



Universidad de Buenos Aires
Facultad de Ciencias Económicas
Escuela de Estudios de Posgrado



Universidad de Buenos Aires
Facultad de Ciencias Económicas
Escuela de Estudios de Posgrado

**CARRERA DE ESPECIALIZACIÓN EN MÉTODOS
CUANTITATIVOS PARA LA GESTIÓN Y ANÁLISIS DE
DATOS EN ORGANIZACIONES**

TRABAJO FINAL DE ESPECIALIZACIÓN

Título: Evaluación y generación de recomendaciones de acciones a inversionistas utilizando herramientas de Machine Learning

AUTOR: SOFÍA TRONGÉ

[DICIEMBRE 2019]



Resumen

Actualmente, el Mercado de Capitales se encuentra en una expansión gracias a las nuevas plataformas de inversión online, tanto de financieras como de instituciones tradicionales. En los Bancos y las Casas de Bolsa se busca aprovechar esta expansión aumentando el volumen de operaciones. Para ello, se busca no solo incorporar nuevos clientes, sino que aumentar el volumen de operatoria de los clientes ya existen.

Para lograr dicho objetivo los Traders o Promotores realizan periódicamente recomendaciones a sus inversores. Las mismas, son realizadas hoy en día en base al conocimiento o la experiencia de cada promotor. En el presente trabajo se busca evaluar las recomendaciones realizadas actualmente por parte de los promotores de Casas de Bolsa y/o Bancos a los inversionistas que asesoran respecto al perfil del inversor y la diversificación de riesgo de la cartera.

La operatoria de Capitales en Bancos y Casas de Bolsa genera un gran volumen de datos, que actualmente no está siendo explotado en el Mercado mexicano. Para alimentar los ya mencionados algoritmos, se van a utilizar datos de operaciones históricas realizadas por los clientes, las cuales van a ser procesadas para proponer una nueva manera de generar recomendaciones utilizando algoritmos de Machine Learning.

Palabras clave

Sistemas de Recomendaciones, Collaborative Filtering, Mercados de Capitales, Big Data



Estructura

Introducción.....	4
Análisis de las recomendaciones tradicionales.....	7
1.1. Estructura actual de las Organizaciones	9
1.2. Problemática en la generación de recomendación	10
1.3. Análisis y generación de recomendaciones con técnicas de Machine Learning	12
Generación de Recomendaciones con Métodos de Machine Learning.....	13
2.1. Tratamiento de datos para la aplicación de modelos	13
2.2. Desarrollo de Modelos de Sistemas de Recomendaciones.....	14
2.3. Medición de resultados del modelo de Recomendaciones	17
Análisis de resultados y conclusiones finales.....	21
3.1. Problematización de la utilización de datos	21
3.2. Análisis de resultados obtenidos.....	23
3.3. Propuestas y trabajo futuro	24
Conclusión.....	26
Referencias bibliográficas	27
Anexos.....	27
Apéndices	28



Introducción

Fundamentación

Las Entidades que se dedican a operar en los mercados de capitales, como Bancos y Casas de Bolsas de México, cuentan con una gran cantidad de datos que gestionan para dar frente a diferentes necesidades de negocio y tomar decisiones ante situaciones complejas. Como en todos los sectores de la economía los líderes de las organizaciones buscan sacar valor de los grandes volúmenes de datos, generados de manera creciente por la aparición de nuevas tecnologías, buscando obtener el mayor valor posible de ellos para competir en el Mercado (LaValle 2011).

Entre los datos que están disponibles en dichas entidades financieras, se cuenta con un gran volumen de información de todas las transacciones realizadas en el Mercado de Capitales por parte de Clientes, sus precios y cantidades. Las compras que se realizan en dicho Mercado se encuentran generalmente disparadas por una orden del cliente, el cual puede contar con un servicio de inversión asesorado o no asesorado, dependiendo de su calificación por conocimiento del mercado y experiencia. Aquellos clientes no asesorados realizan directamente pedidos de instrumentos específicos al Promotor, quien registra la operación. En cambio, en el caso de los clientes asesorados, generalmente se realiza una oferta/recomendación del Trader basada en su experiencia personal con otros clientes a aquellos clientes menos experimentados.

En el presente trabajo se plantea la necesidad de predecir de manera independiente del cliente su próxima orden, permitiendo una recomendación de parte del Trader más exitosa basada en el historial de compras realizadas. Para predecir los instrumentos que potencialmente van a ser comprados por los clientes se va a utilizar un algoritmo predictivo, más específicamente, sistemas de recomendación. Dichos sistemas constan de complejos algoritmos de trading alimentados por datos, sin la supervisión cercana de seres humanos (MacKenzie, 2014). Además, se va a analizar cómo los instrumentos adquiridos se relacionan con el servicio de inversión del cliente y si las recomendaciones realizadas por los traders respetan la diversificación de riesgo de la cartera del cliente.



Adicionalmente, se va a tratar el dilema ético sobre la utilización de datos privados de los clientes para la generación de dichas recomendaciones, no siendo este el motivo para el cual el cliente presta sus datos personales a las entidades financieras.

La regulación en materia de utilización de datos de índole privado para un propósito diferente para los que fueron provistos está desactualizada ya que no toma en cuenta el cambio tecnológico y el manejo de los abundantes datos generados tampoco se encuentra legislado en la mayoría de los países, por lo tanto, la propiedad y el uso de los datos no se encuentra definido (Snider,2014).

Planteamiento del tema/problema

Actualmente, en Entidades de Casa de Bolsa o Bancos en México, se cuentan con algoritmos de Trading conocidos y habituales en el mercado como los algoritmos que siguen distintas métricas del mercado, como por ejemplo el VWAP. Estos algoritmos dependen de una orden del cliente que lo dispare, para lo cual deben especificar en qué instrumento desean invertir. Dichos algoritmos buscan, dado un instrumento y una cantidad del mismo, regular el volumen invertido evitando disrumpir el orden del mercado.

Existe una dependencia en la generación de la demanda por parte del cliente lo que ocasiona que la iniciativa se encuentre de su lado y no en mano de los Traders. Esto se debe a que en el mercado actualmente no cuenta con herramientas o algoritmos para recomendar instrumentos a los clientes.

El objetivo del trabajo busca desarrollar un sistema de predictivo que permita recomendar qué instrumento va a elegir en su próxima compra el cliente. De esta manera, se le da la posibilidad al Trader de adelantarse a la decisión y disparar el contacto con el cliente, en vez de esperar la orden del mismo.

El objetivo del trabajo es elaborar recomendaciones de compra para los inversores del mercado de capitales y evaluar las recomendaciones que se les realizan actualmente a los clientes respecto a la diversificación del riesgo de la cartera, utilizando algoritmos de



Machine Learning basados en datos históricos transaccionales de clientes de Entidades Financieras. Para alcanzar dicho objetivo, se va a desarrollar un modelo que identifique una relación entre el tipo de servicio de inversión y las acciones que los clientes con servicios asesorados y no asesorados compran. Se van a evaluar las recomendaciones realizadas actualmente por los Traders respecto a la diversificación de cartera de los clientes utilizando Reglas de Asociación. Y, por último, se va a describir la problemática ética del manejo de datos de origen privado para el entrenamiento de los modelos desarrollados.

Estructura del Trabajo

Para cumplimentar el objetivo de este trabajo, en un primer apartado se describirá las organizaciones con las que se van a trabajar y su operatoria actual, se va a exponer la problemática que dichas organizaciones presentan actualmente a la hora de generar recomendaciones de inversiones en el Mercado de Capitales y se va a plantear una posible solución aplicando para la generación de las mismas, algoritmos de Machine Learning basados en la información histórica de la operatoria.

En un segundo apartado se abarcarán los pasos necesarios para el desarrollo de los modelos a utilizar. En primer lugar, se tratará la recopilación y el tratamiento dado a la base de datos. Luego, se explicarán los algoritmos seleccionados y su aplicación. Por último, se expondrán los resultados provenientes de la aplicación de los algoritmos seleccionados y se tratarán las medidas de performance seleccionadas para medir los resultados obtenidos.

En el tercer apartado se expondrán los modelos utilizados y se analizarán los resultados obtenidos a partir de la aplicación de los algoritmos seleccionados y sus implicancias. Además, se tratará la problemática de los datos utilizados para el entrenamiento de los modelos.



Análisis de las recomendaciones tradicionales

Una parte muy importante de la operatoria y de los ingresos de Entidades Financieras, como las Casas de Bolsa y los Bancos especializados en Banca Privada, provienen de la compra y venta de acciones dentro del Mercado de Capitales. Para generar mayores ingresos, los operadores o promotores que trabajan en las instituciones financieras realizan recomendaciones a sus clientes para promover un mayor nivel de inversión de su parte. A partir de la utilización de nuevas tecnologías para la operatoria diaria, los sistemas que utilizan los promotores para realizar las operaciones recopilan automáticamente información de cada movimiento de cada cliente o inversionista que genera grandes volúmenes de datos o “Big Data”.

“Big Data es un término relativo, la información recopilada hoy en día por el software utilizado en las organizaciones es de gran volumen comparada con los datos generados en el pasado, y los métodos y dispositivos para procesarla han avanzado también. El desafío presente hoy en día respecto de la llamada, Big Data, se representa por las 4 Vs, volumen, velocidad, variedad y veracidad. El volumen se refiere a la cantidad de datos. La velocidad se refiere a la tasa en la que fluye la información, o sea, la velocidad en la que es generada y procesada. La variedad se refiere a los diferentes tipos de datos generados. La veracidad se refiere al hecho de que la información es generada por procesos orgánicos distribuidos por y nos sujetos a controles de calidad que aplican a la información recolectada para estudios estadísticos.

Para la mayoría de las organizaciones grandes los grandes volúmenes de datos son tanto una oportunidad como un desafío porque la mayoría de los procesos generan datos que



pueden ser almacenados y potencialmente analizados. La magnitud puede ser visualizada comparando la información generada a través de un análisis estadístico tradicional (de por ejemplo 15 variables y 5000 registros), contra la base de datos de Walmart. Si la base de datos del estudio tradicional fuera del tamaño de una un punto, la base de datos de Walmart sería del tamaño de un campo de futbol americano.” Schmueli et al (2017)

Con la información disponible, procesada, recopilada y guardada por los sistemas que las organizaciones financieras utilizan para facilitar su operatoria diaria se pueden generar análisis que permitan facilitar la toma de decisiones estratégicas.

En el caso de las entidades de Casa de Bolsa y Banca Privada, la información recopilada de cada uno de los inversionistas puede permitir generar recomendaciones basadas en la información histórica de cada una de las operaciones de la totalidad de los inversionistas utilizando las herramientas disponibles de Machine Learning.

Se entiende por Machine Learning “al estudio de algoritmos computacionales que permiten a los programas mejorar automáticamente a partir de la experiencia” Mitchell, T. M. (1997).

Esto permitiría generar más interés de parte de los inversionistas y un mayor de volumen de ingreso y operatoria en las Instituciones Financieras.

“Mejores resultados pueden ser obtenidos a partir de la adopción de un método de Machine Learning, en el que un set de tamaño de N dígitos $\{x_1, \dots, x_N\}$, el cual es llamado set de entrenamiento, es utilizado para afinar o mejorar los parámetros de un modelo adaptativo.” Bishop, C. M. (2006).

“La forma de la función (x), resultado del modelo, es determinada durante la fase de entrenamiento, también conocida como fase de aprendizaje del algoritmo, la cual se basa en los datos de entrenamiento. Una vez que el modelo es entrenado, se puede entonces determinar la identidad de nuevos dígitos imágenes de dicha función, los cuales se dicen que componen el conjunto de pruebas o Testing. La habilidad de categorizar correctamente nuevos ejemplos que sean diferentes de aquellos usados en el entrenamiento se conoce



como generalización. En aplicaciones prácticas, la variabilidad de los datos de entrada genera que los datos de entrenamiento puede ser un conjunto de los tantos posibles, por lo que, la generalización es una meta del reconocimiento de patrones.” Bishop, C. M. (2006).

1.1. Estructura actual de las Organizaciones

Las organizaciones dentro del alcance del presente trabajo son Casas de Bolsa y Banco especializados en Banca Privada, no considerándose la operatoria de Banca de Retail. Se va a analizar la operatoria de las mencionadas instituciones dentro del Mercado de Capitales de México.

Para llevar a cabo la operatoria de Capitales, hoy en día, las entidades hacen uso distintos sistemas que recopilan y guardan en las bases de datos información propia de la operatoria. Las Entidades que se dedican a operar en los mercados de capitales, como Bancos y Casas de Bolsas de México, cuentan con una gran cantidad de datos que gestionan para dar frente a diferentes necesidades de negocio y tomar decisiones ante situaciones complejas, aunque actualmente no explotan dicha información con métodos de Machine Learning para optimizar sus decisiones. Dentro de la clasificación de tipos de organizaciones de Lavalle, se las podría catalogar como aspiracionales:

“Se pueden clasificar en 3 niveles a las organizaciones según sus capacidades para utilizar datos para solucionar diferentes problemáticas:

- Aspiracional: Organizaciones en proceso de entender los desafíos y oportunidades del análisis de datos, para lo cual deben desarrollar procesos, gente y herramientas para actuar a partir de análisis.
- Experimentadas: organizaciones que desarrollan mejores formas de recolectar y actuar en base al análisis de datos para optimizar procesos de dichas organizaciones.
- Transformadas: organizaciones experimentadas en análisis de datos usando procesos y gente capacitada, para diferenciarse de competidores y obtener una ventaja competitiva.” LaValle et Al (2011)

A medida que se recolecta más datos, los líderes de las organizaciones se plantean cómo mejor explotarlos para obtener mejores resultados de negocio. Para la toma de decisiones



se necesitan algoritmos que no solo expliquen el pasado, sino que sirvan para predecir tendencias futuras. Como en todos los sectores de la economía los líderes de las organizaciones buscan sacar valor de los grandes volúmenes de datos, generados de manera creciente por la aparición de nuevas tecnologías, buscando obtener el mayor valor posible de ellos para competir en el Mercado (LaValle 2011).

Las organizaciones incluyen el análisis para transformar los datos en conclusiones y luego transformarlas en acciones concretas tanto operativas como financieras. Las empresas que realizan análisis de datos tienen mayor performance que sus competidores.

El obstáculo en las organizaciones para la adopción del análisis de datos para la toma de decisiones no son los datos en sí, sino la barreta cultural y de management. Para ello, la información compleja generada debe ser comunicados con técnicas que permitan mostrar el significado de la información.

Entre los datos que están disponibles en dichas entidades financieras, se cuenta con un gran volumen de información de todas las transacciones realizadas en el Mercado de Capitales por parte de Clientes, sus precios y cantidades. Las compras que se realizan en dicho Mercado se encuentran generalmente disparadas por una orden del cliente, el cual puede contar con un servicio de inversión asesorado o no asesorado, dependiendo de su calificación por conocimiento del mercado y experiencia.

Aquellos clientes no asesorados realizan directamente pedidos de instrumentos específicos al Promotor, quien registra la operación. En cambio, en el caso de los clientes asesorados, generalmente se realiza una oferta/recomendación del Trader basada en su experiencia personal con otros clientes a aquellos clientes menos experimentados.

1.2. Problemática en la generación de recomendación

Actualmente, en Entidades de Casa de Bolsa o Bancos en México, se cuentan con algoritmos de Trading conocidos y habituales en el mercado como los algoritmos que siguen distintas métricas del mercado, como por ejemplo el VWAP. Estos algoritmos



dependen de una orden del cliente que lo dispare, para lo cual deben especificar en qué instrumento desean invertir. Dichos algoritmos buscan, dado un instrumento y una cantidad del mismo, regular el volumen invertido evitando disrumpir el orden del mercado.

Existe una dependencia en la generación de la demanda por parte del cliente lo que ocasiona que la iniciativa se encuentre de su lado y no en mano de los Traders. Esto se debe a que en el mercado actualmente no cuenta con herramientas o algoritmos para recomendar instrumentos a los clientes.

We need technology to help us wade through all the information to find the items we really want and need, and to rid us of the things we do not want to be bothered with. Shardanand (2015)

El objetivo del trabajo busca desarrollar un sistema de predictivo que permita recomendar qué instrumento va a elegir en su próxima compra el cliente. De esta manera, se le da la posibilidad al Trader de adelantarse a la decisión y disparar el contacto con el cliente, en vez de esperar la orden del mismo.

En el presente trabajo se plantea la necesidad de predecir de manera independiente del cliente su próxima orden, permitiendo una recomendación de parte del Trader más exitosa basada en el historial de compras realizadas. Para predecir los instrumentos que potencialmente van a ser comprados por los clientes se va a utilizar un algoritmo predictivo, más específicamente, sistemas de recomendación. Dichos sistemas constan de complejos algoritmos de trading alimentados por datos, sin la supervisión cercana de seres humanos (MacKenzie, 2014). Además, se va a analizar cómo los instrumentos adquiridos se relacionan con el servicio de inversión del cliente y si las recomendaciones realizadas por los traders respetan la diversificación de riesgo de la cartera del cliente.

Adicionalmente, se va a tratar el dilema ético sobre la utilización de datos privados de los clientes para la generación de dichas recomendaciones, no siendo este el motivo para el cual el cliente presta sus datos personales a las entidades financieras. La regulación en materia de utilización de datos de índole privado para un propósito diferente para los que fueron



provistos está desactualizada ya que no toma en cuenta el cambio tecnológico y el manejo de los abundantes datos generados tampoco se encuentra legislado en la mayoría de los países, por lo tanto, la propiedad y el uso de los datos no se encuentra definido (Snider, 2014).

1.3. Análisis y generación de recomendaciones con técnicas de Machine Learning

En los incisos anteriores del trabajo se planteó la necesidad de las organizaciones financieras de predecir de manera independiente del inversor su próxima orden, permitiendo una recomendación de parte del Trader más exitosa basada en el historial de compras realizadas. Se van a analizar, en primer lugar, las recomendaciones generadas actualmente en base al conocimiento y la experiencia de los empleados que se dedican exclusivamente a operar capitales. Las mismas serán evaluadas respecto al impacto que general en la diversificación de la cartera del cliente teniendo en cuenta que los instrumentos adquiridos se relacionan con el servicio de inversión del cliente.

Para predecir los instrumentos que potencialmente van a ser comprados por los clientes se va a utilizar un algoritmo predictivo, más específicamente, sistemas de recomendación con filtrado colaborativo basado en usuarios. Dichos sistemas constan de complejos algoritmos de trading alimentados por datos, sin la supervisión cercana de seres humanos (MacKenzie, 2014). Además, y si las recomendaciones realizadas por los algoritmos respetan la diversificación de riesgo de la cartera del cliente.



Generación de Recomendaciones con Métodos de Machine Learning

En el presente apartado se presentan los aspectos metodológicos del tratamiento de datos y del desarrollo de los modelos utilizados para la evaluación de las recomendaciones realizadas actualmente y aquellos modelos calibrados para generar nuevas recomendaciones automáticamente y a partir de información histórica.

2.1. Tratamiento de datos para la aplicación de modelos

En primer lugar, se debe adaptar la información recolectada por sistemas pensados para la operatoria diaria de las organizaciones estudiadas y no el análisis de datos.

Se parte de una base de banca privada, con información de la operatoria bancaria diaria de 2018 del Mercado de Capitales de clientes, de la cual se extrajo mediante consultas información relevante y disponible sobre la operatoria de acciones y los inversores o clientes. Más específicamente se obtuvo información de:

- Tipo de operación
- Cliente
- Tipo de persona
- Género
- Instrumento
- Producto
- Fecha de operación
- Tipo de Servicio de Inversión

La información extraída de transacciones de capitales realizadas tiene ciertas consideraciones que se deben tener en cuenta. En la entidad estudiada la operatoria de capitales cuenta con la peculiaridad de que se genera una operación por instrumento, no registrándose operaciones múltiples. En el caso que un cliente requiera comprar múltiples instrumentos en una sola instrucción, se cargan tantas operaciones como instrumentos desee comprar.



En la base analizada se observó que había más de una operación para un mismo cliente e instrumento. Como los clientes y los instrumentos se encontraban repetidos en las operaciones, se genera una lista de cada uno de los atributos sin duplicados. Chequeando los registros de la base también se detectaron instrumentos que se comercializan y operan como acciones, pero que no lo son. Por eso se remueven de la lista registros de ciertos instrumentos financieros como ETFs o fideicomisos:

- CKDs
- FHIPOs
- Fibras
- TRACs

Adicionalmente, se quitan los registros de operaciones propias del banco, porque está afuera del alcance del trabajo que no busca predecir compras de propias de las instituciones bancarias, sino las de sus clientes.

Una vez quitados la información no relevante para el trabajo, los datos fueron preparados en Excel para cumplir con el formato necesario para servir de datos de entrada de los modelos. Para el análisis de recomendaciones haciendo uso del algoritmo a priori, se armó una matriz donde cada fila es un cliente y cada columna un instrumento y se indica con cero o uno si el cliente posee esa acción en su cartera o no. Para la generación de nuevas recomendaciones se preparó una matriz similar, pero con la concentración del instrumento en la cartera en cada columna.

2.2. Desarrollo de Modelos de Sistemas de Recomendaciones

Para analizar las recomendaciones generadas actualmente a los inversores en Casas de Bolsa y Bancos se decidió utilizar el modelo de Reglas de Asociación, ya que permite descubrir relaciones entre características de los Clientes y los instrumentos de las transacciones. Las reglas a descubrir buscan determinar que productos se comprar conjuntamente frecuentemente, de manera tal de poder inferir con la presencia de ciertos productos en una transacción, la presencia de otros. Las reglas de asociación buscan



permitir definir estrategias que lleven a fomentar que el cliente compre esos ítems relacionados.

Las reglas de asociación emulan un análisis de afinidad, constituyen un estudio de que ítems se relacionan. La idea es determinar dependencias, en las bases transaccionales, entre las compras de diferentes ítems. Por ello, el método es ampliamente utilizado en modelo de ventas de productos.

Aplicando el modelo se genera una cierta cantidad de reglas, de las que se desea seleccionar reglas robustas dentro de la variedad generada. Para medir la robustez de la asociación implícita en una regla generalmente se utilizan las medidas de soporte y confianza.

Dados los ítems X e Y:

Una regla de asociación $X \rightarrow Y$ tiene confianza “c” si c% de las transacciones en la base de datos que contienen X también contienen Y.

Una regla de asociación $X \rightarrow Y$ tiene soporte “s” si s% de las transacciones en la base de datos contienen X U Y.

Cómo se genera un gran número de reglas y no todas son necesariamente relevantes, se aplica un algoritmo que depura los conjuntos menos frecuentes y se queda con las reglas de los conjuntos de ítems frecuentes.

Un ejemplo de las reglas generadas son las siguientes:

No.	Premisa	Antecedente	Soporte	Confianza	Lift
350	Asesoría, 1I SHV *, 1A GOOG *	1A FB *	0,1154	0,8571	3,5374
352	Asesoría, 1I SHV *, 1A GOOG *	1A FB *, 1A AMZN *	0,1154	0,8571	4,6429
407	Asesoría, 1I SHV *, 1A GOOG *	1A AMZN *	0,1231	0,9143	4,4852



488	Asesoría, 1I SHV *, 1A FB *, 1A GOOG *	1A AMZN *	0,1154	1,0000	4,9057
439	Asesoría, 1I SHV *, 1A FB *, 1A AMZN *	1A GOOG *	0,1154	0,9375	4,6875

Las demás reglas generadas por el algoritmo se presentan en la sección de Apéndices.

Para alcanzar el objetivo de generar nuevas recomendaciones utilizando técnicas de Machine Learning se va a utilizar el algoritmo de Filtrado Colaborativo basado en usuarios que utiliza la técnica de armado de Clusters K vecinos más cercanos. El algoritmo se basa en la búsqueda de usuarios similares. El método está pensado para generar recomendaciones personalizadas para un usuario utilizando filtrado colaborativo, se basa en encontrar usuarios con preferencias similares y realizar recomendaciones de ítems que a los usuarios potencialmente les gustarían y podrían comprar.

El algoritmo cuenta con dos instancias:

1. En la primera etapa se buscan usuarios con la mayor cantidad de similitudes al interés del usuario, los cuales se define como vecinos. Esto se logra comparando las preferencias del usuario con las de los demás usuarios.
2. En la segunda etapa considerando únicamente los ítems que el usuario no ha adquirido todavía, se recomienda aquel que sea de mayor preferencia de sus vecinos más cercanos. Este método es el que utiliza Amazon, para recomendar ítems que comprar a sus clientes a partir de otras compras de clientes que compraron dicho producto, y Google para generar las recomendaciones de páginas similares mostradas en los resultados de las búsquedas.

El primer paso requiere que se seleccione una métrica de distancia para medir proximidad entre el usuario al que se le van a generar recomendaciones y los otros usuarios. Una vez que las distancias se encuentran calculadas, se usa un número determinado por el usuario como una suerte de límite de distancia que sirve para determinar los vecinos más cercanos. Esta metodología recibe el nombre de Top N recomendaciones basada en usuarios, donde se mide la distancia en el usuario seleccionado y los demás usuarios pertenecientes al conjunto de datos con el que se cuenta y se seleccionan los vecinos más cercanos de



manera similar a la del algoritmo “k vecinos más cercanos”. Dentro de los vecinos más cercanos se seleccionan los mejores ítems para recomendarlos al usuario con preferencias similares. En caso de un conjunto de datos binarios la mejor recomendación es el ítem más comprado o mejor rankeado.

“El método de filtrado colaborativo esencialmente automatiza el proceso de recomendaciones boca a boca, ya que se le recomiendan ítems a un usuario basándose en los valores asignados por otra gente con gustos similares. El sistema determina que usuarios tienen gustos similares utilizando fórmulas estándar para calcular correlaciones estadísticas” (Shardanand, 1995)

La ventaja de la utilización del filtrado colaborativo basado en usuarios es que el Sistema puede llegar a recomendar al usuario ítems muy diferentes, en términos de contenido, que aquellos ítems que el usuario indicó que le gustaban previamente.

El método se basa en el supuesto de que los gustos de las personas no están distribuidos aleatoriamente, sino que se presentan patrones dentro de los gustos de las personas y también los hay entre grupos de personas.

Un ejemplo de las top 5 recomendaciones generadas por el algoritmo para un usuario son:

```
"1 BIMBO A"  
"1B NAFTRAC ISHRS"  
"0 CREAL"  
"0 UNIFIN A"  
"1 AEROMEX"
```

2.3. Medición de resultados del modelo de Recomendaciones

Los resultados generados por los algoritmos utilizados, tanto para analizar las recomendaciones generadas de manera tradicional como para generar reglas utilizando técnicas de Machine Learning, pueden ser evaluados utilizando distintos criterios.

El algoritmo utilizado para la evaluación de las recomendaciones realizadas por los promotores de Bancos y Casas de Bolsa, se aplica para generar asociaciones entre el perfil de inversión del cliente y los instrumentos comprados por el inversionista. Como se



mencionó anteriormente la robustez de las reglas encontradas por la aplicación del modelo A Priori puede ser medida utilizando diferentes criterios:

La medida de confianza expresa el grado de incertidumbre de la regla de tipo si → entonces. La medida compara la co ocurrencia del antecedente y el ítem consecuente en la base de datos con la ocurrencia del ítem antecedente.

La confianza es definida como el ratio del número de transacciones que incluyen el antecedente y el ítem consecuente sobre el número total de transacciones que incluyen el ítem antecedente.

Confianza= (Número de transacciones que incluyen el antecedente y el consecuente) / (Número de transacciones que incluyen el antecedente)

El soporte mide el número de transacciones donde aparece un ítem sobre el número total de transacciones.

Soporte = (Número de transacciones que incluyen un ítem) / (Número total de transacciones)

Un valor alto de confianza sugiere una regla de asociación robusta. Sin embargo, esto puede ser engañoso ya que si el antecedente y el consecuente tienen un alto nivel de soporte se puede obtener un alto nivel de confianza por más que el antecedente y el consecuente sean independientes.

Por ello, se decide utilizar otra alternativa como medida, el “Lift Ratio”, que decide que tan fuerte es una regla comparando la confianza de una regla con un valor base desde el que se asume que la ocurrencia de un ítem consecuente en una transacción es independiente de la ocurrencia del antecedente de cada regla.

En el primer apéndice se muestra el Lift Ratio, el soporte y la confianza calculada para cada regla determinada por el algoritmo. Por ejemplo:



No.	Premisa	Antecedente	Soporte	Confianza	Lift
350	Asesoría, 1I SHV *, 1A GOOG *	1A FB *	0,1154	0,8571	3,5374

En el caso del algoritmo de Filtrado Colaborativo se pueden utilizar otras mediciones más apropiadas, generalmente por ser un método que implica el armado de clusters las medidas utilizadas son aquellas de distancia.

La forma más simple de calcular la similitud entre dos ítems es mediante el cálculo de la distancia Euclidiana. La distancia Euclidiana entre dos objetos del conjunto de datos, siendo uno el punto x y otro el punto y, se define mediante la siguiente ecuación:

$$d(x, y) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2}$$

Donde, x e y son dos puntos consecutivos dentro del conjunto de datos y n es el número de atributos para dicho conjunto de datos.

Una segunda opción de medida de distancia que puede ser utilizada es la similitud del coseno, que mide la similitud entre dos vectores del espacio de un producto interior con el que se evalúa el valor del coseno del ángulo comprendido entre ellos. La similitud del coseno viene dada por la siguiente fórmula:

$$Similitud = \cos(\theta) = \frac{A \cdot B}{\|A\| \|B\|} = \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} * \sqrt{\sum_{i=1}^n B_i^2}}$$

Otra forma de medir similitud entre dos ítems es mediante la correlación entre variables, para ello se puede utilizar la correlación de Pearson. La correlación de Pearson es un tipo de coeficiente de correlación entre dos variables popular que se calcula como la covarianza entre las dos variables dividida por el producto de sus desvíos estándares. La fórmula de la correlación de Pearson es la siguiente:



$$\rho_{X,Y} = \frac{\sigma_{X,Y}}{\sigma_X \sigma_Y}$$

Otras medidas posibles para evaluar la distancia entre vecinos pueden ser el error cuadrático medio, la raíz del error cuadrático medio y el error absoluto medio.

Error cuadrático medio:

$$ECM = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2$$

Raíz del error cuadrático medio:

$$RECM = \sqrt{ECM}$$

Error absoluto medio:

$$EAM = \frac{\sum_{i=1}^n |y_i - x_i|}{n}$$

La medida que se evaluó como la más indicada es la raíz del error cuadrático, ya que suaviza cualquier desviación provocada por anomalías en la base de datos. También se va a utilizar para contrastar resultados el error cuadrático medio y el error absoluto medio.

A continuación, se muestran las medidas de error para las corridas del modelo sin centralizar los datos, con los datos centralizados y con los datos estandarizados:

	RMSE	MSE	MAE
UBCF_N_C	0.0240274	0.0005773	0.0008900
UBCF_C_C	0.0243417	0.0005925	0.0005925
UBCF_Z_C	0.0243417	0.0005925	0.0005925



Análisis de resultados y conclusiones finales

En la presente sección del trabajo, se analizarán en un primer apartado los datos que se utilizaron para entrenar y desarrollar el algoritmo desde la perspectiva de propiedad y privacidad de los mismos. Además de problematizar sobre la utilización de datos no propios de las organizaciones sujetas a estudio, se justificará el motivo por el cual se pueden utilizar dichos datos, identificando de todas formas los potenciales riesgos de dicho uso.

En un segundo apartado se analizarán los resultados obtenidos por la aplicación del algoritmo A Priori para la evaluación de las recomendaciones que realizan actualmente los promotores a sus clientes inversores. También se explayará sobre los resultados obtenidos en la generación de nuevas recomendaciones de acciones apoyándose en herramientas de Machine Learning.

En el último y tercer apartado se plantearán las limitaciones del trabajo, y se propondrán propuestas de trabajo a futuro y posibles mejoras.

3.1. Problematización de la utilización de datos

Los sistemas de recomendación son algoritmos complejos que utilizan para generar predicciones los datos históricos del transaccional de los clientes. Actualmente, en los países con mercados financieros altamente sofisticados, el mundo de la Banca moderna está dirigido por complejos algoritmos de trading alimentados por datos, sin la supervisión cercana de seres humanos (MacKenzie, 2014).

En este trabajo se propone la utilización de algoritmos de Machine Learning, más específicamente, filtrado colaborativo basado en usuarios que se basa en el método de armado de clusters K vecinos más cercanos, para la generación recomendaciones automáticamente e independiente de los promotores y su conocimiento. Para entrenar



dicho modelo se hace uso de información histórica de compras de inversionistas clientes de una organización de carácter financiero.

La problemática moral sobre la privacidad de datos utilizados para entrenar los modelos se va a abarcar en el trabajo desde la perspectiva del cumplimiento o no de tres principios. El primer principio de falta o inadecuado de consentimiento de los usuarios en el proceso de obtención y distribución de los datos personales. El segundo es el insuficiente acceso y control de los usuarios de la información personal. El tercero es el riesgo de re-identificación de la información personal anonimizada. (Esteve 2017).

Teniendo en cuenta los criterios planteados en el párrafo anterior, se puede evaluar la aplicación de los mismos a la base de datos utilizados para entrenar los algoritmos de generación de recomendaciones automáticas para trading:

- La propiedad de los datos sobre clientes, y su operatoria en el mercado de capitales, manejados por los bancos y casas de bolsa pertenece a dichas organizaciones mismos. Esto se debe a que los datos son proporcionados voluntariamente por los clientes y bajo determinadas normas que protegen la privacidad de los mismos, ya que es información sensible de los clientes que brindan a los bancos. La problemática surge al ser utilizados los datos con un objetivo distinto al de la pura operatoria o con fines regulatorios, los clientes no autorizan explícitamente a las organizaciones a utilizar su información para desarrollar y entrenar modelos.
- El acceso a los datos por parte de los clientes en Banca es bastante transparente, ya que por regulación se entregan Estados de Cuenta o reportes de movimientos de cuenta, como Cartas de Confirmación de operaciones.
- La re-identificación a partir de datos transaccionales, si bien es difícil se identifica como un riesgo si los datos no se encuentran anonimizados apropiadamente. Los datos utilizados en el trabajo fueron anonimizados para no mostrar ningún dato personal de los clientes, ya sea nombre, dirección, número de identificación, entre otros.

La regulación en materia de utilización de datos de índole privado para un propósito diferente para los que fueron provistos está desactualizada ya que no toma en cuenta el



cambio tecnológico y el manejo de los abundantes datos generados tampoco se encuentra legislado en la mayoría de los países, por lo tanto, la propiedad y el uso de los datos no se encuentra definido (Snider,2014). En el contexto de México, se cuenta con leyes de privacidad de datos de clientes de entidades financieras, pero no se especifica que acciones pueden realizar o no dichas entidades internamente con esos datos.

Además, el impacto de los resultados de la aplicación de dichos algoritmos no siempre ha sido positivo en el mercado. Han contribuido a empeorar ciertas tendencias y los procesos de crisis del mercado (Beunza & Millo, 2014). Aunque hay algoritmos utilizados hoy en día para manejar el volumen de las operaciones en el tiempo, para evitar un fuerte impacto en el mercado, los algoritmos son moldeados por el comportamiento de las grandes Casas de Bolsa y los Bancos que tienen el volumen suficiente para manipular tendencias y son permeables a no reaccionar a tiempo a un cambio inesperado en el contexto de aplicación. La regulación no se encuentra actualizada para mitigar el efecto potencial de la utilización de los algoritmos.

3.2. Análisis de resultados obtenidos

A partir de las reglas obtenidas se puede concluir que los clientes con servicio asesorado compran Acciones con tipo de valor 1I y 1A los cuales identifican a las acciones del SIC, el registro internacional de capitales. Las acciones identificadas por ese tipo de valor son acciones estadounidenses de alta calificación y bajo riesgo. Por lo tanto, los clientes asesorados están comprando en su mayoría por recomendación de los traders acciones extranjeras, exclusivamente de Estados Unidos y de bajo riesgo. Esta situación deja expuestos a los inversores al riesgo de poseer una posición concentrada en instrumentos de un único país, dónde, en un contexto como el actual, en el que se está desarrollando una guerra comercial entre Estados Unidos y China que genera el desbalance de cuentas del país norteamericano, generando una situación de inestabilidad en el mercado financiero y exponiéndose los inversores de tales instrumentos a posibles pérdidas.

Respecto a los clientes sofisticados sin servicio asesorado, que son aquellos que cuentan con experiencia en el mercado y mayor capital, y, por ende, no necesitan de



recomendaciones antes de realizar operaciones en el mercado de capitales. Se puede observar que no se presentan reglas de asociación fuertes. De lo cual se puede inferir que su cartera se encuentra altamente diversificada, no concentrando su cartera en un tipo de valor o instrumento específico.

De lo expuesto en los párrafos anteriores, se puede concluir que las recomendaciones generadas actualmente a los clientes asesorados por los traders no apuntan a lograr la diversificación de la cartera del cliente, sino que pueden estar motivadas por otras razones como pueden ser la de generar recomendaciones por el perfil de riesgo de las personas o lograr asegurarle una renta al cliente con una acción de empresas internacionales ampliamente reconocidas.

Mediante la aplicación de la técnica de Machine Learning de Sistemas de Recomendaciones basados en Filtrado Colaborativo de Usuarios, se permite generar recomendaciones a los usuarios basándose en la información histórica del total de la población de inversores e independientemente de los promotores.

3.3. Propuestas y trabajo futuro

El método de Filtrado Colaborativo cuenta con la desventaja de que sufre de problemas de inicialización, esto quiere decir, que no puede ser utilizado de la forma que fue pensado originalmente para generar recomendaciones para nuevos usuarios o nuevos ítems. Para usuarios nuevos que no compraron ninguna acción, el algoritmo de filtrado colaborativo basado en usuarios no puede realizar ninguna recomendación ya que no sabe que usuarios tienen preferencias similares al nuevo usuario. Para acciones que no hayan sido compradas por ningún usuario o, las mismas nunca van a ser recomendadas ya que el algoritmo analiza las compras hechas por usuarios similares y ninguno de los usuarios compró el nuevo ítem todavía.

El algoritmo original, vecinos más cercanos, también tiene dificultades para generar recomendaciones para usuarios que no calificaron más de un ítem, para aquellos usuarios el coeficiente de correlación entre ellos y otros usuarios tendrá un denominador de cero y



una proximidad del coseno que será uno sin importar la puntuación dada a dicho ítem. De manera similar para usuarios con un solo ítem, los ítems con un solo usuario no pueden ser utilizados para encontrar vecinos cercanos.

Un desafío a futuro es poder incorporar al algoritmo una manera de superar este inconveniente para nuevos ítems o usuarios. Para poder atacar esa problemática se va a incluir otra información que permita tener más información sobre la preferencia de los usuarios, como perfiles de usuarios y descripción de los ítems.

Además, otra desventaja del método de los vecinos más cercanos es el lento procesamiento en bases de datos con gran número de usuarios. Una solución antes esta problemática es la utilización de metodologías de clusterización, que permiten agrupar a los usuarios en grupos homogéneos en términos de preferencias, para luego medir la distancia de cada usuario dentro de los grupos definidos por el algoritmo de clusterización. De esta manera, se pueden bajar los tiempos de procesamiento con el paso de agrupamiento en clusters, que se puede realizar de manera independiente o previa, ganando tiempo que permita luego comparar las preferencias de cada usuario dentro de su respectivo grupo. La contra del armado de clusters previamente a la ejecución del algoritmo de vecinos más cercanos por usuarios, es que se generan recomendaciones menos certeras debido a que no necesariamente los usuarios más cercanos del grupo son los más parecidos a un usuario determinado.

Como trabajo futuro se desea extender la base de datos a la que se le aplica el algoritmo, por lo cual, se debe considerar que el tiempo de procesamiento sea factible, por lo cual, la aplicación de clusters antes del algoritmo de vecinos más cercanos es una opción.

En cuanto a la medición de los resultados, en el trabajo se presentaron varias y se eligieron para el filtrado colaborativo basado en usuarios medidas de distancia mínima. Estudios empíricos demuestran que el Coeficiente de Pearson superó a las otras medidas para sistemas de recomendación con filtrado colaborativo basado en usuarios. Por lo tanto, se van a extender a futuro las medidas de resultados para incluir el cálculo de dicho coeficiente asegurando de esta manera la relación entre el usuario y el ítem seleccionado.



Conclusión

En el trabajo se analizaron en primer lugar las recomendaciones generadas actualmente por los Promotores de Casas de Bolsa y Banca Privada. Se encontró que las mismas se generan con una fuerte asociación entre aquellos inversores con perfil asesorado e instrumentos del tipo de valor 1A o 1I, con el cual se identifican las acciones americanas en el mercado mexicano. En tanto, los clientes con servicio de ejecución, que son aquellos sofisticados que no invierten siendo asesorados por promotores, no presentan reglas de asociación con algún instrumento en particular, sino que su cartera se encuentra más diversificada y no concentrada en instrumentos de determinado tipo de valor.

En segundo lugar, se hizo uso de un algoritmo de Machine Learning, llamado Sistemas de Recomendación de Filtrado Colaborativo Basado en Usuarios para generar nuevas recomendaciones a los usuarios. Esto permite generar recomendaciones automáticamente e independientemente de los promotores y, además, que las recomendaciones se encuentren basadas en información histórica del conjunto de los clientes.

A futuro, se va a extender la aplicación del algoritmo a un mayor número de usuarios aplicando anteriormente clusters para hacer posible su procesamiento en términos de tiempo. También se trabajará con ensambles y se extenderá la información disponible de los usuarios e instrumentos para poder armar un modelo que soporte usuarios e ítems nuevos o con una sola compra.



Referencias bibliográficas

- Nair, B. B., Mohandas, V. P., Nayanar, N., Teja, E. S. R., Vigneshwari, S., & Teja, K. V. N. S. (2015). A stock trading recommender system based on temporal association rule mining. *SAGE Open*, 5(2), 2158244015579941.
- Shmueli, G., Bruce, P. C., Yahav, I., Patel, N. R., & Lichtendahl Jr, K. C. (2017). *Data mining for business analytics: concepts, techniques, and applications in R*. John Wiley & Sons.
- Borgelt, C., & Kruse, R. (2002). Induction of association rules: Apriori implementation. In *Computat* (pp. 395-400). Physica, Heidelberg.
- Agrawal, R., & Srikant, R. (1994, September). Fast algorithms for mining association rules. In *Proc. 20th int. conf. very large data bases, VLDB* (Vol. 1215, pp. 487-499).
- Esteve, A. (2017). The business of personal data: Google, Facebook, and privacy issues in the EU and the USA. *International Data Privacy Law*, 7(1), 36-47.
- LaValle, S., Lesser, E., Shockley, R., Hopkins, M. S., & Kruschwitz, N. (2011). Big data, analytics and the path from insights to value. *MIT sloan management review*, 52(2), 21-32.
- Snider, L. (2014). Interrogating the algorithm: Debt, derivatives and the social reconstruction of stock market trading.
- Beunza, D., & Millo, Y. (2014). Blended automation: Integrating algorithms on the floor of the New York Stock Exchange. Systemic Risk Centre.
- MacKenzie, D. (2014, February). A sociology of algorithms: High frequency trading and the shaping of markets. School of Social and Political Science, University of Edinburgh, Edinburgh, Scotland.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. springer.
- Mitchell, T. M. (1997). *Machine learning*. 1997. Burr Ridge, IL: McGraw Hill, 45(37), 870-877.
- Shardanand, U., & Maes, P. (1995, May). Social information filtering: algorithms for automating "word of mouth". In *Chi* (Vol. 95, pp. 210-217).
- Gorakala, S. K., & Usuelli, M. (2015). *Building a recommendation system with R*. Packt Publishing Ltd.



Apéndices

Apéndice 1: Tabla de reglas generadas por el algoritmo de Reglas de Asociación, con las medidas de soporte, confianza y lift de cada regla.

No.	Premisa	Antecedente	Soporte	Confianza	Lift
350	Asesoría, 1I SHV *, 1A GOOG *	1A FB *	0,1154	0,8571	3,5374
352	Asesoría, 1I SHV *, 1A GOOG *	1A FB *, 1A AMZN *	0,1154	0,8571	4,6429
407	Asesoría, 1I SHV *, 1A GOOG *	1A AMZN *	0,1231	0,9143	4,4852
488	Asesoría, 1I SHV *, 1A FB *, 1A GOOG *	1A AMZN *	0,1154	1,0000	4,9057
439	Asesoría, 1I SHV *, 1A FB *, 1A AMZN *	1A GOOG *	0,1154	0,9375	4,6875
146	Asesoría, 1I SHV *, 1A FB *	1A BABA N	0,1038	0,6750	3,2500
238	Asesoría, 1I SHV *, 1A FB *	1A GOOG *	0,1154	0,7500	3,7500
243	Asesoría, 1I SHV *, 1A FB *	1A AMZN *, 1A GOOG *	0,1154	0,7500	4,4318
291	Asesoría, 1I SHV *, 1A FB *	1A AMZN *	0,1231	0,8000	3,9245
308	Asesoría, 1I SHV *, 1A BABA N	1A FB *	0,1038	0,8182	3,3766
343	Asesoría, 1I SHV *, 1A BABA N	1A AMZN *	0,1077	0,8485	4,1624
440	Asesoría, 1I SHV *, 1A AMZN *, 1A GOOG *	1A FB *	0,1154	0,9375	3,8690
275	Asesoría, 1I SHV *, 1A AMZN *	1A BABA N	0,1077	0,7778	3,7449
325	Asesoría, 1I SHV *, 1A AMZN *	1A FB *, 1A GOOG *	0,1154	0,8333	5,0388
370	Asesoría, 1I SHV *, 1A AMZN *	1A FB *	0,1231	0,8889	3,6684
371	Asesoría, 1I SHV *, 1A AMZN *	1A GOOG *	0,1231	0,8889	4,4444
123	Asesoría, 1I EUFN *	1I EPI *	0,1115	0,6591	5,5279
437	Asesoría, 1I EPI *	1I EUFN *	0,1115	0,9355	5,4050
135	Asesoría, 1A GOOG *	1A FB *, 1A BABA N	0,1000	0,6667	4,1270
137	Asesoría, 1A GOOG *	1A FB *, 1A BABA N, 1A AMZN *	0,1000	0,6667	4,5614
168	Asesoría, 1A GOOG *	1A BABA N	0,1038	0,6923	3,3333
174	Asesoría, 1A GOOG *	1A BABA N, 1A AMZN *	0,1038	0,6923	4,3902
261	Asesoría, 1A GOOG *	1I SHV *, 1A FB *	0,1154	0,7692	3,4483



263	Asesoría, 1A GOOG *	1I SHV *, 1A FB *, 1A AMZN *	0,1154	0,7692	4,6512
311	Asesoría, 1A GOOG *	1I SHV *, 1A AMZN *	0,1231	0,8205	4,5390
337	Asesoría, 1A GOOG *	1A FB *	0,1269	0,8462	3,4921
339	Asesoría, 1A GOOG *	1A FB *, 1A AMZN *	0,1269	0,8462	4,5833
387	Asesoría, 1A GOOG *	1A AMZN *	0,1346	0,8974	4,4025
280	Asesoría, 1A FB *, 1A GOOG *	1A BABA N	0,1000	0,7879	3,7935
281	Asesoría, 1A FB *, 1A GOOG *	1A BABA N, 1A AMZN *	0,1000	0,7879	4,9963
404	Asesoría, 1A FB *, 1A GOOG *	1I SHV *, 1A AMZN *	0,1154	0,9091	5,0290
486	Asesoría, 1A FB *, 1A GOOG *	1A AMZN *	0,1269	1,0000	4,9057
489	Asesoría, 1A FB *, 1A BABA N, 1A GOOG *	1A AMZN *	0,1000	1,0000	4,9057
458	Asesoría, 1A FB *, 1A BABA N, 1A AMZN *	1A GOOG *	0,1000	0,9630	4,8148
382	Asesoría, 1A FB *, 1A BABA N	1A GOOG *	0,1000	0,8966	4,4828
383	Asesoría, 1A FB *, 1A BABA N	1A AMZN *, 1A GOOG *	0,1000	0,8966	5,2978
431	Asesoría, 1A FB *, 1A BABA N	1A AMZN *	0,1038	0,9310	4,5673
282	Asesoría, 1A FB *, 1A AMZN *, 1A GOOG *	1A BABA N	0,1000	0,7879	3,7935
227	Asesoría, 1A FB *, 1A AMZN *	1A BABA N, 1A GOOG *	0,1000	0,7429	5,2201
265	Asesoría, 1A FB *, 1A AMZN *	1A BABA N	0,1038	0,7714	3,7143
351	Asesoría, 1A FB *, 1A AMZN *	1I SHV *, 1A GOOG *	0,1154	0,8571	4,7416
441	Asesoría, 1A FB *, 1A AMZN *	1A GOOG *	0,1269	0,9429	4,7143
73	Asesoría, 1A FB *	1A BABA N, 1A GOOG *	0,1000	0,6047	4,2489
75	Asesoría, 1A FB *	1A BABA N, 1A AMZN *, 1A GOOG *	0,1000	0,6047	4,3669
92	Asesoría, 1A FB *	1I SHV *, 1A BABA N	0,1038	0,6279	3,5490
93	Asesoría, 1A FB *	1A BABA N, 1A AMZN *	0,1038	0,6279	3,9818
144	Asesoría, 1A FB *	1A BABA N	0,1115	0,6744	3,2472
175	Asesoría, 1A FB *	1I SHV *, 1A GOOG *	0,1154	0,6977	3,8595
177	Asesoría, 1A FB *	1I SHV *, 1A AMZN *, 1A GOOG *	0,1154	0,6977	4,4243
230	Asesoría, 1A FB *	1I SHV *, 1A AMZN *	0,1231	0,7442	4,1168
253	Asesoría, 1A FB *	1A GOOG *	0,1269	0,7674	3,8372



255	Asesoría, 1A FB *	1A AMZN *, 1A GOOG *	0,1269	0,7674	4,5349
304	Asesoría, 1A FB *	1A AMZN *	0,1346	0,8140	3,9930
457	Asesoría, 1A BABA N, 1A GOOG *	1A FB *	0,1000	0,9630	3,9741
459	Asesoría, 1A BABA N, 1A GOOG *	1A FB *, 1A AMZN *	0,1000	0,9630	5,2160
487	Asesoría, 1A BABA N, 1A GOOG *	1A AMZN *	0,1038	1,0000	4,9057
460	Asesoría, 1A BABA N, 1A AMZN *, 1A GOOG *	1A FB *	0,1000	0,9630	3,9741
355	Asesoría, 1A BABA N, 1A AMZN *	1A FB *, 1A GOOG *	0,1000	0,8667	5,2403
391	Asesoría, 1A BABA N, 1A AMZN *	1A FB *	0,1038	0,9000	3,7143
392	Asesoría, 1A BABA N, 1A AMZN *	1A GOOG *	0,1038	0,9000	4,5000
115	Asesoría, 1A BABA N	1A FB *, 1A GOOG *	0,1000	0,6500	3,9302
116	Asesoría, 1A BABA N	1A FB *, 1A AMZN *, 1A GOOG *	0,1000	0,6500	4,0238
145	Asesoría, 1A BABA N	1A GOOG *	0,1038	0,6750	3,3750
147	Asesoría, 1A BABA N	1I SHV *, 1A FB *	0,1038	0,6750	3,0259
148	Asesoría, 1A BABA N	1A FB *, 1A AMZN *	0,1038	0,6750	3,6563
149	Asesoría, 1A BABA N	1A AMZN *, 1A GOOG *	0,1038	0,6750	3,9886
182	Asesoría, 1A BABA N	1I SHV *, 1A AMZN *	0,1077	0,7000	3,8723
209	Asesoría, 1A BABA N	1A FB *	0,1115	0,7250	2,9921
237	Asesoría, 1A BABA N	1A AMZN *	0,1154	0,7500	3,6792
228	Asesoría, 1A AMZN *, 1A GOOG *	1A FB *, 1A BABA N	0,1000	0,7429	4,5986
266	Asesoría, 1A AMZN *, 1A GOOG *	1A BABA N	0,1038	0,7714	3,7143
353	Asesoría, 1A AMZN *, 1A GOOG *	1I SHV *, 1A FB *	0,1154	0,8571	3,8424
442	Asesoría, 1A AMZN *, 1A GOOG *	1A FB *	0,1269	0,9429	3,8912
136	Asesoría, 1A AMZN *	1A FB *, 1A BABA N, 1A GOOG *	0,1000	0,6667	4,8148
172	Asesoría, 1A AMZN *	1A FB *, 1A BABA N	0,1038	0,6923	4,2857
173	Asesoría, 1A AMZN *	1A BABA N, 1A GOOG *	0,1038	0,6923	4,8649
199	Asesoría, 1A AMZN *	1I SHV *, 1A BABA N	0,1077	0,7179	4,0580
259	Asesoría, 1A AMZN *	1A BABA N	0,1154	0,7692	3,7037
262	Asesoría, 1A AMZN *	1I SHV *, 1A FB *, 1A GOOG *	0,1154	0,7692	5,0000



309	Asesoría, 1A AMZN *	1I SHV *, 1A FB *	0,1231	0,8205	3,6782
310	Asesoría, 1A AMZN *	1I SHV *, 1A GOOG *	0,1231	0,8205	4,5390
338	Asesoría, 1A AMZN *	1A FB *, 1A GOOG *	0,1269	0,8462	5,1163
385	Asesoría, 1A AMZN *	1A FB *	0,1346	0,8974	3,7037
386	Asesoría, 1A AMZN *	1A GOOG *	0,1346	0,8974	4,4872
181	1I VGK *	1I SHV *, 1A BABA N	0,1077	0,7000	3,9565
208	1I VGK *	1A BABA N	0,1115	0,7250	3,4907
72	1I TIP *	1I SHV *, 1A FB *	0,1000	0,6047	2,7105
117	1I TIP *	1A FB *	0,1077	0,6512	2,6873
274	1I SHV *, 1I VGK *	1A BABA N	0,1077	0,7778	3,7449
160	1I SHV *, 1I TIP *	1A FB *	0,1000	0,6842	2,8237
483	1I SHV *, 1I IUIT N	1I IUHC N	0,1000	1,0000	8,1250
354	1I SHV *, 1I IUHC N	1I IUIT N	0,1000	0,8667	7,7701
390	1I SHV *, 1I IUHC N	1I IUFS N	0,1038	0,9000	7,5484
462	1I SHV *, 1I IUFS N	1I IUHC N	0,1038	0,9643	7,8348
102	1I SHV *, 1A GOOG *	Asesoría, 1A FB *	0,1154	0,6383	3,8595
104	1I SHV *, 1A GOOG *	Asesoría, 1A FB *, 1A AMZN *	0,1154	0,6383	4,7416
154	1I SHV *, 1A GOOG *	Asesoría, 1A AMZN *	0,1231	0,6809	4,5390
184	1I SHV *, 1A GOOG *	1A FB *, 1A BABA N, 1A AMZN *	0,1269	0,7021	4,8040
205	1I SHV *, 1A GOOG *	1A FB *, 1A BABA N	0,1308	0,7234	4,4782
207	1I SHV *, 1A GOOG *	1A BABA N, 1A AMZN *	0,1308	0,7234	4,5874
233	1I SHV *, 1A GOOG *	1A BABA N	0,1346	0,7447	3,5855
319	1I SHV *, 1A GOOG *	1A FB *, 1A AMZN *	0,1500	0,8298	4,4947
345	1I SHV *, 1A GOOG *	1A FB *	0,1538	0,8511	3,5123
363	1I SHV *, 1A GOOG *	1A AMZN *	0,1577	0,8723	4,2794
244	1I SHV *, 1A FB *, 1A GOOG *	Asesoría, 1A AMZN *	0,1154	0,7500	5,0000
313	1I SHV *, 1A FB *, 1A GOOG *	1A BABA N, 1A AMZN *	0,1269	0,8250	5,2317
344	1I SHV *, 1A FB *, 1A GOOG *	1A BABA N	0,1308	0,8500	4,0926
475	1I SHV *, 1A FB *, 1A GOOG *	1A AMZN *	0,1500	0,9750	4,7830
466	1I SHV *, 1A FB *, 1A BABA N, 1A GOOG *	1A AMZN *	0,1269	0,9706	4,7614
443	1I SHV *, 1A FB *, 1A BABA N, 1A AMZN *	1A GOOG *	0,1269	0,9429	4,7143
340	1I SHV *, 1A FB *, 1A BABA N	1A AMZN *, 1A GOOG *	0,1269	0,8462	5,0000
361	1I SHV *, 1A FB *, 1A BABA N	1A GOOG *	0,1308	0,8718	4,3590
388	1I SHV *, 1A FB *, 1A BABA N	1A AMZN *	0,1346	0,8974	4,4025



341	1I SHV *, 1A FB *, 1A AMZN *, 1A GOOG *	1A BABA N	0,1269	0,8462	4,0741
178	1I SHV *, 1A FB *, 1A AMZN *	Asesoría, 1A GOOG *	0,1154	0,6977	4,6512
257	1I SHV *, 1A FB *, 1A AMZN *	1A BABA N, 1A GOOG *	0,1269	0,7674	5,3928
305	1I SHV *, 1A FB *, 1A AMZN *	1A BABA N	0,1346	0,8140	3,9190
401	1I SHV *, 1A FB *, 1A AMZN *	1A GOOG *	0,1500	0,9070	4,5349
12	1I SHV *, 1A FB *	1I TIP *	0,1000	0,4483	2,7105
14	1I SHV *, 1A FB *	Asesoría, 1A BABA N	0,1038	0,4655	3,0259
21	1I SHV *, 1A FB *	1A AAPL *	0,1077	0,4828	2,9885
34	1I SHV *, 1A FB *	Asesoría, 1A GOOG *	0,1154	0,5172	3,4483
35	1I SHV *, 1A FB *	Asesoría, 1A AMZN *, 1A GOOG *	0,1154	0,5172	3,8424
49	1I SHV *, 1A FB *	Asesoría, 1A AMZN *	0,1231	0,5517	3,6782
58	1I SHV *, 1A FB *	1A BABA N, 1A AMZN *, 1A GOOG *	0,1269	0,5690	4,1092
63	1I SHV *, 1A FB *	1A BABA N, 1A GOOG *	0,1308	0,5862	4,1193
69	1I SHV *, 1A FB *	1A BABA N, 1A AMZN *	0,1346	0,6034	3,8267
138	1I SHV *, 1A FB *	1A BABA N	0,1500	0,6724	3,2375
139	1I SHV *, 1A FB *	1A AMZN *, 1A GOOG *	0,1500	0,6724	3,9734
166	1I SHV *, 1A FB *	1A GOOG *	0,1538	0,6897	3,4483
226	1I SHV *, 1A FB *	1A AMZN *	0,1654	0,7414	3,6370
444	1I SHV *, 1A BABA N, 1A GOOG *	1A FB *, 1A AMZN *	0,1269	0,9429	5,1071
469	1I SHV *, 1A BABA N, 1A GOOG *	1A FB *	0,1308	0,9714	4,0091
470	1I SHV *, 1A BABA N, 1A GOOG *	1A AMZN *	0,1308	0,9714	4,7655
467	1I SHV *, 1A BABA N, 1A AMZN *, 1A GOOG *	1A FB *	0,1269	0,9706	4,0056
356	1I SHV *, 1A BABA N, 1A AMZN *	1A FB *, 1A GOOG *	0,1269	0,8684	5,2509
373	1I SHV *, 1A BABA N, 1A AMZN *	1A GOOG *	0,1308	0,8947	4,4737
415	1I SHV *, 1A BABA N, 1A AMZN *	1A FB *	0,1346	0,9211	3,8012
64	1I SHV *, 1A BABA N	Asesoría, 1A FB *	0,1038	0,5870	3,5490
77	1I SHV *, 1A BABA N	1I VGK *	0,1077	0,6087	3,9565
78	1I SHV *, 1A BABA N	Asesoría, 1A AMZN *	0,1077	0,6087	4,0580



198	1I SHV *, 1A BABA N	1A FB *, 1A AMZN *, 1A GOOG *	0,1269	0,7174	4,4410
223	1I SHV *, 1A BABA N	1A FB *, 1A GOOG *	0,1308	0,7391	4,4692
224	1I SHV *, 1A BABA N	1A AMZN *, 1A GOOG *	0,1308	0,7391	4,3676
249	1I SHV *, 1A BABA N	1A GOOG *	0,1346	0,7609	3,8043
250	1I SHV *, 1A BABA N	1A FB *, 1A AMZN *	0,1346	0,7609	4,1214
314	1I SHV *, 1A BABA N	1A AMZN *	0,1462	0,8261	4,0525
342	1I SHV *, 1A BABA N	1A FB *	0,1500	0,8478	3,4990
217	1I SHV *, 1A AMZN *, 1A GOOG *	Asesoría, 1A FB *	0,1154	0,7317	4,4243
293	1I SHV *, 1A AMZN *, 1A GOOG *	1A FB *, 1A BABA N	0,1269	0,8049	4,9826
317	1I SHV *, 1A AMZN *, 1A GOOG *	1A BABA N	0,1308	0,8293	3,9928
451	1I SHV *, 1A AMZN *, 1A GOOG *	1A FB *	0,1500	0,9512	3,9257
67	1I SHV *, 1A AMZN *	Asesoría, 1A BABA N	0,1077	0,5957	3,8723
103	1I SHV *, 1A AMZN *	Asesoría, 1A FB *, 1A GOOG *	0,1154	0,6383	5,0290
152	1I SHV *, 1A AMZN *	Asesoría, 1A FB *	0,1231	0,6809	4,1168
153	1I SHV *, 1A AMZN *	Asesoría, 1A GOOG *	0,1231	0,6809	4,5390
183	1I SHV *, 1A AMZN *	1A FB *, 1A BABA N, 1A GOOG *	0,1269	0,7021	5,0709
206	1I SHV *, 1A AMZN *	1A BABA N, 1A GOOG *	0,1308	0,7234	5,0834
234	1I SHV *, 1A AMZN *	1A FB *, 1A BABA N	0,1346	0,7447	4,6099
296	1I SHV *, 1A AMZN *	1A BABA N	0,1462	0,8085	3,8928
318	1I SHV *, 1A AMZN *	1A FB *, 1A GOOG *	0,1500	0,8298	5,0173
362	1I SHV *, 1A AMZN *	1A GOOG *	0,1577	0,8723	4,3617
409	1I SHV *, 1A AMZN *	1A FB *	0,1654	0,9149	3,7758
290	1I SHV *, 1A AAPL *	1A FB *	0,1077	0,8000	3,3016
485	1I IUIT N, 1I IMEA N	1I IUHC N	0,1000	1,0000	8,1250
376	1I IUIT N	1I CSPX N	0,1000	0,8966	7,5195
377	1I IUIT N	1I IUFS N	0,1000	0,8966	7,5195
378	1I IUIT N	1I IMEA N	0,1000	0,8966	8,6335
379	1I IUIT N	1I SHV *, 1I IUHC N	0,1000	0,8966	7,7701
380	1I IUIT N	1I IUHC N, 1I CSPX N	0,1000	0,8966	8,6335
381	1I IUIT N	1I IUHC N, 1I IMEA N	0,1000	0,8966	8,6335
464	1I IUIT N	1I IUHC N	0,1077	0,9655	7,8448
424	1I IUHC N, 1I IUIT N	1I CSPX N	0,1000	0,9286	7,7880
425	1I IUHC N, 1I IUIT N	1I IMEA N	0,1000	0,9286	8,9418
456	1I IUHC N, 1I IMEA N	1I IUIT N	0,1000	0,9630	8,6335
454	1I IUHC N, 1I CSPX N	1I IUIT N	0,1000	0,9630	8,6335



300	1I IUHC N	1I SHV *, 1I IUIT N	0,1000	0,8125	8,1250
301	1I IUHC N	1I CSPX N, 1I IUIT N	0,1000	0,8125	8,1250
302	1I IUHC N	1I IUIT N, 1I IMEA N	0,1000	0,8125	8,1250
333	1I IUHC N	1I CSPX N	0,1038	0,8438	7,0766
334	1I IUHC N	1I IMEA N	0,1038	0,8438	8,1250
335	1I IUHC N	1I SHV *, 1I IUFS N	0,1038	0,8438	7,8348
364	1I IUHC N	1I IUIT N	0,1077	0,8750	7,8448
400	1I IUHC N	1I IUFS N	0,1115	0,9063	7,6008
330	1I IUFS N	1I IUIT N	0,1000	0,8387	7,5195
359	1I IUFS N	1I SHV *, 1I IUHC N	0,1038	0,8710	7,5484
435	1I IUFS N	1I IUHC N	0,1115	0,9355	7,6008
453	1I IMEA N	1I IUIT N	0,1000	0,9630	8,6335
455	1I IMEA N	1I IUHC N, 1I IUIT N	0,1000	0,9630	8,9418
481	1I IMEA N	1I IUHC N	0,1038	1,0000	8,1250
109	1I EUFN *	1I EPI *	0,1115	0,6444	5,4050
110	1I EUFN *	Asesoría, 1I EPI *	0,1115	0,6444	5,4050
434	1I EPI *	1I EUFN *	0,1115	0,9355	5,4050
436	1I EPI *	Asesoría, 1I EUFN *	0,1115	0,9355	5,5279
484	1I CSPX N, 1I IUIT N	1I IUHC N	0,1000	1,0000	8,1250
329	1I CSPX N	1I IUIT N	0,1000	0,8387	7,5195
331	1I CSPX N	1I IUHC N, 1I IUIT N	0,1000	0,8387	7,7880
358	1I CSPX N	1I IUHC N	0,1038	0,8710	7,0766
27	1A GOOG *	Asesoría, 1A FB *, 1A BABA N	0,1000	0,5000	4,4828
29	1A GOOG *	Asesoría, 1A FB *, 1A BABA N, 1A AMZN *	0,1000	0,5000	4,8148
38	1A GOOG *	Asesoría, 1A BABA N	0,1038	0,5192	3,3750
39	1A GOOG *	Asesoría, 1A BABA N, 1A AMZN *	0,1038	0,5192	4,5000
61	1A GOOG *	Asesoría, 1I SHV *, 1A FB *	0,1154	0,5769	3,7500
62	1A GOOG *	Asesoría, 1I SHV *, 1A FB *, 1A AMZN *	0,1154	0,5769	4,6875
82	1A GOOG *	Asesoría, 1I SHV *, 1A AMZN *	0,1231	0,6154	4,4444
97	1A GOOG *	Asesoría, 1A FB *	0,1269	0,6346	3,8372
98	1A GOOG *	Asesoría, 1A FB *, 1A AMZN *	0,1269	0,6346	4,7143
99	1A GOOG *	1I SHV *, 1A FB *, 1A BABA N, 1A AMZN *	0,1269	0,6346	4,7143
118	1A GOOG *	1I SHV *, 1A FB *, 1A BABA N	0,1308	0,6538	4,3590



119	1A GOOG *	1I SHV *, 1A BABA N, 1A AMZN *	0,1308	0,6538	4,4737
141	1A GOOG *	Asesoría, 1A AMZN *	0,1346	0,6731	4,4872
142	1A GOOG *	1I SHV *, 1A BABA N	0,1346	0,6731	3,8043
143	1A GOOG *	1A FB *, 1A BABA N, 1A AMZN *	0,1346	0,6731	4,6053
169	1A GOOG *	1A FB *, 1A BABA N	0,1385	0,6923	4,2857
170	1A GOOG *	1A BABA N, 1A AMZN *	0,1385	0,6923	4,3902
193	1A GOOG *	1A BABA N	0,1423	0,7115	3,4259
242	1A GOOG *	1I SHV *, 1A FB *, 1A AMZN *	0,1500	0,7500	4,5349
260	1A GOOG *	1I SHV *, 1A FB *	0,1538	0,7692	3,4483
283	1A GOOG *	1I SHV *, 1A AMZN *	0,1577	0,7885	4,3617
294	1A GOOG *	1A FB *, 1A AMZN *	0,1615	0,8077	4,3750
315	1A GOOG *	1A FB *	0,1654	0,8269	3,4127
336	1A GOOG *	1A AMZN *	0,1692	0,8462	4,1509
74	1A FB *, 1A GOOG *	Asesoría, 1A BABA N	0,1000	0,6047	3,9302
76	1A FB *, 1A GOOG *	Asesoría, 1A BABA N, 1A AMZN *	0,1000	0,6047	5,2403
179	1A FB *, 1A GOOG *	Asesoría, 1I SHV *, 1A AMZN *	0,1154	0,6977	5,0388
256	1A FB *, 1A GOOG *	Asesoría, 1A AMZN *	0,1269	0,7674	5,1163
258	1A FB *, 1A GOOG *	1I SHV *, 1A BABA N, 1A AMZN *	0,1269	0,7674	5,2509
284	1A FB *, 1A GOOG *	1I SHV *, 1A BABA N	0,1308	0,7907	4,4692
306	1A FB *, 1A GOOG *	1A BABA N, 1A AMZN *	0,1346	0,8140	5,1617
326	1A FB *, 1A GOOG *	1A BABA N	0,1385	0,8372	4,0310
402	1A FB *, 1A GOOG *	1I SHV *, 1A AMZN *	0,1500	0,9070	5,0173
476	1A FB *, 1A GOOG *	1A AMZN *	0,1615	0,9767	4,7916
202	1A FB *, 1A BABA N, 1A GOOG *	Asesoría, 1A AMZN *	0,1000	0,7222	4,8148
410	1A FB *, 1A BABA N, 1A GOOG *	1I SHV *, 1A AMZN *	0,1269	0,9167	5,0709
471	1A FB *, 1A BABA N, 1A GOOG *	1A AMZN *	0,1346	0,9722	4,7694
161	1A FB *, 1A BABA N, 1A AMZN *	Asesoría, 1A GOOG *	0,1000	0,6842	4,5614
357	1A FB *, 1A BABA N, 1A AMZN *	1I SHV *, 1A GOOG *	0,1269	0,8684	4,8040
417	1A FB *, 1A BABA N, 1A AMZN *	1A GOOG *	0,1346	0,9211	4,6053
85	1A FB *, 1A BABA N	Asesoría, 1A GOOG *	0,1000	0,6190	4,1270



87	1A FB *, 1A BABA N	Asesoría, 1A AMZN *, 1A GOOG *	0,1000	0,6190	4,5986
108	1A FB *, 1A BABA N	Asesoría, 1A AMZN *	0,1038	0,6429	4,2857
278	1A FB *, 1A BABA N	1I SHV *, 1A AMZN *, 1A GOOG *	0,1269	0,7857	4,9826
297	1A FB *, 1A BABA N	1I SHV *, 1A GOOG *	0,1308	0,8095	4,4782
322	1A FB *, 1A BABA N	1I SHV *, 1A AMZN *	0,1346	0,8333	4,6099
323	1A FB *, 1A BABA N	1A AMZN *, 1A GOOG *	0,1346	0,8333	4,9242
349	1A FB *, 1A BABA N	1A GOOG *	0,1385	0,8571	4,2857
397	1A FB *, 1A BABA N	1A AMZN *	0,1462	0,9048	4,4385
88	1A FB *, 1A AMZN *, 1A GOOG *	Asesoría, 1A BABA N	0,1000	0,6190	4,0238
279	1A FB *, 1A AMZN *, 1A GOOG *	1I SHV *, 1A BABA N	0,1269	0,7857	4,4410
324	1A FB *, 1A AMZN *, 1A GOOG *	1A BABA N	0,1346	0,8333	4,0123
48	1A FB *, 1A AMZN *	Asesoría, 1A BABA N, 1A GOOG *	0,1000	0,5417	5,2160
54	1A FB *, 1A AMZN *	1A AAPL *	0,1038	0,5625	3,4821
55	1A FB *, 1A AMZN *	Asesoría, 1A BABA N	0,1038	0,5625	3,6563
91	1A FB *, 1A AMZN *	Asesoría, 1I SHV *, 1A GOOG *	0,1154	0,6250	4,6429
163	1A FB *, 1A AMZN *	Asesoría, 1A GOOG *	0,1269	0,6875	4,5833
164	1A FB *, 1A AMZN *	1I SHV *, 1A BABA N, 1A GOOG *	0,1269	0,6875	5,1071
212	1A FB *, 1A AMZN *	1I SHV *, 1A BABA N	0,1346	0,7292	4,1214
213	1A FB *, 1A AMZN *	1A BABA N, 1A GOOG *	0,1346	0,7292	5,1239
285	1A FB *, 1A AMZN *	1A BABA N	0,1462	0,7917	3,8117
303	1A FB *, 1A AMZN *	1I SHV *, 1A GOOG *	0,1500	0,8125	4,4947
365	1A FB *, 1A AMZN *	1A GOOG *	0,1615	0,8750	4,3750
360	1A FB *, 1A AAPL *	1A AMZN *	0,1038	0,8710	4,2727
4	1A FB *	1I SHV *, 1I TIP *	0,1000	0,4127	2,8237
5	1A FB *	Asesoría, 1A BABA N, 1A GOOG *	0,1000	0,4127	3,9741
6	1A FB *	Asesoría, 1A BABA N, 1A AMZN *, 1A GOOG *	0,1000	0,4127	3,9741
7	1A FB *	1A AMZN *, 1A AAPL *	0,1038	0,4286	3,9796
8	1A FB *	Asesoría, 1I SHV *, 1A BABA N	0,1038	0,4286	3,3766
9	1A FB *	Asesoría, 1A BABA N, 1A AMZN *	0,1038	0,4286	3,7143
10	1A FB *	1I TIP *	0,1077	0,4444	2,6873



11	1A FB *	1I SHV *, 1A AAPL *	0,1077	0,4444	3,3016
13	1A FB *	Asesoría, 1A BABA N	0,1115	0,4603	2,9921
15	1A FB *	Asesoría, 1I SHV *, 1A GOOG *	0,1154	0,4762	3,5374
16	1A FB *	Asesoría, 1I SHV *, 1A AMZN *, 1A GOOG *	0,1154	0,4762	3,8690
23	1A FB *	1A AAPL *	0,1192	0,4921	3,0461
30	1A FB *	Asesoría, 1I SHV *, 1A AMZN *	0,1231	0,5079	3,6684
40	1A FB *	Asesoría, 1A GOOG *	0,1269	0,5238	3,4921
41	1A FB *	Asesoría, 1A AMZN *, 1A GOOG *	0,1269	0,5238	3,8912
42	1A FB *	1I SHV *, 1A BABA N, 1A AMZN *, 1A GOOG *	0,1269	0,5238	4,0056
47	1A FB *	1I SHV *, 1A BABA N, 1A GOOG *	0,1308	0,5397	4,0091
50	1A FB *	Asesoría, 1A AMZN *	0,1346	0,5556	3,7037
52	1A FB *	1I SHV *, 1A BABA N, 1A AMZN *	0,1346	0,5556	3,8012
53	1A FB *	1A BABA N, 1A AMZN *, 1A GOOG *	0,1346	0,5556	4,0123
59	1A FB *	1A BABA N, 1A GOOG *	0,1385	0,5714	4,0154
68	1A FB *	1A BABA N, 1A AMZN *	0,1462	0,6032	3,8250
84	1A FB *	1I SHV *, 1A BABA N	0,1500	0,6190	3,4990
86	1A FB *	1I SHV *, 1A AMZN *, 1A GOOG *	0,1500	0,6190	3,9257
101	1A FB *	1I SHV *, 1A GOOG *	0,1538	0,6349	3,5123
128	1A FB *	1A BABA N	0,1615	0,6667	3,2099
132	1A FB *	1A AMZN *, 1A GOOG *	0,1615	0,6667	3,9394
157	1A FB *	1A GOOG *	0,1654	0,6825	3,4127
158	1A FB *	1I SHV *, 1A AMZN *	0,1654	0,6825	3,7758
251	1A FB *	1A AMZN *	0,1846	0,7619	3,7376
114	1A BAC *	1A BABA N	0,1000	0,6500	3,1296
185	1A BABA N, 1A GOOG *	Asesoría, 1A FB *	0,1000	0,7027	4,2489
186	1A BABA N, 1A GOOG *	Asesoría, 1A FB *, 1A AMZN *	0,1000	0,7027	5,2201
215	1A BABA N, 1A GOOG *	Asesoría, 1A AMZN *	0,1038	0,7297	4,8649
372	1A BABA N, 1A GOOG *	1I SHV *, 1A FB *, 1A AMZN *	0,1269	0,8919	5,3928
412	1A BABA N, 1A GOOG *	1I SHV *, 1A FB *	0,1308	0,9189	4,1193
413	1A BABA N, 1A GOOG *	1I SHV *, 1A AMZN *	0,1308	0,9189	5,0834
449	1A BABA N, 1A GOOG *	1A FB *, 1A AMZN *	0,1346	0,9459	5,1239



473	1A BABA N, 1A GOOG *	1A FB *	0,1385	0,9730	4,0154
474	1A BABA N, 1A GOOG *	1A AMZN *	0,1385	0,9730	4,7731
203	1A BABA N, 1A AMZN *, 1A GOOG *	Asesoría, 1A FB *	0,1000	0,7222	4,3669
411	1A BABA N, 1A AMZN *, 1A GOOG *	1I SHV *, 1A FB *	0,1269	0,9167	4,1092
472	1A BABA N, 1A AMZN *, 1A GOOG *	1A FB *	0,1346	0,9722	4,0123
96	1A BABA N, 1A AMZN *	Asesoría, 1A FB *, 1A GOOG *	0,1000	0,6341	4,9963
120	1A BABA N, 1A AMZN *	Asesoría, 1A FB *	0,1038	0,6585	3,9818
121	1A BABA N, 1A AMZN *	Asesoría, 1A GOOG *	0,1038	0,6585	4,3902
292	1A BABA N, 1A AMZN *	1I SHV *, 1A FB *, 1A GOOG *	0,1269	0,8049	5,2317
316	1A BABA N, 1A AMZN *	1I SHV *, 1A GOOG *	0,1308	0,8293	4,5874
347	1A BABA N, 1A AMZN *	1I SHV *, 1A FB *	0,1346	0,8537	3,8267
348	1A BABA N, 1A AMZN *	1A FB *, 1A GOOG *	0,1346	0,8537	5,1617
366	1A BABA N, 1A AMZN *	1A GOOG *	0,1385	0,8780	4,3902
420	1A BABA N, 1A AMZN *	1A FB *	0,1462	0,9268	3,8250
17	1A BABA N	1A AAPL *	0,1000	0,4815	2,9806
18	1A BABA N	1A BAC *	0,1000	0,4815	3,1296
19	1A BABA N	Asesoría, 1A FB *, 1A GOOG *	0,1000	0,4815	3,7935
20	1A BABA N	Asesoría, 1A FB *, 1A AMZN *, 1A GOOG *	0,1000	0,4815	3,7935
24	1A BABA N	Asesoría, 1A GOOG *	0,1038	0,5000	3,3333
25	1A BABA N	Asesoría, 1I SHV *, 1A FB *	0,1038	0,5000	3,2500
26	1A BABA N	Asesoría, 1A FB *, 1A AMZN *	0,1038	0,5000	3,7143
28	1A BABA N	Asesoría, 1A AMZN *, 1A GOOG *	0,1038	0,5000	3,7143
36	1A BABA N	1I SHV *, 1I VGK *	0,1077	0,5185	3,7449
37	1A BABA N	Asesoría, 1I SHV *, 1A AMZN *	0,1077	0,5185	3,7449
45	1A BABA N	1I VGK *	0,1115	0,5370	3,4907
46	1A BABA N	Asesoría, 1A FB *	0,1115	0,5370	3,2472
51	1A BABA N	Asesoría, 1A AMZN *	0,1154	0,5556	3,7037
80	1A BABA N	1I SHV *, 1A FB *, 1A AMZN *, 1A GOOG *	0,1269	0,6111	4,0741
94	1A BABA N	1I SHV *, 1A FB *, 1A GOOG *	0,1308	0,6296	4,0926



95	1A BABA N	1I SHV *, 1A AMZN *, 1A GOOG *	0,1308	0,6296	3,9928
111	1A BABA N	1I SHV *, 1A GOOG *	0,1346	0,6481	3,5855
112	1A BABA N	1I SHV *, 1A FB *, 1A AMZN *	0,1346	0,6481	3,9190
113	1A BABA N	1A FB *, 1A AMZN *, 1A GOOG *	0,1346	0,6481	4,0123
131	1A BABA N	1A FB *, 1A GOOG *	0,1385	0,6667	4,0310
133	1A BABA N	1A AMZN *, 1A GOOG *	0,1385	0,6667	3,9394
162	1A BABA N	1A GOOG *	0,1423	0,6852	3,4259
187	1A BABA N	1I SHV *, 1A AMZN *	0,1462	0,7037	3,8928
188	1A BABA N	1A FB *, 1A AMZN *	0,1462	0,7037	3,8117
200	1A BABA N	1I SHV *, 1A FB *	0,1500	0,7222	3,2375
248	1A BABA N	1A AMZN *	0,1577	0,7593	3,7247
273	1A BABA N	1A FB *	0,1615	0,7778	3,2099
65	1A AMZN *, 1A GOOG *	Asesoría, 1A FB *, 1A BABA N	0,1000	0,5909	5,2978
81	1A AMZN *, 1A GOOG *	Asesoría, 1A BABA N	0,1038	0,6136	3,9886
155	1A AMZN *, 1A GOOG *	Asesoría, 1I SHV *, 1A FB *	0,1154	0,6818	4,4318
240	1A AMZN *, 1A GOOG *	Asesoría, 1A FB *	0,1269	0,7500	4,5349
245	1A AMZN *, 1A GOOG *	1I SHV *, 1A FB *, 1A BABA N	0,1269	0,7500	5,0000
268	1A AMZN *, 1A GOOG *	1I SHV *, 1A BABA N	0,1308	0,7727	4,3676
289	1A AMZN *, 1A GOOG *	1A FB *, 1A BABA N	0,1346	0,7955	4,9242
307	1A AMZN *, 1A GOOG *	1A BABA N	0,1385	0,8182	3,9394
368	1A AMZN *, 1A GOOG *	1I SHV *, 1A FB *	0,1500	0,8864	3,9734
452	1A AMZN *, 1A GOOG *	1A FB *	0,1615	0,9545	3,9394
463	1A AMZN *, 1A AAPL *	1A FB *	0,1038	0,9643	3,9796
22	1A AMZN *	Asesoría, 1A FB *, 1A BABA N, 1A GOOG *	0,1000	0,4906	4,9057
31	1A AMZN *	1A FB *, 1A AAPL *	0,1038	0,5094	4,2727
32	1A AMZN *	Asesoría, 1A FB *, 1A BABA N	0,1038	0,5094	4,5673
33	1A AMZN *	Asesoría, 1A BABA N, 1A GOOG *	0,1038	0,5094	4,9057
43	1A AMZN *	1A AAPL *	0,1077	0,5283	3,2704
44	1A AMZN *	Asesoría, 1I SHV *, 1A BABA N	0,1077	0,5283	4,1624
56	1A AMZN *	Asesoría, 1A BABA N	0,1154	0,5660	3,6792
57	1A AMZN *	Asesoría, 1I SHV *, 1A FB *, 1A GOOG *	0,1154	0,5660	4,9057



70	1A AMZN *	Asesoría, 1I SHV *, 1A FB *	0,1231	0,6038	3,9245
71	1A AMZN *	Asesoría, 1I SHV *, 1A GOOG *	0,1231	0,6038	4,4852
89	1A AMZN *	Asesoría, 1A FB *, 1A GOOG *	0,1269	0,6226	4,9057
90	1A AMZN *	1I SHV *, 1A FB *, 1A BABA N, 1A GOOG *	0,1269	0,6226	4,7614
105	1A AMZN *	1I SHV *, 1A BABA N, 1A GOOG *	0,1308	0,6415	4,7655
124	1A AMZN *	Asesoría, 1A FB *	0,1346	0,6604	3,9930
125	1A AMZN *	Asesoría, 1A GOOG *	0,1346	0,6604	4,4025
126	1A AMZN *	1I SHV *, 1A FB *, 1A BABA N	0,1346	0,6604	4,4025
127	1A AMZN *	1A FB *, 1A BABA N, 1A GOOG *	0,1346	0,6604	4,7694
151	1A AMZN *	1A BABA N, 1A GOOG *	0,1385	0,6792	4,7731
195	1A AMZN *	1I SHV *, 1A BABA N	0,1462	0,7170	4,0525
196	1A AMZN *	1A FB *, 1A BABA N	0,1462	0,7170	4,4385
219	1A AMZN *	1I SHV *, 1A FB *, 1A GOOG *	0,1500	0,7358	4,7830
269	1A AMZN *	1A BABA N	0,1577	0,7736	3,7247
270	1A AMZN *	1I SHV *, 1A GOOG *	0,1577	0,7736	4,2794
286	1A AMZN *	1A FB *, 1A GOOG *	0,1615	0,7925	4,7916
298	1A AMZN *	1I SHV *, 1A FB *	0,1654	0,8113	3,6370
320	1A AMZN *	1A GOOG *	0,1692	0,8302	4,1509
398	1A AMZN *	1A FB *	0,1846	0,9057	3,7376
83	1A AAPL *	1A BABA N	0,1000	0,6190	2,9806
106	1A AAPL *	1A FB *, 1A AMZN *	0,1038	0,6429	3,4821
129	1A AAPL *	1A AMZN *	0,1077	0,6667	3,2704
130	1A AAPL *	1I SHV *, 1A FB *	0,1077	0,6667	2,9885
222	1A AAPL *	1A FB *	0,1192	0,7381	3,0461

Apéndice 2: Información procesada y anonimizada para la corrida del algoritmo de reglas de asociación. Donde, cada fila representa un usuario y en cada columna se indica si el mismo posee el instrumento respectivo con un uno, o si no lo posee, con un cero.



matriz_tp_metodos_p
redictivos_asesoria.xls



Apéndice 3: Información procesada y anonimizada para la corrida del algoritmo de Sistemas de Recomendación con Filtrado Colaborativo Basado en Usuarios. Donde, cada fila representa un usuario y en cada columna se indica la proporción en la que el usuario posee determinado instrumento sobre el total de su cartera.



datos_collaborative_fi
ltering_matriz.xlsx