
Valor crítico de t (dos colas)	1.96166233	

*Tabla 94: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera específica a Panaderías Bodega en m1g1 y de manera global en m1g2.
Fuente: Elaboración propia.*

	<i>Grupo m2g2</i>	<i>Grupo m2g1</i>
Media	0.00142857	0.00357143
Varianza	0.00035561	0.00088136
Varianza agrupada	0.00061849	
Grados de libertad	1398	
Estadístico t	-1.6119904	
P(T<=t) una cola	0.05359487	
Valor crítico de t (una cola)	1.64594432	
P(T<=t) dos colas	0.10718975	
Valor crítico de t (dos colas)	1.96166233	

Tabla 95: Test t para Productos Distintos utilizando el modelo SVD calibrado de manera específica a Panaderías Bodega en m1g1 y de manera global en m1g2. Además de eso, el modelo presenta ayuda eliminándolos productos vistos y no comprados.

Fuente: Elaboración propia.