

Escuela de Negocios
Tipo de documento: Tesis de maestría



Master in Management + Analytics

Optimización de la red de Fulfillment en un Marketplace online

Autoría: Melnitzky, Eitán Nicolás

Año: 2025

¿Cómo citar este trabajo?

Melnitzky, E. (2025) "*Optimización de la red de Fulfillment en un Marketplace online*". [Tesis de maestría. Universidad Torcuato Di Tella]. Repositorio Digital Universidad Torcuato Di Tella

<https://repositorio.utdt.edu/handle/20.500.13098/13744>

El presente documento se encuentra alojado en el **Repositorio Digital de la Universidad Torcuato Di Tella** bajo una licencia Creative Commons Atribución-No Comercial-Compartir Igual 4.0 Internacional

Dirección: <https://repositorio.utdt.edu>



**UNIVERSIDAD
TORCUATO DI TELLA**

MASTER IN MANAGEMENT + ANALYTICS

**OPTIMIZACIÓN DE LA RED DE FULFILLMENT
EN UN MARKETPLACE ONLINE**

TESIS

Eitán Nicolás Melnitzky

Mayo-2025

Tutor: Javier Marengo

Abstract

Fulfillment networks pose a significant challenge for online marketplaces due to their high investment and elevated fixed costs. As a result, they require a large volume of transactions to achieve profitability. At the same time, they must compete not only with other online marketplaces but also with traditional brick-and-mortar retail. In this competition, providing fast delivery times is crucial to outcompete other marketplaces and to bridge the gap with the immediacy of traditional retail. In this endeavor, the location of warehouses, the speed of operations, and the efficiency of the logistics network play important roles. However, it is also necessary to consider other strategies to win the race for speed. In this context, intelligent stock distribution and cost minimization become fundamental objectives to ensure both the success and sustainability of the e-commerce business.

This thesis explores and discusses the optimization of the fulfillment network in an online marketplace. To achieve this, real data on sales, products, transportation, capacities, and costs are available. The analyzed datasets include millions of products and sales to ensure the robustness of the results. To meet the objectives, several data science models are developed in order to segment products, predict costs, and optimize the valuable resource: the sellers' stock. However, the mentioned components are not used in isolation; instead, they are integrated into the proposal of a complete optimization system for the strategic redistribution of inventory throughout the logistics network. The results of this process demonstrate a significant reduction in operational costs for the selected product set, an improvement in financial efficiency, and an improvement in user experience. Specifically, there is a 5.9% reduction in total logistics costs and a 7.1% reduction for the most relevant product set in the marketplace. Additionally, due to the application of this optimization system, product sales can be expected to increase by up to 50% through higher conversion rates.

Resumen

Las redes de fulfillment representan un desafío significativo para los marketplaces online debido a su alta inversión y costos fijos elevados. Debido a esto, tienen la necesidad de un gran volumen de transacciones para lograr rentabilidad. Al mismo tiempo deben competir no solo con otros marketplaces online, sino también con el comercio tradicional en tiendas físicas. En esta competencia es crucial brindar tiempos de entrega rápidos tanto para ganar en oferta contra otros marketplaces como para acortar la brecha con la inmediatez del comercio tradicional. En esta labor juega un papel importante la ubicación de los depósitos, la velocidad de la operación y la velocidad de la red logística. Sin embargo es necesario también plantear otro tipo de estrategias para ganar la competencia por la velocidad. En ese contexto, la distribución inteligente del stock y la minimización de costos logísticos se vuelven objetivos fundamentales para asegurar tanto el éxito como la sostenibilidad del negocio del ecommerce.

En este trabajo de investigación se explora y se discute la optimización de la red de fulfillment en un marketplace online. Para esto, se cuenta con datos reales de ventas, productos, transporte, capacidades y costos. Los datasets analizados cuentan con millones de productos y ventas para asegurar la robustez de los resultados. Para cumplir con el objetivo se desarrollan modelos para segmentar productos y para predecir costos, así como también para optimizar el valioso recurso en cuestión: el stock de los vendedores. Pero la serie de componentes mencionados no se usan aisladamente sino que se articulan en la propuesta de un sistema completo de optimización para la redistribución estratégica del inventario a lo largo de la red logística. Los resultados de este proceso demuestran una reducción significativa de los costos operativos para el universo de productos seleccionados, una mejora en la eficiencia financiera y una mejora en la experiencia de cara a los usuarios. En concreto, se logra una reducción del 5,9% en los costos totales de logística y un 7,1% de reducción para el conjunto de productos más relevante del marketplace. Además, debido a la aplicación de este sistema de optimización se puede esperar incrementos en las ventas de los productos de hasta un 50% vía aumento en las tasas de conversión.

Índice de Contenidos

Introducción.....	4
Procesamiento y Preparación de los Datos.....	6
Análisis y Clasificación de Productos.....	6
Hipótesis Inicial sobre los Productos.....	6
Análisis sobre los productos.....	7
Topología de la red a optimizar.....	9
Clasificación de Productos.....	11
Costos de transporte.....	14
Costos de MWH.....	15
Costos de Delivery.....	16
Demanda.....	19
Selección de Productos a Optimizar.....	19
Demanda de los productos.....	21
Stock.....	22
Incumplimiento de la demanda.....	24
Modelado del Problema y Optimización.....	25
Modelado.....	25
Descripción Gráfica del Problema.....	25
Planteo del Modelo Formal.....	26
Optimización.....	29
Aproximación y Enfoque hacia la Optimización.....	29
Inconvenientes y Soluciones.....	30
Interpretación de Resultados.....	32
Costos Sin Optimización.....	32
Costo Con Optimización.....	32
Costo de MWH.....	33
Costo de Fulfillment.....	33
Beneficio de la Optimización.....	34
Conclusiones e Implicancias de Negocio.....	36
Conclusiones.....	36
Perspectiva Económica.....	36
Perspectiva Financiera.....	37
Perspectiva de Demanda.....	37
Implicancias de Negocio.....	38
Riesgos.....	39
Posibilidades adicionales que ofrece el sistema de optimización.....	40
Fuentes.....	41

Introducción

El presente trabajo tiene como objetivo optimizar la asignación de productos a lo largo de una red de fulfillment con la finalidad de bajar los costos y disminuir los tiempos de entrega de la red.

Una red de fulfillment es un sistema logístico diseñado para entregar compras con la mayor velocidad y eficiencia posibles. Es especialmente aplicable a compañías de ecommerce, como la que se toma de referencia en este trabajo de investigación, donde el desafío es hacer llegar a los usuarios que compran en un marketplace online los productos de vendedores de forma segura y dando una buena experiencia. Esto se persigue en el marco de que los usuarios siempre tienen la elección de comprar en el “mundo físico” (en una tienda cercana a su hogar, por ejemplo) o en el “mundo online”, y que los marketplaces digitales perciben que una de sus mayores debilidades frente al mundo físico es la velocidad con que el comprador dispone de sus productos.

En cuanto a las ventajas que tiene este tipo de sistemas, se observa que son rápidos y eficientes en un nivel operativo, mejoran la experiencia de compradores y vendedores y son escalables mediante mejoras en la red logística o incluso invirtiendo en más depósitos. En cuanto a las desventajas, es un sistema con una alta inversión y altos costos fijos para la empresa de ecommerce. Por consiguiente, combinando sus ventajas y desventajas, se observa que un sistema de fulfillment es óptimo cuando existe una escala lo suficientemente grande de transacciones que ocurren en el marketplace. Esto contribuye a diluir costos fijos mientras se aprovechan las bondades de este sistema.

La velocidad de entrega, como principal fortaleza de este tipo de sistemas, obedece a que los vendedores almacenan sus productos en la red logística del marketplace. Esto significa que cuando se produce la venta, el producto ya está en manos de la red que se encargará de llevarla hasta su comprador. En otras palabras, en el momento de la venta el *first mile* (viaje del vendedor hasta la red) ya está completo, y solo resta por recorrer el *last mile* (viaje desde el centro de distribución hasta el usuario comprador). En el e-commerce tradicional, al producirse la venta el producto aún está en manos de su vendedor, por lo que debe recorrer ambos procesos: *first mile* y *last mile* antes de llegar a su comprador.

Los componentes básicos de un sistema de fulfillment son el *inbound* (recepción de productos de los vendedores), la gestión del stock (almacenamiento, asignación, etc) y el *outbound* (envío de los productos a sus compradores). Cabe destacar que los depósitos en un sistema de fulfillment no son depósitos comunes, ya que el depósito pertenece a la empresa que ofrece el marketplace online para transaccionar, pero los productos que se almacenan dentro del mismo son, en parte, propiedad de usuarios que quieren venderlos a través de dicha plataforma.

En cuanto a la topología de una red de fulfillment, la misma depende en gran parte del país en el que se encuentra. Por ejemplo, si el país es pequeño, es posible que se pueda ubicar un solo centro de almacenamiento y aun así llegar en un día o menos a cualquier parte del país (experiencia estándar que espera la mayoría de los compradores online). En cuanto a países más grandes o no tan bien comunicados, sería imposible ubicar solamente un depósito y abastecer en menos de un día a cualquier comprador. Es en ese escenario en que surge la inquietud de cuántos depósitos ubicar, dónde ubicarlos y qué tamaño deben tener. Otro factor que atraviesa estas decisiones es cómo se distribuye la demanda dentro del país. Un país con demanda muy centralizada puede ofrecer

facilidades de ubicar los depósitos en los lugares donde la demanda se concentra, mientras que un país con su población bien distribuída (más “federal”) vuelve a ofrecer grandes desafíos en el sentido de cómo pensar la red de fulfillment para abastecer la demanda de forma efectiva.

Sin embargo, las dificultades no terminan ahí, ya que una vez que se ha decidido la topología de la red, es aún necesario entender cómo distribuir los productos en stock a lo largo de dicha red. Por ejemplo, si los vendedores más importantes de un producto determinado se encuentran cerca del mismo depósito de fulfillment (porque el mismo se importa y entra por un puerto del país), entonces todas las unidades de ese producto entrarán a la red por el mismo depósito, lo que hará que se almacenen allí y que los compradores lejanos a ese depósito no vean entregas rápidas del mismo, degradando la experiencia y degradando algunas de las ventajas de este sistema. Lo ideal en una situación semejante sería poder distribuir esos productos a lo largo de la red de forma proporcional a la demanda futura, y poder entonces abastecer este producto a todos los usuarios con tiempos de entrega razonables y con costos mínimos. Esto muestra que hay decisiones para tomar en el día a día respecto de la gestión del stock que afectan en gran medida el funcionamiento del sistema.

Siguiendo con esta idea, ¿son, acaso, todos los productos igualmente importantes dentro de la oferta como para que amerite transportarlos a otro nodo de la red? ¿Los usuarios valoran tener más cerca todos los productos que demandan? ¿Cuánto varía la conversión de los productos frente a una variación en la promesa de entrega? Las respuestas a estas preguntas son de importancia meridiana para entender cómo se puede optimizar la operación de una red de fulfillment.

Estas son las preguntas que se estarán abordando en esta investigación, y se buscará responderlas para una red con numerosos depósitos en un país con una demanda descentralizada. Los datos usados para el presente trabajo son reales, pero están modificados para preservar la identidad y la información de la compañía a la que pertenecen.

Las herramientas con las que se buscará responder estas preguntas son modelos de clusterización K-Means, modelos de regresión XGBoost, algoritmos de optimización lineal mixta (SCIP) y simulaciones a medida. Esta amplia gama de herramientas fue necesaria para ir trascendiendo barreras a lo largo de toda la investigación y cada una se probó indispensable para la realización de este trabajo. Toda la implementación correspondiente a las necesidades de este trabajo serán realizadas en Python utilizando las librerías *numpy*, *pandas*, *matplotlib*, *pyscipopt*, *scikit-learn* y *xgboost*.

Se calculará no solo el rendimiento operativo esperado de la iniciativa, sino también el económico y financiero, para llegar a una conclusión completa y multidisciplinaria. Finalmente, luego de transitar el proceso descrito, se emitirá una recomendación sobre la conveniencia de adoptar esta práctica en el contexto de redes de fulfillment o no, dependiendo de los resultados obtenidos.

Procesamiento y Preparación de los Datos

Durante esta parte del informe, se buscará setear el escenario en cuanto al problema y se irá traduciendo desde el problema de negocios descrito a varios problemas de datos. El objetivo será recabar, procesar, interpretar y conocer los datos disponibles, para luego prepararlos para que el optimizador los consuma y pueda devolver un escenario de red con el stock alocado donde sea más eficiente.

Análisis y Clasificación de Productos

Se aborda a continuación el estudio de los productos con el fin de tomar decisiones que ayuden a considerar cómo encarar la optimización

Hipótesis Inicial sobre los Productos

En la búsqueda de cómo optimizar una red de fulfillment, es indispensable conocer los productos que la red se ocupa de distribuir y entregar. Por ejemplo, debido a que la compañía de e-commerce permite a vendedores publicar cualquier producto, ¿cómo es posible saber si dos personas venden el mismo producto? Para poder definir un marco, se tomarán ciertas hipótesis de base sobre cómo funciona el marketplace en términos de los productos que se publican en él:

- Se puede publicar cualquier producto en el marketplace. Nuevos y usados, productos estándar (con un EAN) o productos únicos (como pueden ser fabricados por microemprendimientos informales, coleccionables, etc)
- Se conocen las dimensiones y peso de todos los productos que se almacenan en los depósitos de fulfillment.
- El marketplace cuenta con un catálogo. Esto implica que hay una serie de productos que, al ser publicados, el vendedor debe asignarlos a un “producto de catálogo” indicando la marca, modelo, y variación del mismo. Por ejemplo, al publicar un producto tan conocido como un iPhone, el vendedor debe indicar que lo que está publicando pertenece a esa gama de productos, de forma que cuando un comprador busque un modelo de iPhone, el marketplace le pueda ofrecer todas las publicaciones de ese modelo sabiendo que puede confiar en la asertividad de lo que ofrece y no dependiendo de títulos de publicaciones ni descripciones que puedan diferir entre vendedores. De esta manera, los productos más comunes del mercado estarán catalogados, mientras que los de menor demanda tienen libertad para ser publicados pero sin un “control” del marketplace en cuanto a la forma de publicarlo.
- *Commingled Inventory*: este modelo logístico asume que el marketplace puede *entremezclar* el stock de diferentes vendedores como si fueran uno solo. La hipótesis de publicaciones catalogadas es indispensable para poder asumir esta nueva hipótesis, debido a que se trata de poder reconocer qué publicaciones venden el mismo producto y tener la posibilidad de entregar el producto físico de un vendedor para satisfacer la venta de otro vendedor. Debido a que la complejidad de esta hipótesis, sus implicancias y consecuencias se discutirán en secciones futuras del trabajo.

Con este conjunto de hipótesis, se tiene que el marketplace quiere por definición un catalogado parcial de los productos, donde un vendedor no puede publicar un iPhone fuera del catálogo, pero se permite que otro vendedor publique fuera de catálogo las remeras que fabrica en su emprendimiento. Esto implica que para todos los productos catalogados se conoce quienes venden el mismo producto, y por consiguiente se pueden identificar la cantidad de “iPhones 16 pro max” en un depósito sin importar quien lo haya publicado.

Otro aspecto a destacar sobre los productos es que el presente trabajo se enfocará en brindar soluciones para los productos catalogados, debido a que son los productos que más ventas concentran y al mismo tiempo de los que más información se dispone y de mayor calidad, debido a que se puede relacionar sin errores todas las publicaciones que venden productos iguales.

Análisis sobre los productos

Los datos disponibles son ventas pasadas (en dinero y unidades), la categoría de producto, las dimensiones, el peso, las visitas, la conversión, la promesa de entrega de cada visita y el precio de venta.

En cuanto a las visitas y conversión, una de las inquietudes de este trabajo es si todos los productos son iguales en términos de cuánto les importa a sus compradores la velocidad de entrega. Para despejar esta incógnita, se procedió a calcular la sensibilidad de la conversión a la promesa de entrega, es decir, cuántas unidades aumenta la tasa de conversión por mejorar la promesa de entrega. Las promesas de entrega se clasificaron en 3 tipos (en línea con el estándar de la industria): Entregas en el mismo día de la compra (*same day*), entregas al día siguiente (*next day*) y entregas de dos días o más (*two days+*). En la *Figura 1* se observa la distribución de los productos según la tasa de conversión que tienen cuando se prometen entregas más rápidas o más lentas. Cada producto estará en las tres distribuciones que se observan superpuestas contabilizando la conversión al prometer cada tiempo de entrega en ese producto.




Figura 1: Histograma de productos según su tasa de conversión con distintas promesas de entrega

Como puede apreciarse, las distribuciones *same day* y *next day* tienen distribuciones de conversión muy similares, mientras que la distribución que difiere de ambas es la conversión en caso

de promesa *two days+* (lógicamente una conversión menor). De esta forma, se saca la primera conclusión sobre los compradores, y es que no parece importar si el producto se entrega el mismo día o al día siguiente y esto no afecta la decisión de compra. Sí se ve afectada la decisión de compra cuando la promesa de entrega es de dos días o más. A fines prácticos, se considerará como una única promesa de *same day* o *next day* (sd/nd) versus las promesas de *two days+* (2d+), como se observa en la *Figura 2*.

De forma que la sensibilidad de la conversión a la promesa de entrega se calculará de la siguiente forma:

$$\text{Sensibilidad Conversión} = \frac{\text{Conv Rate}_{SD/ND}}{\text{Conv Rate}_{2D+}} = \frac{\text{Conversiones}_{SD/ND}}{\text{Conversiones}_{2D+}} \cdot \frac{\text{Visitas}_{2D+}}{\text{Visitas}_{SD/ND}}$$

Del cálculo anterior se desprende que si el resultado para un producto es 1, entonces las tasas de conversión comparadas son iguales, mientras que si el resultado fuera 1,5 se entiende que las promesas rápidas convierten un 50% más que las lentas.




Figura 2: Histograma de productos según su tasa de conversión con distintas promesas de entrega agrupadas

Esta nueva variable derivada de las existentes es clave para medir la utilidad de acercar físicamente el almacenamiento de cada producto a los compradores para que puedan recibir mejores promesas al comprarlos. Tiene sentido distribuir un producto que presente una alta sensibilidad de la conversión a la promesa de entrega a lo largo de toda la red debido a que el usuario valora en algún grado su rápida entrega, mientras que lo contrario es cierto para productos de baja sensibilidad.

En el transporte y distribución de los productos a lo largo de la red es también importante tener en cuenta otras variables que pueden contribuir a aportar información relevante sobre los productos. Las dimensiones, principalmente el volumen, es una de ellas ya que el mismo determina cuánto se puede transportar de manera eficiente y cuán costosa es la manipulación de cada producto. Asimismo son variables importantes el precio y las ventas, tanto en unidades como en dinero transaccionado. En el caso de las unidades vendidas y el dinero transaccionado, son variables

que presentan una alta correlación entre sí (70%). De hecho, podría pensarse el dinero transaccionado como una variable dependiente del precio y las unidades vendidas. Debido a este hecho, se considera que el dinero transaccionado no tiene la capacidad de aportar información nueva. Se observan las distribuciones de estas variables en la *Figura 3*. Como puede apreciarse en dicha figura, para poder distinguir algún nivel de detalle sobre las distribuciones mencionadas, es necesario representarlas en escala logarítmica. De lo contrario, los histogramas de estas variables estarían representados con una gran barra a la izquierda y una cola muy larga hacia los valores más altos.

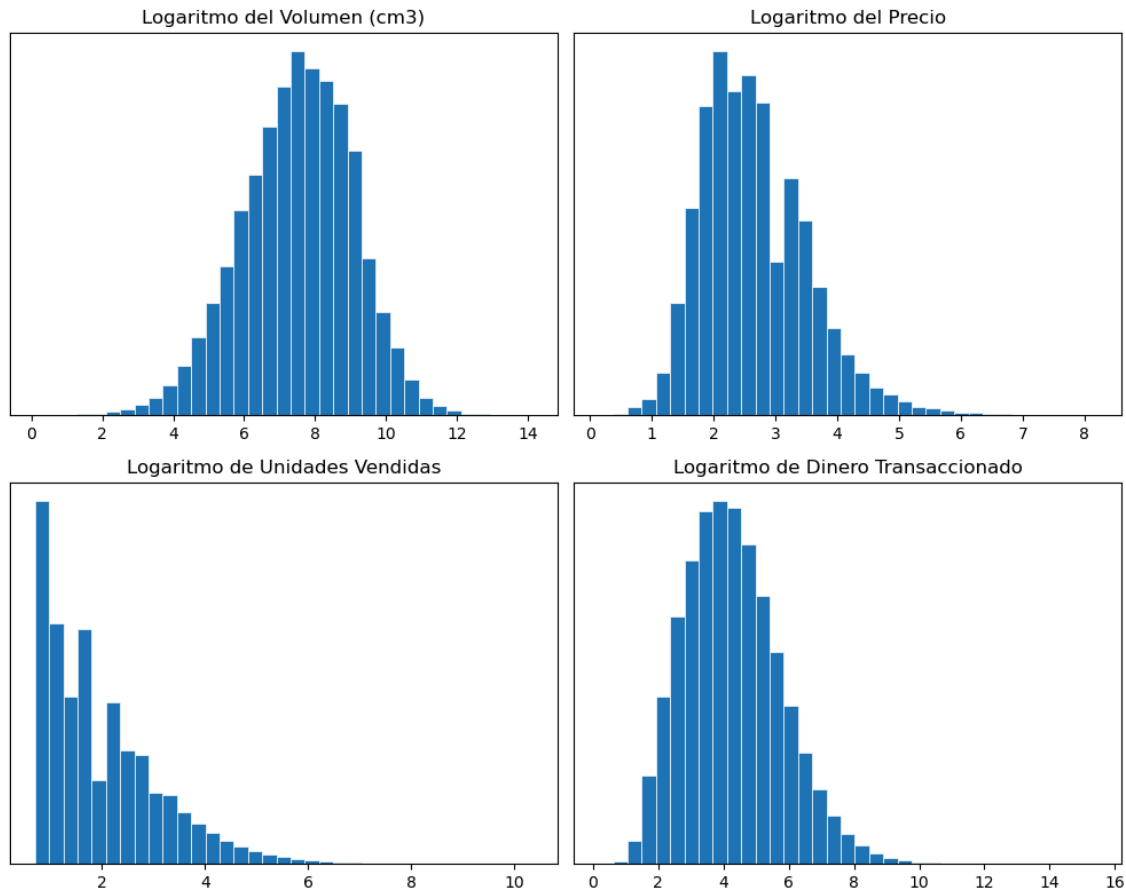


Figura 3: Histogramas de productos del logaritmo de 4 variables relevantes (Volumen, Precio, Ventas en Unidades y Ventas en Dinero)

Por ende, se procederá a intentar clasificar los productos catalogados según sus distribuciones en 4 variables: precio de venta, volumen (en cm3), unidades vendidas y sensibilidad de la conversión.

Topología de la red a optimizar

Como fue precisado anteriormente, la topología de la red está relacionada con la distribución de la demanda, que a su vez tiene relación con la demografía. Como ejemplo, se tomará a Argentina, Brasil y Estados Unidos, cuyos mapas de densidades demográficas se aprecian en la *Figura 4*. Argentina tiene una distribución centralizada de forma radial en su capital y una parte muy apreciable de la demanda se encuentra allí. Es posible que ubicar depósitos solamente en Buenos Aires sea suficiente. En el caso de Brasil, tiene una distribución más federal, con numerosas ciudades

grandes ubicadas sobre la costa Atlántica. Esto hace improbable que sea eficiente ubicar depósitos sólo en San Pablo y llegar a todo el territorio con promesas de entrega útiles para los compradores. En el caso de Estados Unidos (si bien el mapa demográfico es de todo América del Norte, se hará foco sólo en el territorio estadounidense), se encuentra una demografía muy ecuménica en ambas costas (Atlántico y Pacífico) separadas por una zona menos habitada y con accidentes geográficos importantes. Esto vuelve imposible ubicar depósitos de una red de fulfillment en un solo lugar y abastecer satisfactoriamente todo el territorio. Se tomará para la resolución de este caso una red ubicada en una nación de similares características que Brasil y Estados Unidos, de manera que la misma cuenta con múltiples depósitos. No se devela de qué país se trata ni el continente en que está ubicado para preservar la información de la empresa.

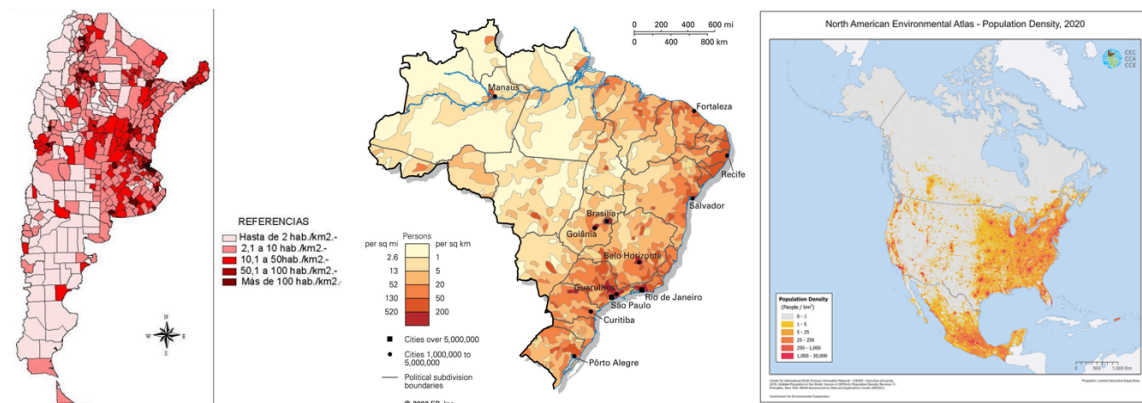


Figura 4: Densidades poblacionales de Argentina, Brasil y Estados Unidos respectivamente

Para tomar la decisión de cuántos clusters se necesitan para proseguir con el objetivo, es necesario poder distinguir entre productos que se quieren distribuir por la red de productos que se dejarán en el depósito en el que ingresen en la red. Pero es necesario previamente entender la topología de la red también, de manera de entender cómo es y qué decisiones se necesitan tomar.

La red de fulfillment a optimizar pertenece a un país que, como fue mencionado, presenta una distribución de su demanda análoga a la que se encuentra en Brasil o Estados Unidos. Ésta cuenta con 13 depósitos ubicados en 7 unidades administrativas y abastece 27 unidades administrativas en total (serán llamadas estados en adelante). Todos los depósitos que coinciden en el mismo estado se encuentran en la misma ciudad o en las cercanías. Debido a esta particularidad, se simplificará el problema como si cada estado tuviera un solo depósito combinando la capacidad de todos los depósitos en ese estado. Las unidades de capacidad fueron modificadas por un factor para preservar la información real de la compañía. Las mismas se observan en la *Figura 5*.

Estado	B	M	P	J	R	C	S
Capacidad	19969	75007	3629	1140	717	56859	239212

Figura 5: Capacidad en unidades de volumen por estado

Los únicos estados que reciben productos de los vendedores son B, M, C y S. Los otros estados solamente reciben productos transferidos desde otros depósitos de la red. Esto es una decisión de la compañía, debido a que tienen un tamaño muy reducido y se quiere decidir estratégicamente qué productos tener allí. Por otra parte, el estado S es donde nacieron las

operaciones de la compañía estudiada en este país, por lo que este estado sería el estado central, o la región central en cuanto a las operaciones logísticas de este ecommerce.

Debido a esto, se tiene 3 tipos de estados con depósitos: el Central o Nacional (S), los depósitos Regionales (B, M y C) y finalmente los depósitos Metropolitanos (P, J y R)

Otro factor a considerar es que es más económico transportar 1 metro cúbico de productos entre dos depósitos que entre un depósito y un cliente. Esto se debe a varios factores. El primero es una cuestión de escala, ya que los camiones que transportan productos entre depósitos suelen ser más grandes (abaratando los costos), el segundo es que cuando se transportan productos entre depósitos no existe la urgencia de entregarlos a ningún usuario final y se pueden aprovechar los espacios de forma más inteligente y formar pallets multi producto de formas más eficientes y el tercero es el factor de la capilaridad de la red de *last mile* de entrega a usuarios, lo que hace necesarios transbordos, centros intermedios, etc.

Clasificación de Productos

Para clasificar los productos del marketplace, se dispone de una base de 2 millones de productos, catalogados y no catalogados, con el fin de tener una noción representativa de todos los productos y tipos de productos. Si bien luego sólo se enfocarán los esfuerzos en los productos catalogados, el modelo de clusterización se entrena conociendo a todos los productos que existen.

Es necesario entonces tener en cuenta lo explicado en la sección anterior, ya que lo que se busca en última instancia es clasificar los productos según 3 comportamientos a seguir. Los Productos Centrales son aquellos que no se transportarán en absoluto respecto del depósito por el que ingresen. Los Productos Regionales son aquellos productos que, sin importar por donde ingresen, se distribuirán entre los depósitos Centrales y Regionales (en los estados B, M, C y S), pero no se enviarán a depósitos Metropolitanos. Por último los Productos Metropolitanos son aquellos que, sin importar en qué punto de la red ingresen se habilita enviarlo a cualquier depósito de la red. En otras palabras, todos los productos serán clasificados en estos 3 buckets para tomar la decisión de cómo se quiere aloarlos en la red de fulfillment.

Para empezar a segmentar los productos se realizó el análisis exploratorio ya descrito, y con las 4 variables definidas y un algoritmo de K-Means se exploraron las clusterizaciones usando el método del codo recorriendo valores de K entre 2 y 25. Para esto fue necesario tratar los outliers, estandarizar las variables y normalizarlas entre 0 y 1, con el objeto de que ninguna sea más importante que las demás para este algoritmo basado en distancias.

Para cada valor de K (cantidad de clústers) en el método del codo, se inicializaron 10 modelos de forma aleatoria debido a que el algoritmo es propenso a alcanzar mínimos locales. Como puede observarse en la *Figura 6*, cuando K es 3 (la cantidad de clusters finales deseados) la inercia está en un punto considerablemente más elevado que el que llega a estar con más cantidad de clusters. La inercia es una medida del desorden (o entropía) de la clusterización. De hecho, no hay un codo visible en este método que indique claramente un K óptimo con el que trabajar. Podría argumentarse que con K=4 se vislumbra un codo, pero nuevamente en un inercia demasiado alta respecto a la que se tiene con mayor cantidad de clústers.

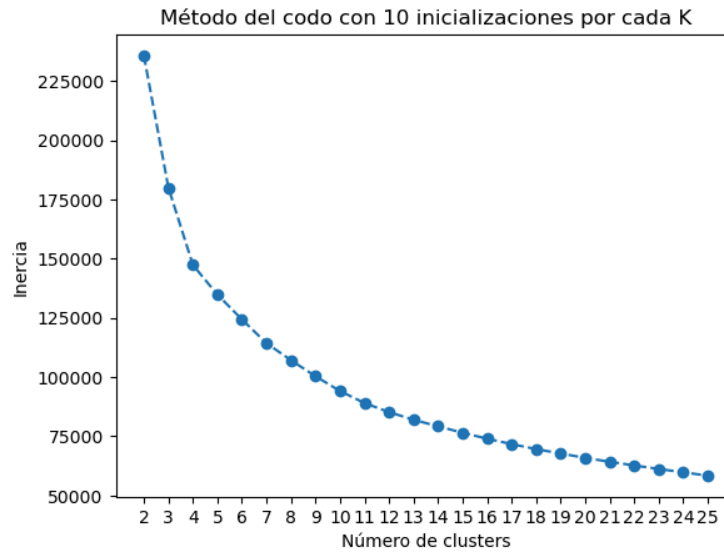


Figura 6: Inercia por número de clústers como resultado del método del codo

Con estas observaciones sobre el método del codo, se procede a hacer una clusterización en dos etapas. En la primera etapa, se utiliza un modelo K-Means con $K=20$ y se inicializa el entrenamiento 150 veces con centroides iniciales aleatorios con el objetivo de evitar mínimos locales en la función de inercia. De los 150 modelos, se elige el de menor inercia. Esto divide la base en 20 clusters mutuamente excluyentes y colectivamente exhaustivos (MECE). Finalmente, con un criterio de puntajes sobre cada variable, se agrupa a los clusters resultantes en los 3 grupos finales requeridos.

Podría pensarse, en un plano teórico, que el conjunto de datos tiene una cantidad de clústers óptima que lo representa mejor y que el trabajo de quien quiera clusterizar dicho conjunto de datos es el de descubrir o acercarse lo más posible a ese número, de forma de poder lograr clústers que sean internamente lo más homogéneos posible y que los clusters sean lo más heterogéneos posible entre ellos (es decir, que los clústers capten las diferencias entre los grupos). Por otro lado, están las necesidades del negocio, donde no sería eficiente tener demasiados grupos entre los cuales distinguir y tomar decisiones. La clusterización en 2 etapas busca respetar las dinámicas de ambos mundos (clusterización y necesidad de negocio) y lograr un maridaje funcional entre ellas. La elección del criterio de puntajes para la segunda etapa se hace debido a la simpleza que tiene para ser realizada por una persona, sin necesidad de algoritmos complejos. Al mismo tiempo capta la idea de que habrá 20 grupos y 4 variables que los describen y permite asignar una importancia relativa a cada variable y mediante los puntajes, definir el corte en base a qué características deben cumplir los clusters para ser considerados Metropolitanos, Regionales o Centrales.

En cuanto a la etapa 1 de agrupación en 20 clusters, se puede apreciar en la *Figura 7* que los 20 clusters tienen cantidades razonables de productos, es decir que no quedan clusters con una ínfima cantidad de productos aislados de los demás, debido al trabajo con outliers. Los clústers no tienen porqué tener cantidades similares de productos, pero sí se espera no tener clústers con 10 productos de una base de 2 millones.




Figura 7: Cantidad de productos en cada clúster como resultado del algoritmo K-Means

En la etapa 2, se agrupan los 20 clusters del algoritmo K-Means en los 3 grupos ya explicados mediante un sistema de puntaje. Para cada clúster se computa el puntaje considerando el valor promedio de las 4 variables en juego. A mayor precio, menor volumen, mayores ventas y mayor sensibilidad a la conversión, mayor es el puntaje asignado. Finalmente, 3 clusters quedan como productos Metropolitanos con un 8% de los productos, pero concentrando un 69% del monto transaccionado. Los productos Regionales agrupan 8 clusters, con un 34% de los productos en la base y un 20% del dinero transaccionado. Finalmente, los últimos 9 clusters quedan como productos Centrales, agrupando el 58% de los productos en la base y un 11% del dinero transaccionado. Resulta obvio que los productos Metropolitanos son los más relevantes y los que más rotan su stock, mientras que los Centrales son productos con peores características que los hace no solo menos eficientes, sino más riesgosos para transportarlos a otras locaciones, ya que de no venderse o tener una demanda más volátil o esporádica, haría tener un transporte entre depósitos para luego entregarse en un lugar distante al nuevo depósito o incluso ocupar por más tiempo lugar en depósitos más pequeños que necesitan una “población” de productos con rápida rotación.

En la *Figura 8* se muestra la tabla de centroides y puntajes en la que se puede apreciar la dinámica de la etapa 2 de clusterización. Para cada variable se toma un criterio para asignar 0, 10 o 20 puntos, excepto para las ventas en unidades, que se asigna un puntaje de 0, 20 o 40 puntos, debido a que es la variable más importante a la hora de pensar en la redistribución del inventario a lo largo de la red. Es la más importante debido a que brinda una idea de velocidad de rotación del inventario. De manera que el mínimo puntaje alcanzable es de 0 puntos y el máximo es de 100. Los clusters entre 0 y 30 puntos, serán Centrales, entre 40 y 50 puntos serán Regionales, y por encima de 60 puntos serán Metropolitanos. Puntajes de 80, 90 o 100 puntos son realmente difíciles de alcanzar, de hecho como se aprecia en la *Figura 8* ningún clúster alcanza esos puntajes.

Cabe destacar que, dada la complejidad del caso y la cantidad de variables disponibles, dio un gran resultado disponer de flexibilidad a la hora de clusterizar y tomar lo mejor de 2 métodos. Por un lado, el K-Means permite agrupar millones de productos según la distancia de sus variables, sin formar fronteras rígidas y adaptándose a los datos de entrada para ubicar los centroides. Al mismo tiempo, con K=3 desde el inicio no se podría haber captado la complejidad del universo de productos. Por otro lado, la clusterización por puntajes es un proceso más “manual”, que si fuera usado con millones de productos tendería a generar fronteras más rígidas, ortogonales, que tienden a fracasar en adaptarse a la base y dependen de la interpretación de un ser humano que nunca

llegará a analizar a detalle todos los productos. Sin embargo, su aplicación con 20 clusters (o bien podrían pensarse como 20 productos canónicos) es más sencilla y menos propensa a sesgos por parte del analista. La combinación de ambos métodos resumió el problema a una solución que interpreta la complejidad de la base y al mismo tiempo tiene un resultado extremadamente pragmático y usable.

Cluster	# Prods	Centroides				Puntaje				Score	Bucket
		Precio	Volumen	Unidades	Sens. Conversión	Precio	Volumen	Unidades	Sens. Conversión		
0	102800	2.450	13'643	2.436	1.330	10	0	0	10	20	Central
1	134504	0.701	2'434	1.904	1.374	0	10	0	10	20	Central
2	74256	1.074	4'853	17.901	1.113	10	10	20	0	40	Regional
3	80639	10.153	24'985	3.102	1.363	20	0	0	10	30	Central
4	68910	0.565	1'191	3.937	1.538	0	20	0	20	40	Regional
5	31274	7.445	29'620	61.518	1.384	20	0	40	10	70	Metro
6	103265	2.687	8'786	2.658	1.146	10	10	0	0	20	Central
7	97822	0.526	196	15.687	1.359	0	20	20	10	50	Regional
8	125022	0.887	8'891	8.275	1.285	0	10	0	10	20	Central
9	93900	2.419	6'888	15.676	1.329	10	10	20	10	50	Regional
10	104259	2.447	1'061	2.881	1.351	10	20	0	10	40	Regional
11	155375	0.521	224	2.163	1.341	0	20	0	10	30	Central
12	40292	2.490	9'014	4.398	1.549	10	10	0	20	40	Regional
13	61243	0.536	1'097	211.920	1.392	0	20	40	10	70	Metro
14	97917	0.885	3'176	2.565	1.073	0	10	0	0	10	Central
15	162226	0.599	967	6.774	1.308	0	20	0	10	30	Central
16	61289	1.234	8'385	144.132	1.277	10	10	40	10	70	Metro
17	160642	0.800	4'381	1.900	1.234	0	10	0	0	10	Central
18	64844	0.655	2'798	25.366	1.514	0	10	20	20	50	Regional
19	117508	0.646	2'083	28.438	1.299	0	10	20	10	40	Regional

Figura 8: Tabla descriptiva de los centroides de los 20 clusters y su asignación por puntajes a un bucket

Para futuros trabajos, puede ser interesante descubrir las implicancias de tomar decisiones distintas a la hora de calcular los puntajes en la segunda etapa de la clusterización. Por ejemplo, si todas las variables tuvieran el mismo peso, ¿cómo afectaría a la alocaión final de productos? ¿Cómo es la sensibilidad de estas decisiones respecto del resultado final de este trabajo?

A fines prácticos, para utilizar más adelante con la base real de productos catalogados a clasificar, se guarda el proceso con los transformadores ya entrenados (para trabajar outliers de la misma forma y normalizar la base con el mismo criterio) y se guardan los centroides del K-Means.

Costos de transporte

Como fue mencionado en secciones anteriores y será ampliado en la presente, existen dos tipos de transporte en este problema a resolver. El primero es el transporte de productos entre distintos depósitos de la red y se llamarán transportes de *multi-warehousing* (MWH). Las características principales de estos transportes son que obedecen a una decisión del marketplace y que los productos no están vendidos aún.

El segundo es el transporte de productos hasta un usuario final desde alguno de los depósitos. Estos transportes cuentan con la urgencia de dar una buena experiencia de entrega (cumpliendo tiempos prometidos) y son decisión de la demanda. Esto hace que este tipo de transporte sea más complejo y demande más actividades que el primero. Entre otras actividades, es necesario buscar producto por producto de sus ubicaciones, empaquetar lo que el comprador haya elegido en una sola caja, ordenarlo según el destino (por ejemplo código postal) al que se dirija,

viajar a centros intermedios para desconsolidar y canalizar los paquetes hacia la parte más capilar de la red, recorriendo la última milla hasta su destino.

Estas diferencias entre los dos tipos de transporte sugieren que el transporte por MWH es más económico que el transporte por Delivery. Este hecho se confirma en la realidad, y se procede a explicar cómo. Para determinar los costos de cada tipo de transporte, se exploró información de MWH y entregas pasadas y los costos finales que la empresa afrontó.

Costos de MWH

Cada transporte de MWH tiene como origen un depósito (en este caso un estado) y como destino otro. Por consiguiente las combinaciones dentro del escenario planteado es que el producto sale de 1 de los 7 estados y llega a 1 de los otros 6. La combinatoria devuelve solamente 42 rutas posibles, pero lo que se constató mediante los datos es que no todas las rutas (combinación de estado de origen con estado de destino) son usadas, ni tiene sentido usarlas. Por ejemplo, entre un depósito Metropolitano y otro no tiene sentido hacer envíos de productos. La mayor parte de las veces tampoco tiene sentido hacer envíos desde un depósito Metropolitano a uno Regional, por ejemplo, ya que sería menos eficiente y esto representaría un doble transporte sin que se haya producido ninguna venta aún para esos productos. Por consiguiente, sólo se cuenta con información sobre 18 rutas, las que se encuentran en la *Figura 9*. Se tomarán estas mismas 18 rutas existentes como base con el objeto de contar con los costos reales de transporte.

Rutas MWH		
Origen	Destino	Envios (Mensual)
S	B	568
S	C	350
M	C	305
M	B	266
S	J	136
C	B	129
M	P	116
C	S	103
S	R	78
S	P	53
M	J	43
B	S	36
M	R	30
J	S	28
C	R	18
S	M	11
R	S	6
B	P	1

Figura 9: Cantidad de envíos mensuales por ruta

Debido a que no se cuenta con la información de costeo de transportes de la compañía y tampoco se cuenta con la forma de simular el armado de un camión para transportar productos entre depósitos, se debe recurrir a una forma de predecir el costo de mover productos de un depósito a otro. Para esto se cuenta con información de un mes de transportes.

El análisis de estas rutas se ha efectuado en base a las siguientes variables: origen, destino, volumen transportado, tipo de vehículo y distancia. El tipo de vehículo resulta ser una de las variables más influyentes para determinar el costo del transporte, ya que correlaciona en gran medida, pero desafortunadamente no se sabe en un futuro qué tipo de transportes se dispondrán para cada viaje en cada ruta. Si bien la elección del vehículo depende del volumen a transportar, no se sabe antes de realizar la asignación qué volumen se debe transportar en cada ruta y por ende qué tipo de vehículo sería el más propicio. Al mismo tiempo, la elección del vehículo podría formar parte de la optimización e incluso preocuparse del llenado eficiente de los mismos, pero se excede ampliamente el alcance del presente trabajo. Por esto, dado que no es una variable disponible para predecir el costo, se la procede a descartar. El descartarla provoca que todos los tipos de vehículos sean considerados por los datos reales y que los costos estén también en línea con los reales.

Sin embargo, cuando se cruza el costo y el volumen transportado, se observa que el volumen es también un excelente predictor del costo. Esto se observa por los patrones de rectas en el gráfico de todas las rutas en la *Figura 10*.

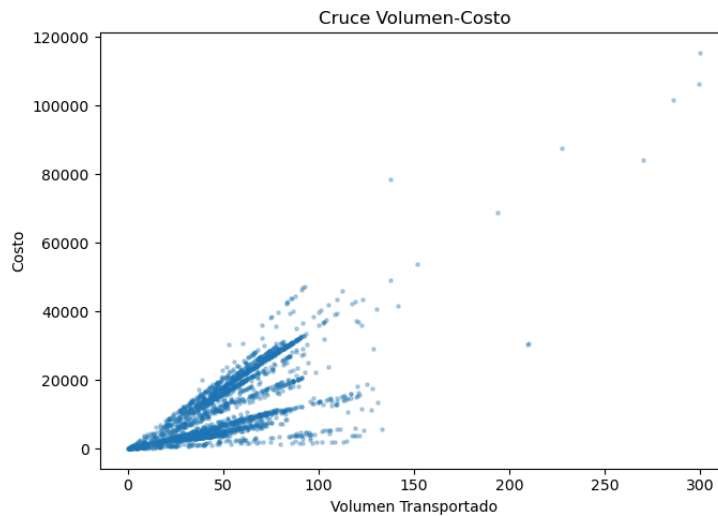


Figura 10: Gráfico de dispersión de envíos MWH según el volumen transportado y el costo del transporte

Para determinar si el ordenamiento de los puntos es fortuito o realmente la pendiente Volumen-Costo puede ser tomada como referencia, se repite el análisis sobre las 4 rutas más frecuentes de las 18. Como puede apreciarse en la *Figura 11*, cada ruta tiene su propio perfil de rectas, con diferentes pendientes y diferentes escalas. Las diferentes pendientes dentro de una misma ruta se explican por el tipo de transporte utilizado para recorrer la ruta, ya que la distancia es fija en cada ruta posible.

Las pendientes, medidas en costo por unidad de volumen, varían aproximadamente entre 50 y 400 en toda la población de rutas. A la vista de los resultados y la simpleza con la que las variables predictoras se relacionan con la variable a predecir, no se usará ningún algoritmo ni modelo estadístico para predecir el costo de transporte MWH, sino que se reducirá esta parte del problema a tomar la pendiente promedio y generar el costo volumétrico de transporte por ruta, de manera de que un producto de un volumen conocido tendrá un costo promedio para ser transportado por todas las rutas disponibles.

El resultado de este proceso es una **matriz de 2 dimensiones** donde se cruzan los **orígenes** y **destinos** posibles (depósitos) y se conoce para cada combinación el costo volumétrico de transporte de cada ruta. Esto luego se utilizará como parámetro para la optimización.

Costos de Delivery

En el caso de los costos de delivery se hizo exactamente lo mismo que para los costos de MWH, aunque con resultados diferentes. En el caso de este tipo de transportes, es más complejo determinar cuál será el costo de entregar un producto a un usuario. Esto se debe a todos los factores previamente explicados que aumentan la complejidad, pero también porque se pueden abastecer ventas desde los 7 depósitos, pero los estados de destino en este caso son los 27 estados de este territorio.

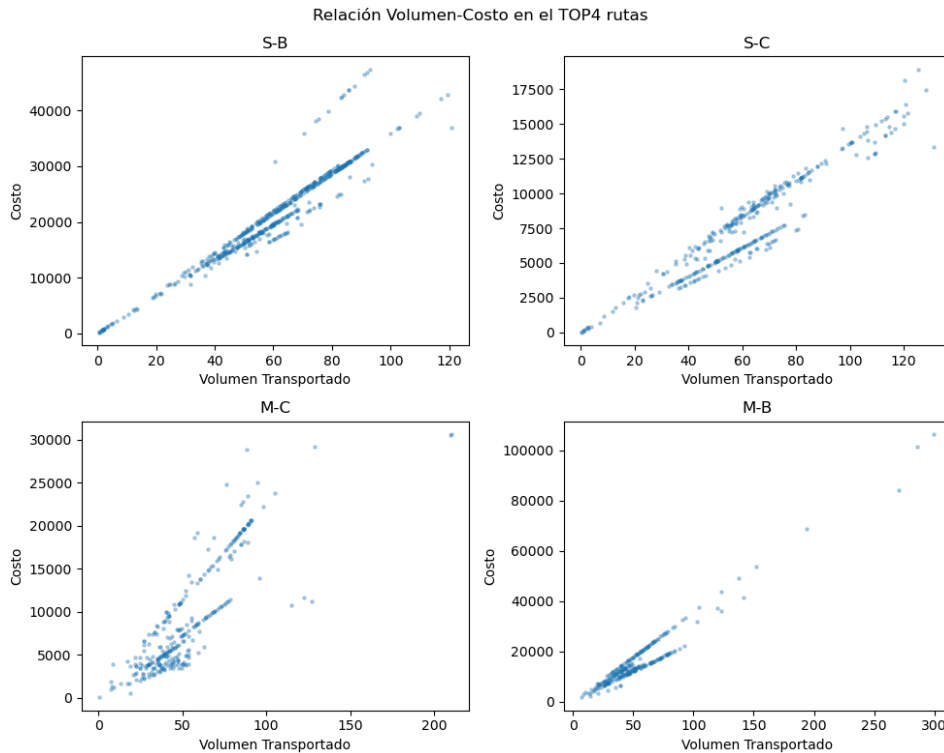


Figura 11: Gráficos de dispersión de envíos MWH según el volumen transportado y el costo de transporte para las 4 rutas más usadas

En el contexto de la entrega de productos y la locación de inventario que se pretende realizar, cabe aclarar cómo se conforma la red que entrega los productos en lo que se conoce como última milla o *Last Mile*. En la práctica, todo ese proceso de la red en realidad se podría distinguir entre *Middle Mile* y *Last Mile*. Esto es debido a que entre los centros de Fulfillment y el comprador existen centros intermedios que se ocupan de recibir y descargar una parte de los productos de transportes de gran tamaño, centralizar los pedidos de una pequeña zona, y usar transportes más pequeños para el reparto final. Según donde se encuentre cada comprador, siempre recibirá sus productos desde el mismo centro intermedio, ya que su dirección no cambia y las zonas de influencia de estos centros tampoco. De forma que, siendo rigurosos con la terminología, este trabajo no busca cambiar nada en el *Last Mile*, sino que los cambios se verán en el *Middle Mile*, es decir, en el transporte entre los Fulfillment y los centros intermedios. Esto es debido a que, al realocar los productos, el costo que cambiará en el delivery es el costo de *Middle Mile*. Es decir, que todas las diferencias de costos de delivery que se vean para un mismo producto obedecen al *Middle Mile* y por ende no hay ningún assumption ni modificación sobre el *Last Mile*. Por simplificación, se engloba todo este proceso llamándolo *Last Mile*, siguiendo la nomenclatura de la industria.

En este caso las variables disponibles fueron la cantidad de unidades compradas, la ciudad del comprador, el estado del comprador, la distancia, el volumen del producto, la dimensión máxima (se dispone de ancho, largo y alto y se selecciona la medida máxima entre las 3), el peso, el estado de origen, si es un producto de supermercado y si es un producto pesado o voluminoso (por ejemplo una heladera). En el caso de los productos pesados o voluminosos, este dataset reveló que solamente se almacenan en un depósito de toda la red. Este depósito está completamente dedicado a este tipo de productos ya que son más complejos de manejar. Esto lleva a descartar este depósito

por completo para el análisis, debido a que los productos allí almacenados no se pueden enviar a otros depósitos y ningún producto de otros depósitos se puede enviar aquí. Este depósito sería el N°14, ya descontado de la capacidad total antes presentada.

Además de esto, se probaron variables derivadas, como el día de la semana, si era día hábil, el día del mes, el mes del año, si la ciudad de destino era grande, mediana o pequeña, y la región en la que se encuentra el estado de destino.

Para todos los envíos disponibles en la base (poco más de 3 millones) se buscó las variables que correlacionaron mejor con el costo del envío. Para esto se buscó correr algoritmos de XGBoost y observar el *feature importance* resultante. Se acompañó este análisis con cruces entre el costo de delivery y todas las variables mencionadas. Finalmente, las variables que mejor correlacionaron con la variable a explicar fueron el volumen, la máxima dimensión, el peso, si el producto es de supermercado, el estado de origen y el estado de destino. Las demás variables fueron descartadas como poco explicativas del costo de delivery.

Dado que para el costo de MWH la decisión fue usar el costo volumétrico y que el volumen es una de las variables seleccionadas, en este punto se tomó la decisión de cambiar la variable a predecir del costo nominal al costo volumétrico. Esto llevó a quitar la variable volumen del conjunto de variables explicativas y usar las variables restantes para predecir el costo dividido por el volumen.

En cuanto a los estados de origen y destino, se transformaron en variables numéricas utilizando la técnica de *One Hot Encoding*. Como parte del *Feature Engineering*, también se retiraron los outliers. Finalmente se dividió la base en 3 sets: entrenamiento, validación y test.

Nuevamente se utilizó el algoritmo XGBoost ya que en las pruebas preliminares fue el más performante contra otras implementaciones de Boosteo de árboles, Random Forest y Regresión Lineal. Para determinar los hiperparámetros se procedió a correr 600 modelos mediante la técnica de *random search*, que consiste en generar un conjunto aleatorio de hiperparámetros en un rango determinado para conocer qué combinaciones de hiperparámetros afinan mejor con el problema. Los hiperparámetros a definir fueron la cantidad de árboles, el *learning rate*, la profundidad máxima de cada árbol, el muestreo de filas y de columnas del dataset y el lambda (regularizador). Además se seteó el algoritmo para un corte temprano en caso de que por 30 árboles no se encontraran mejoras en el conjunto de validación. La métrica elegida para el error fue el MAE (*Mean Absolute Error*).

El modelo elegido fue aquel que mejor se comportó en el set de test, que fue el único set que no se usó ni para entrenar ni como validación para el *early stopping* que evita el sobreajuste del algoritmo. Se muestra en la *Figura 12* la salida de este proceso de búsqueda aleatoria de hiperparámetros, donde se muestran los mejores 5 modelos y el modelo N°76 fue el mejor para predecir el set de test. La *Figura 12* muestra también los hiperparámetros utilizados en el modelo definitivo entrenado con todos los datos.

Se presenta también, en la *Figura 13*, las primeras 10 variables del *feature importance* del modelo final. Como puede observarse, las 3 variables numéricas que usó el modelo quedan entre las 10 con las que el modelo toma la mayor parte de las decisiones: dimensión máxima en el ranking N°1, el peso en el ranking N°4 y la variable booleana de productos de supermercado en el ranking

Nº8. El resto de las variables refieren a los estados de origen y destino, que debido al *One Hot Encoding* multiplicaron sus cantidades.

[43]:

	n_estimators	learning_rate	max_depth	colsample_bytree	subsample	lambda	error_train	error_test	algoritmo	tiempo_min	best_iteration
1	134	0.010285	80	0.868856	0.389307	2.207773	4.311547	4.295357	XGBRegressor	2.1	133
76	83	0.019489	41	0.897448	0.446218	6.531064	4.334598	4.291620	XGBRegressor	1.1	82
93	73	0.023545	59	0.809789	0.391217	4.907507	4.348513	4.300498	XGBRegressor	0.9	72
118	117	0.017528	55	0.838272	0.341955	3.133374	4.322053	4.297391	XGBRegressor	1.8	116
245	53	0.029381	45	0.865353	0.476383	5.809039	4.336334	4.297250	XGBRegressor	0.8	52

Figura 12: Salida del algoritmo de Random Search con los mejores 5 modelos y sus hiperparámetros y datos de corrida

Este modelo se utilizó finalmente para generar una **matriz de 3 dimensiones** que tuviera toda la información del costo de delivery. Entonces, para cada **producto** (con un volumen, peso y dimensiones determinados), saliendo en cada estado de **origen** (depósito) y entregado en cada estado de **destino** (demanda), se tiene la predicción del costo volumétrico de entregarlo a un comprador. Esta matriz será más adelante uno de los parámetros utilizados para la optimización.

Finalmente, en este punto ya se dispone de la matriz de costos de MWH y de delivery, con lo cual se puede hacer una comparativa más exacta de ambos costos de transporte. Haciendo el promedio de ambas matrices, se tiene que el costo de delivery es en promedio de 2800 unidades monetarias por unidad de volumen, mientras que en el caso de MWH este promedio es de 185 unidades monetarias por unidad de volumen. Esto implica que transportar una unidad de volumen entre depósitos es en promedio 15 veces más económico que transportar la misma unidad de volumen hasta un comprador. Los factores a los que obedece esto fueron ya explicados.

	cols	feature_importance
2	max_dim_m	0.185084
28	buyer_state_sp	0.179201
16	buyer_state_pa	0.067508
1	weight_kg	0.063970
30	wh_state_mg	0.037840
12	buyer_state_ma	0.031933
21	buyer_state_rj	0.027918
0	is_super	0.024417
8	buyer_state_ce	0.022915
5	buyer_state_am	0.020155

Figura 13: Feature Importante del mejor modelo

Demanda

En esta sección se abordará el problema de la demanda. Esto es, qué productos entran dentro del scope de esta optimización (ya se había referido que eran los productos catalogados, pero se entrará en mayor detalle), cuánto se demanda de cada producto en cada estado en un período de tiempo y cuál es el stock con el que se cuenta.

Selección de Productos a Optimizar

En la sección en donde se analizaron los productos y se generó una segmentación de los mismos usando un algoritmo K-Means, se mencionó que la base total de productos con la que se cuenta son 2 millones. Sin embargo, se hizo la distinción que muchos de esos productos son vendedores distintos publicando el mismo producto, o lo que es lo mismo, que dentro de esos 2 millones hay repetidos. La única forma de identificar a los repetidos entre sí y contabilizarlos como un mismo objeto es el catálogo de la compañía. De manera que con esos 2 millones de productos ya se puede dividir el universo en 2 partes: catalogado y no catalogado. Dentro de los productos catalogados, incluso se puede reducir más el número agrupando los productos iguales,

etiquetándolos con su “producto agrupador”. Finalmente, se pasa de 2 millones de productos a solamente 104.295 “productos agrupadores” únicos.

De hecho, optimizar 2 millones de productos no hubiese sido sensato debido a varias razones. La primera es simplemente computacional, debido a que no se cuenta con los recursos computacionales suficientes para correr una optimización de tantas variables. Recordando el K-Means, por ejemplo el cluster de productos Regionales era el 34% de la base, lo que implica que se tenía ~680.000 productos de este tipo. Se dijo también que estos productos solo podían aloarse en 4 depósitos (B, M, C o S). De manera que no importa por qué depósito ingresen, hay que decidir a cuál de esos 4 enviar qué cantidad de stock disponible. Luego también hay que decidir cómo se abastecerá la demanda de los 27 para todos esos productos. En cantidad de variables de decisión hasta ahora se calculan en 84,32 millones de variables de decisión, como se muestra en el cálculo debajo. Aún así faltan variables que durante el modelado se crearán para darle sentido al problema, haciendo que esta dimensión de optimización no sea posible para el scope del presente trabajo.

$$\text{Vars. Totales} = \text{MWH} + \text{Delivery} = 680000 * 4 * 4 + 680000 * 4 * 27 = 84320000$$

La segunda razón es que, pensando que hay una parte de la base que está catalogada y que por ende dentro de esos 2 millones de productos existen repetidos, no hay razones para asumir que dentro de los productos que hoy no están catalogados no haya también repetidos en “catálogos aún sin identificar”. La compañía tiene un área dedicada a catalogar productos y definir qué partes de la oferta pertenecen a él, y se ocupa de depurar el catálogo y hacerlo fidedigno. Pero al momento de escribir esta investigación, ese trabajo de relevamiento no está completo y no lo estará en lo inmediato. Entonces, ¿qué sentido tendría incluir en la optimización productos que pueden ser iguales que otros? Si se hiciera eso, sin saberlo, se podría estar enviando unidades a un depósito donde ese “producto agrupador” ya tiene stock, pero la compañía no lo sabe.

Por estas razones, la decisión del scope de este trabajo de investigación se cerrará solamente a los productos catalogados, que ofrecen una base firme que permite saber exactamente lo que se hace cuando se toma una decisión y evita los puntos ciegos del sistema. A partir de este punto, se referirá a los “productos agrupadores” simplemente como “productos”, como si estos fueran un producto normal.

Partiendo, entonces, de la nueva base de 104.295 productos de catálogo que se buscará optimizar en la red de fulfillment, se procede a pasarlos por el modelo K-Means, para saber cuántos de ellos son Centrales, cuántos Regionales y cuántos Metropolitanos. No se podría usar la clasificación anterior debido a que ahora estos productos suman las ventas y el precio de todas las publicaciones que agrupan. El resultado se muestra en la *Figura 14*, es que 22.509 de estos productos son Metropolitanos, 48.000 son Regionales y el restante 33.786 son Centrales. Los productos clasificados como Centrales no se transferirán a ningún depósito, por lo que no hay nada que optimizar en ellos y la cantidad de productos a optimizar se reduce a 70.509 entre los otros dos clústers. Si se vuelve a calcular la cantidad de variables de decisión, se tiene que la cantidad de variables de decisión a priori para los productos Regionales baja de 84,32 millones a casi 6 millones, lo cual favorece el proceso de optimización.

	Productos
Central	33786
Regional	48000
Metro	22509

Figura 14: Cantidad de productos de catálogo por clúster

$$\text{Vars. Totales} = \text{MWH} + \text{Delivery} = 48000 * 4 * 4 + 48000 * 4 * 27 = 5952000$$

Como resultado para usar en el momento de la optimización, se dispone de **dos vectores con identificadores de producto**, uno para productos Metropolitanos, y otro para Regionales.

Demanda de los productos

Para determinar la demanda de los productos, es necesario conocer qué cantidad de unidades de cada producto se necesita entregar en cada uno de los 27 estados de destino. La compañía cuenta con algoritmos de forecasting de demanda y áreas específicas que se encargan de mantenerlos y servirlos al resto de la compañía. De esta forma, se entiende que no es un problema dentro del *scope* de esta investigación generar la solución al forecasting de demanda.

Sin embargo, no se tiene acceso a las predicciones de dicho algoritmo para la realización de esta investigación, por decisión de la misma compañía de no compartir los resultados de su algoritmo. Por consiguiente, la decisión que se tomó fue usar un mes de demanda real del pasado de los productos a optimizar.

Como resultado, se presenta en la *Figura 15* un gráfico ilustrativo de la distribución de demanda por cada uno de los 27 estados. En el eje x siempre se tiene la suma de las unidades demandadas de todos los productos en un estado en escala logarítmica, mientras que en el eje y siempre se tiene el promedio de las unidades demandadas. Si bien son variables muy correlacionadas, ofrecen una imagen de demanda global y de demanda promedio por producto en cada estado, dando una idea de cuántos estados traccionan las ventas en el territorio total. En el primer gráfico de la *Figura 15* (izquierda) se tiene solamente los productos Metropolitanos, en el segundo (centro) se tiene solamente los productos Regionales y en el tercero (derecha) se tiene la comparación de ambos conjuntos. En el último se puede apreciar que los productos Metropolitanos tienen un orden de magnitud en su demanda superior al de los Regionales, difiriendo apreciablemente en la demanda por producto.




Figura 15: Distribución de demanda por estado para Productos Metropolitanos, Regionales y conjunto

El resultado de esta búsqueda es que finalmente se tiene para el momento de la optimización una **matriz de 2 dimensiones** que informa para cada uno de los 70.509 **productos** la cantidad demandada en cada uno de los 27 **estados de destino**.

Stock

Este factor es muy importante para la optimización ya que se trata del recurso a optimizar. Cada uno de los 70.509 productos tiene un conjunto de vendedores que los han publicado para su venta. Si bien cada uno de los vendedores es libre de colocar el precio que deseen a sus publicaciones, se sabe que el stock de cada uno de los vendedores de un cierto producto es indistinguible de los demás, gracias a la parte de la oferta del marketplace que ya ha sido catalogada. Esto trae nuevamente una de las hipótesis sobre el problema a resolver, cuyas implicancias serán tratadas a continuación.

Se asumió, en la sección de *Hipótesis Iniciales sobre los Productos*, que esta compañía de marketplace puede tratar el stock de los productos como si fuera un solo vendedor el dueño de todos las unidades en stock (*Commingled Inventory*). ¿Cuáles son las implicancias de esta hipótesis?

Por un lado, hace posible entregar una unidad de stock que, si bien pertenece al vendedor "A", ha sido vendida con la publicación del vendedor "B". El beneficio es que el stock del vendedor "A" se encuentra más cerca del comprador y tiene una mejor promesa de entrega, lo que colabora en generar una conversión mayor. Este incremento de conversión beneficia a todos los vendedores de dicho producto (aumentando el *size of the prize*) y les aumenta las probabilidades de generar ventas. Al mismo tiempo favorece la competencia por precio entre vendedores, hecho que beneficia a los compradores en la posibilidad de conseguir mejores precios.

Por el otro, con la presencia de esta hipótesis (en alguna medida disruptiva), empiezan a existir problemas frente a fallos en los productos y la responsabilidad que cabe a cada vendedor sobre las garantías, así como también qué sucede si un vendedor quisiera retirar su propio stock. En el caso de esta empresa, se tiene solucionada esa parte de trazabilidad, legal y económica de entremezclar stock indistinguible de diferentes vendedores, por lo que se puede aprovechar esta ventaja en la optimización sin la necesidad de brindar una solución a este problema. Si esto no existiera, la optimización se podría realizar de igual forma, pero sin entremezclar el stock de diferentes vendedores, teniendo una mayor cantidad de productos distinguibles a alojar.

Se asume entonces la posibilidad de tratar el stock del mismo producto y vendedores diferentes de forma indistinguible.

Con el fin de obtener una posición de stock determinada para cada producto y poder usar como stock inicial a distribuir en la red, se recurre a mirar el stock actual de estos productos en la red. De esta manera surge como primera observación que aproximadamente un 10% de los productos no tienen stock disponible. Si bien esta situación es la realidad, sería mejor a los fines de la optimización que todos los productos contasen con algo de stock para distribuir y no hacer trivial la distribución de ningún producto. Más allá de querer solucionar un problema real de una compañía, este trabajo de investigación persigue ser académicamente interesante, para lo cual sería más "desafiante" contar con stock de todos los productos en la cartera a optimizar.

Por esta razón, se toma la decisión de generar información sintética mediante una simulación. Observando la distribución real del stock de los productos, se concluye que esta distribución no estaría muy bien representada por una Normal sino con una distribución Gamma donde la forma no fuera simétrica. El resultado de esta distribución se multiplicará por la demanda

global de cada producto, de manera que si el resultado del número aleatorio es 1, el producto contará con la misma cantidad de unidades que requiere la demanda, por ejemplo.

En el caso de los productos Metropolitanos, se elige una Gamma de alfa (parámetro de forma) 2 y beta (parámetro de escala) 0,6, ya que la mitad de los productos contarían con stock suficiente y la otra mitad no. En cuanto a los Regionales, se representa mejor con una Gamma de alfa 6 y beta 0,3, de forma que 13% de los productos no tienen stock para abastecer un mes de demanda. Ambas distribuciones se truncan en 3 veces la demanda para evitar la incidencia de una cola demasiado larga en la distribución. Esto es así porque los productos Metropolitanos suelen tener una baja cobertura de stock en días, debido a que su rápida rotación dificulta a los vendedores enviar muchos días de cobertura. En el caso de los Regionales esto no es así, ya que es más fácil hacer envíos de stock que cubran más tiempo de su demanda. La *Figura 16* muestra las distribuciones Gamma referidas con sus parámetros (de forma y de escala) y marcada la probabilidad de encontrar valores mayores que 1.

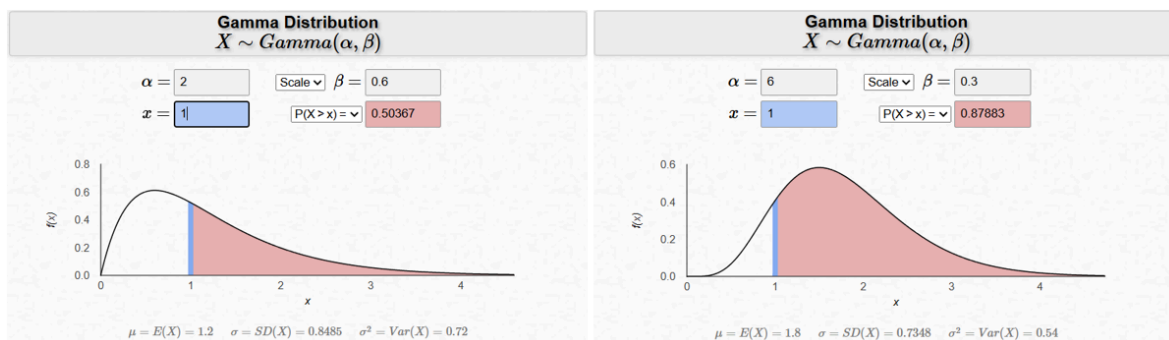


Figura 16: Distribuciones Gamma elegidas para las simulaciones

Además de simular la cantidad de stock para cada producto usando la distribución que le corresponda a su clasificación, se elige solamente 1 depósito en el que se encontrará el stock antes de su optimización. Esto se hizo con un *random choice*, pero la probabilidad no se configura de manera uniforme, ya que el *inbound* de los depósitos no se encuentra balanceado, sino que cada vendedor envía al que más conveniente le resulta. Se usó como probabilidades para el *random choice* el share actual de inbounds que reciben los depósitos, plasmadas en la *Figura 17*. Como fue mencionado previamente, los depósitos B, M, C y S son los únicos habilitados para recibir productos de los vendedores.

Como observación adicional, se podría proponer una topología diferente de red a la actual en donde se reciban los *inbounds* de Fulfillment en instalaciones específicas (llamados *Receiving Centers* o Centros de Recibimiento) y luego se tome la decisión de cómo alocar en la red el stock recibido, enviándolo al depósito óptimo. Este enfoque queda para un trabajo futuro, sin embargo se pueden hacer algunas observaciones sobre el mismo en el presente. El problema en cuestión sería el mismo, aunque se movería el momento de la decisión de alocación al mismo momento en que se reciben los productos. Esto traería algunos beneficios, como ahorrarse el proceso de almacenamiento de los productos en el depósito de origen y luego el proceso de prepararlos para un transporte de *MultiWarehousing*, que probablemente se refleje en una mejora económica y de tiempos. Sin embargo traería aparejado algunas contras, como el hecho de el ahorro en costos variables debería compensar el costo fijo adicional de contar con una instalación de Centros de Recibimiento y el costo variable adicional de transportar los productos Centrales, que de otra forma

se dejarían en el punto de recepción que el vendedor eligiera. Además, tendría un impacto muy apreciable en los modelos que se pueden elegir para optimizar la asignación ya que los modelos de optimización como SCIP pueden tardar horas en sus tiempos de entrega y no sería posible machear la necesidad de respuesta casi inmediata de tener que asignar los productos en su recepción con los tiempos de entrega de dichos algoritmos. En ese caso, habría que recurrir a heurísticas que tengan tiempos de entrega aceptables, resignando optimalidad (y por ende parte del beneficio económico).

¿Por qué simular que el stock, si proviene de varios vendedores, ingresa solamente por un depósito de la red? ¿No sería posible que distintos vendedores del mismo producto prefirieran enviar sus unidades a depósitos distintos? Sí, en efecto es así en la realidad también, sin embargo al simular el estado inicial del stock se decidió tomar la hipótesis más pesimista para la optimización que es que el stock de cada producto está concentrado en una única ubicación. Si se tuviera el stock dividido entre varios depósitos, una parte de la distribución en la red ya estaría realizada y la optimización sería más fácil y requeriría transportar menos unidades en total.

Como resultado del proceso de simulación del stock inicial en la red, tanto en unidades como en ubicación, se tiene una **matriz de 2 dimensiones**, que describe para cada **producto** y cada **estado de origen** (depósito) la cantidad de unidades con que se va a iniciar la optimización y este es el recurso que se quiere gestionar.

Depósito	Share de Inbound
B	2,3%
M	13,3%
C	16,3%
S	68,1%

Figura 17: Perfil de Inbound

Por último, se debe considerar que estos productos no son los únicos almacenados en la red actualmente. Si bien son productos que por una decisión de scope del trabajo no se buscará optimizar, todavía existen y ocupan lugar. Se buscó la ocupación actual de los depósitos y se restó dicha ocupación de la capacidad original de la red, quedando nuevas capacidades disponibles, como se aprecia en la *Figura 18*.

Estado	B	M	P	J	R	C	S
Capacidad	1443.89	5859.63	1814.5	570	358.5	5622.93	19557.14

Figura 18: Capacidades disponibles por estado

Incumplimiento de la demanda

Debido a que se conoce que algunos productos no tienen stock suficiente para cubrir la totalidad de su demanda, es necesario tomar decisiones respecto de qué prioridad tiene cada estado en la satisfacción de la demanda. Para esto, se asignó un valor ficticio de penalización de incumplimiento de demanda por unidad incumplida basado en el costo de delivery promedio de todos los estados. Estos valores se usarán para que el algoritmo de optimización priorice los estados a los que se va a incumplir. Los mismos se pueden observar en la *Figura 19*.

Estado	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27
Penalización	1.000	1.000	1.000	1.000	10.000	1.000	10.000	1.000	1.000	1.000	10.000	1.000	1.000	1.000	10.000	10.000	1.000	10.000	10.000	1.000	1.000	1.000	10.000	10.000	1.000	100.000	1.000

Figura 19: Valores de penalidad por incumplimiento de demanda

Estos números no tienen ningún tipo de significado económico sino más bien reflejan una preferencia de negocio. Es desconocido si la compañía lo evaluaría de la misma forma o lo asignaría distinto.

Modelado del Problema y Optimización

En esta sección se procederá a modelar el problema usando las variables preparadas en la sección anterior. El objetivo será enunciar el problema en una forma lógica y matemática que permitirá escribirlo en un formato entendible por SCIP, en este caso el formato elegido es Zimpl. Finalmente, se obtendrá un resultado del software de optimización, que en una sección futura se interpretará para obtener conclusiones útiles de negocio.

Modelado

Debido a que se utilizarán técnicas de optimización de programación lineal mixta, es necesario poder escribir el modelo en los términos matemáticos estándar de esa rama del conocimiento. Esto es, que se buscará optimizar mirando una única función objetivo, definiendo un conjunto de variables y parámetros que representan a todos los aspectos del problema y finalmente definiendo un conjunto de restricciones que la solución debe atender para ser útil a la situación real que se quiere solucionar.

Descripción Gráfica del Problema

Antes de escribir el modelo, se procede a dibujarlo como un problema de flujo utilizando un grafo, de manera que pueda quedar clara la naturaleza del problema. Vale decir, se representa con un conjunto de vértices o nodos unidos mediante aristas. El grafo se observa en la *Figura 20*.




Figura 20: Grafo ilustrativo del problema

Para explicar esta representación, se comienza por aclarar que la imagen de la *Figura 20* es una simplificación del grafo real, debido a la cantidad de conexiones y complejidad del grafo real. Si se hubiera representado como realmente es, sería imposible entenderlo debido a la enorme

cantidad de aristas que tendría cruzando todo el grafo, de manera que se prioriza la comprensión de la situación por sobre la representación exacta.

El grafo tiene dos tipos de vértices y dos tipos de aristas. En tonos de azul (del lado izquierdo) se tiene a los 7 vértices que representan los 7 depósitos de la red. Las aristas celestes son las que representan los movimientos de redistribución del stock en la red (MWH). Debido a que el stock en algunos casos puede circular bidireccionalmente por estas aristas, se las representó sin una dirección definida. Al mismo tiempo es necesario entender que por las aristas circulan muchos productos distintos y pueden circular en direcciones distintas. Por ejemplo, sería posible que el producto "A" viaje del vértice S al M y que el producto "B" circule del vértice M al S.

Luego, están los vértices y aristas en tonos de rojo (del lado derecho del grafo), que representan los movimientos hacia el fulfillment de la demanda. Cada vértice con fondo rojo representa uno de los 27 estados que demandan productos de esta red de depósitos. No se representaron los 27 por simplicidad. Cada arista, representa el flujo de fulfillment de los productos desde la red hacia la demanda (Se representaron desde un sólo depósito también por simplicidad). En este caso, las aristas sí son direccionadas, ya que los productos pueden viajar desde los depósitos hacia un comprador ubicado en un estado pero no pueden volver, al menos no en esta versión sin logística inversa (devoluciones).

Por último, en estas aristas rojas de demanda podría pensarse, no sin algo de abstracción, que además de las unidades de productos para abastecer la demanda, también viajan las unidades de incumplimiento de demanda. Se conoce, como fue explicado antes, que el stock de los productos puede ser insuficiente para abastecer la demanda de dicho producto, en cuyo caso se incumple. Este fenómeno, debe estar modelado también ya que se quiere que el optimizador decida con cierto criterio de prioridad qué demanda abastecer "antes" y qué demanda abastecer "después".

De esta manera se procede a plantear un modelo que plasme en términos matemáticos todas las interacciones en el grafo.

Planteo del Modelo Formal

Para la escritura del modelo en lenguaje formal, hay dos aspectos que se consideraron. El primero es, como fue mencionado, que el lenguaje de programación para alimentar a SCIP será Zimpl, por lo que se escribirá el modelo utilizando la misma estructura que sigue Zimpl en su gramática: conjuntos, parámetros, variables, función objetivo y restricciones. El segundo es que se decidió plantear el problema como un problema de flujo, por lo que se modelará como tal. Esto es, usando restricciones de balance de los nodos y de capacidad de los nodos. En este caso no se considerarán restricciones de capacidad de los arcos o aristas, debido a que no es una restricción que la compañía tenga. Esto es así porque la red logística es propia y cuenta con la flexibilidad suficiente para escalar en caso de ser necesario.

Un último aspecto a considerar sobre las particularidades de este problema de flujo es el de las triangulaciones. En un problema de flujo normal, no hay ningún inconveniente con que las unidades corran a través del grafo siguiendo un camino poco intuitivo (pero óptimo) y recorran varios nodos hasta llegar al sumidero (en este caso a la demanda del cliente). Sin embargo, este aspecto no representa fielmente la realidad del problema que se busca resolver en este trabajo de investigación.

Si se piensa qué implica que un producto recorra varios nodos en esta situación, equivaldría a que sea cargado en un camión en el depósito 1 y viaje hasta el depósito 2. Allí el camión sería parcialmente descargado, su mercadería desconsolidada y pasaría horas (o hasta días) parado en un depósito. Luego marcharía con los productos cargados en el depósito 1 hasta el depósito 3. Recién en ese momento el producto sería descargado, desconsolidado, procesado y ubicado en una estantería. Sólo a partir de ese momento, el producto pasaría a estar disponible para la venta. El inconveniente es que podría parecer que ese camino fue óptimo, pero sería necesario modelar el costo de oportunidad de no haberlo tenido disponible para la venta todo ese tiempo en lugar del tiempo necesario para ir directamente del depósito 1 al depósito 3, el riesgo adicional de daños por un transporte de más distancia y un manipuleo adicional y el riesgo de que el vendedor tenga una mala experiencia viendo su stock no disponible por demasiado tiempo y eleve una queja a través de los canales de la empresa. Debido a que todo esto no se está modelando, y que además la empresa actualmente no hace transportes con dichas triangulaciones, es que se decidirá restringir esta posibilidad del modelo. Esto lleva a crear una variable adicional y dos restricciones adicionales.

Otro enfoque que se podría haber considerado es el plasmar esta realidad en la función objetivo en lugar de las restricciones. Esto sería, penalizar el uso de triangulaciones, sin prohibirlo y permitir al modelo optar por triangulaciones en caso de que las mismas resulten altamente beneficiosas. Este enfoque queda para un futuro trabajo.

Para la escritura del modelo se recurre a los elementos creados en las secciones anteriores. Estos vectores y matrices en los que se fueron resumiendo la información que describe la red y el problema son ahora los parámetros del modelado. En cada uno de ellos se puede ver la cantidad de variables de las que dependen correlacionando con las dimensiones de las matrices o vectores descritos en las secciones previas. La enunciación del modelo es, finalmente, la siguiente:

Conjuntos:

O: Estados de Origen

D: Estados de Destino

P: Productos

Parámetros:

VP (p): Volúmen de los Productos (p) en m^3

VO (o): Capacidad de almacenamiento en m^3 en los estados de Origen (o)

CMWH (oo, od): Costo Volumétrico ($\$/m^3$) de mover el stock de un Estado de Origen (oo) a otro Estado de Origen (od)

CD (o, d, p): Costo Volumétrico ($\$/m^3$) de entregar un Producto (p) desde un Estado de Origen(o) hasta un Estado de Destino (d)

D (d, p): Demanda en unidades de un Producto (p) en un Estado de Destino (d)

S (o, p): Stock en unidades de un Producto (p) en un Estado de Origen (o)

CI (d): Costo unitario de incumplir la demanda en un Estado de Destino (d)

Variables:

X (o, d, p): Cantidad de unidades que se entregan en satisfacción de demanda del Producto (p) desde el Estado de Origen (o) hasta el Estado de Destino (d)

$M(oo, od, p)$: Cantidad de unidades del Producto (p) que se transportan entre depósitos desde el Estado de Origen (oo) hasta el Estado de Origen (od)

$I(d, p)$: Cantidad de unidades del Producto (p) en que se incumple la demanda del Estado de Destino (d)

$B(o, p)$: Variable binaria que indica si el Estado de Origen (o) recibe envíos del Producto (p) desde cualquier otro depósito de la red

Función Objetivo: Min (Costo Multi-Warehousing + Costo Delivery + Costo Incumplimiento)

$$\begin{aligned} \text{Min} [& \sum_{oo} \sum_{od} \sum_p CMWH(oo, od) * M(oo, od, p) * VP(p) + \sum_o \sum_d \sum_p CD(o, d, p) * X(o, d, p) * VP(p) \dots \\ & \dots + \sum_d \sum_p CI(d) * I(d, p)] \end{aligned}$$

Restricciones:

- Balance en nodos de Origen (unidades):

$$S(oo, p) + \sum_{od} M(od, oo, p) \geq \sum_{od} M(oo, od, p) + \sum_d X(oo, d, p) \quad \forall oo \in O \wedge p \in P$$

- Balance en nodos de Destino (unidades):

$$\sum_o X(o, d, p) = D(d, p) - I(d, p) \quad \forall d \in D \wedge p \in P$$

- Capacidad en cada Estado de Origen (metros cúbicos):

$$\sum_p S(oo, p) * VP(p) + \sum_{od} \sum_p M(od, oo, p) * VP(p) - \sum_{od} \sum_p M(oo, od, p) * VP(p) \dots$$

$$\dots - \sum_d \sum_p X(oo, d, p) * VP(p) \leq VO(o) \quad \forall oo \in O$$

- Activación de la Variable Binaria

$$10^6 \cdot B(od, p) \geq \sum_{oo} M(oo, od, p) \geq B(od, p) \quad \forall od \in O \wedge p \in P$$

- Impedimento de Triangulación

$$\sum_{oo} M(od, oo, p) \leq 10^6 \cdot [1 - B(od, p)] \quad \forall od \in O \wedge p \in P$$

- Dominio de las Variables

$$X \in \mathbb{Z}, X \geq 0 \quad \forall o \in O \wedge d \in D \wedge p \in P$$

$$M \in \mathbb{Z}, X \geq 0 \quad \forall oo \in O \wedge od \in O \wedge p \in P$$

$$I \in \mathbb{Z}, X \geq 0 \quad \forall d \in D \wedge p \in P$$

$$B \in \{0; 1\} \quad \forall o \in O \wedge p \in P$$

Optimización

Se abordará en este espacio la aproximación y los inconvenientes encontrados durante la optimización, así como las soluciones aplicadas.

Aproximación y Enfoque hacia la Optimización

Debido a que la cantidad de productos, depósitos y estados de destino lleva al problema a tener una dimensionalidad muy alta, se plantean formas de reducir dicha dimensionalidad y facilitar la escalabilidad de la optimización. De hecho, durante el desarrollo previo ya se tomaron decisiones que contribuyeron a reducir la dimensionalidad del problema sin afectar el objetivo general. Por ejemplo, la decisión de solo usar productos catalogados y plantear la capacidad de entremezclar el stock de diferentes vendedores son dos factores que redujeron la dimensionalidad del problema y volvieron la optimización una tarea más realizable.

La primera observación, que es prácticamente trivial, es que los productos se dividieron en Metropolitanos y Regionales. Los Metropolitanos se pueden alocar en depósitos Metropolitanos, lo que hace que puedan ir a 7 estados de origen (depósitos), mientras que los Regionales sólo pueden ir a 4 (B, M, C y S). Esto hace que sea deseable tratarlos por separado, ya que tendría el beneficio de no agregar restricciones para la distribución de los productos Regionales y además dividiría el problema en dos partes. Primero, entonces, se optimiza la distribución en la red de los productos Metropolitanos, ya que estos son más relevantes para el negocio, como se observó en el apartado sobre la demanda de los productos. Una vez terminado, se procede a optimizar la distribución de los Regionales. Esto implica también aceptar que la solución óptima puede ser diferente que haciendo todo el problema en una sola etapa, sin embargo se ha comprobado que las herramientas de que se disponen para realizar esta optimización (24GB de RAM) son insuficientes para la tarea.

Se podría haber decidido optimizar al revés, primero los Regionales y luego los Metropolitanos, siendo que los primeros tienen menos depósitos donde pueden ser alocados. Sin embargo, siendo que los Metropolitanos son tanto más relevantes para el negocio que los Regionales (como indican los datos), no sería aceptable que los productos Regionales hicieran que el espacio fuera limitante para alocar los Metropolitanos. Por eso se prefiere el enfoque de decidir sobre los productos más importantes primero y luego sobre los de menor importancia.

Esto hace que el plan de optimización sea:

1. Escritura del archivo Zimpl para los productos Metropolitanos
2. 1° Etapa de optimización
3. Recálculo de espacio en cada depósito considerando la distribución en la optimización de los productos Metropolitanos
4. Escritura del archivo Zimpl para los productos Regionales
5. 2° Etapa de optimización

De esta manera se encararon los primeros intentos de optimizar el modelo completo de una red logística de fulfillment en cuanto a la distribución geográfica del stock.

Inconvenientes y Soluciones

Como era de esperarse, la optimización no fue lograda sin sus pormenores, lo que llevó a cambiar la estrategia de optimización para que se adecuara a los recursos disponibles. Si bien esta versión del modelo pudo haber sido planteada desde el principio, se juzgó con más valor plantear la versión “idealizada” y finalmente la versión “realizable”, ya que cualquiera con más recursos que los que estuvieron disponibles para esta optimización podría querer usar la versión ideal de cómo resolver el problema planteada en secciones previas.

El inconveniente principal, fue que la computadora de que se disponía, con 24GB de memoria RAM, rompía el proceso antes de llegar a la solución debido a la cantidad de variables y restricciones a considerar.

Para solucionar este problema, se decidió eliminar del planteo la variable B (variable binaria para evitar triangulaciones) con las dos restricciones que la involucran. De esta manera, se redujo la dimensionalidad del problema a uno con menos variables, menos restricciones y sin variables binarias. Esto resultó una decisión muy favorable para la etapa N°1 de optimización, que logró llegar hasta el final y devolver un resultado. Resulta que el problema de flujo en esta instancia es un problema cuya solución de la relajación lineal es entera, debido al uso del problema de flujo. Se sabe que esto es así debido a que en la respuesta de SCIP, el modelo reporta que recorrió 1 solo nodo del árbol.

Otra forma de reducción de dimensionalidad podría haber sido dividir el universo de productos usando agrupadores que la empresa tiene por tipo de productos (por ejemplo, electrónica, vestimenta, etc). Sin embargo, dado que la optimización de estos grupos sería secuencias, implicaría decidir qué grupo de productos tiene prioridad sobre otros y recibiría espacio antes que los demás. Se optó por no tomar ese camino, debido a la complejidad que agregaría y también a que volvería la solución menos genérica y más enfocada en el marketplace en cuestión.

Sin embargo, resulta inaceptable para la solución dejar triangulaciones, por las razones ya explicadas. Por esto, fue necesario reemplazar esta variable y sus restricciones por un procesamiento posterior de la solución. En concreto, se creó un script greedy dedicado a romper las triangulaciones. Esto no fue “gratis”, debido a que al modificar manualmente las soluciones óptimas, se está resignando la optimalidad de la solución final. Partiendo de una solución óptima, se asume que la solución final es buena, sin embargo no se puede afirmar que sea óptima.

En concreto, el script implementado recorre todas las variables de la solución apoyándose en que cada producto fue asignado con un depósito de origen donde inicialmente se encuentra la totalidad de su stock. De esta manera, todo movimiento con la variable M (de transporte entre depósitos) que no provenga del depósito de origen se sabe “ilegal” y se sabe también que existe un transporte previo en otra variable M que lo llevó hasta el depósito intermedio. El script luego rastrea ese movimiento anterior de dicho producto que lo llevó hasta el depósito del que parte el movimiento ilegal. Con este movimiento puede “destriangular”: hace que el transporte ilegal vaya a 0 unidades y descuenta las unidades ilegales del transporte previo, asignándolas a un transporte que corta esa triangulación. Este proceso se repite iterativamente para cortar cadenas de 4 o más transportes ilegales, hasta que en cada producto todas las M tienen como origen el depósito inicial

asignado a ese producto. En la *Figura 21* se esquematiza este proceso, de forma que quede claro el cambio realizado y por qué se lo describe como una lógica de tipo greedy.

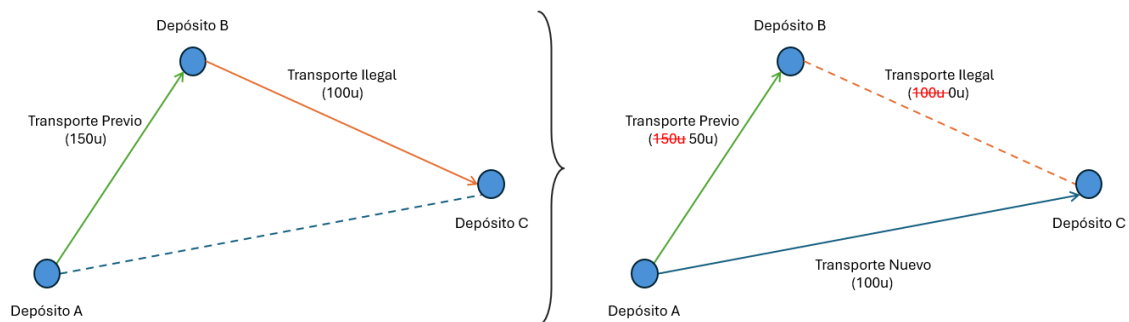


Figura 21: Esquemización del funcionamiento del algoritmo para romper triangulaciones

El segundo inconveniente que surgió en esta etapa, fue que la etapa N°2 de optimización, la correspondiente a los productos Regionales, no logró llegar al final debido a falta de memoria RAM. Frente a la etapa N°1, esta etapa tiene mayor cantidad de variables a priori que resolver (3,06 millones frente a 5,95 millones), por lo que resultó imposible de optimizar. Para solucionar este inconveniente se dividió a los productos regionales en dos partes iguales de 24.000 productos cada una, adicionando una tercera etapa de optimización.

Finalmente, el plan originalmente planteado fue modificado, quedando de la siguiente forma:

1. Escritura del archivo Zimpl para los productos Metropolitanos
2. 1° Etapa de optimización (Metro)
3. Rotura de Triangulaciones
4. Recálculo de espacio en cada depósito considerando la distribución en la optimización de los productos Metropolitanos
5. Escritura del archivo Zimpl para los productos Regionales Parte 1
6. 2° Etapa de optimización (Regional Parte 1)
7. Rotura de Triangulaciones
8. Recálculo de espacio en cada depósito considerando la distribución en la optimización de los productos Metropolitanos y Regionales Parte 1
9. Escritura del archivo Zimpl para los productos Regionales Parte 2
10. 3° Etapa de optimización (Regional Parte 2)
11. Rotura de Triangulaciones

Con estos “parches” en el proceso, se logró una corrida completa del proceso de optimización. De punta a punta el mismo demoró unas 12 horas para completarse. Es evidente, o por lo menos probable, que una empresa grande con herramientas más potentes podría haber resuelto el flujo original con las variables y restricciones originales. Sin embargo, las modificaciones impuestas por las limitaciones de esta investigación fueron superadas y se logró el objetivo de conseguir una solución que, si bien no se puede asegurar óptima, es una heurística aceptable. Resta analizar los resultados de la misma a nivel económico para concluir si es mejor que no hacer nada en términos de distribución de stock en la red.

Interpretación de Resultados

En esta sección del presente trabajo de investigación se buscará presentar y explicar los resultados obtenidos de la optimización. No se ahondará en las implicancias de negocio que tienen estos resultados, sino que se los analizará desde un punto de vista meramente económico y enfocando el caso base abordado hasta el momento. Dicho análisis se abordará en la sección de Conclusiones.

Costos Sin Optimización

Antes de comenzar con el resultado de la optimización, es lógico presentar la situación antes de optimizar. De hecho, es indispensable el cálculo de esta situación debido a que el resultado de la optimización solo arroja un número, que carece de significado sin nada contra qué compararlo, sin un benchmark de algo que se busca mejorar.

Por esta razón se procede a calcular los costos de distribuir el stock inicial desde la ubicación que le fue asignada antes de la optimización hacia donde se encuentra su demanda. Es decir, si no se recurriera en absoluto al MWH (redistribuir el stock entre los *warehouses* de forma que se acerque el stock a la demanda), ¿cuánto costaría la satisfacción de la demanda?

En el caso que se está abordando, se sabe que algunos productos no tienen stock suficiente como para satisfacer toda la demanda, de manera que se busca para este caso base, que será usado de benchmark, satisfacer la misma demanda que el caso optimizado. Con lo cual, se tomarán las variables $X(o,d,p)$ del modelo planteado, con la salvedad de que el origen será fijo para cada producto (según el WH asignado en la sección *Stock*) y no el que viene como resultado de la optimización. Cada X acarrea un costo que depende del origen, destino y producto. Este costo se puede calcular con suma facilidad debido a que en la sección *Costos de Delivery* fue creada una matriz de costos volumétricos para satisfacer la demanda. La forma de cálculo de este costo es análoga a la planteada en la función objetivo del modelo, y es la siguiente:

Siendo o el origen, d el destino, p el producto y s' el WH asignado al producto p :

$$Costo = \sum DeliveryCostMatrix[s', d, p] * X[o, d, p] * Volumen[p]$$

Este mismo cálculo se aplica para los productos Metropolitanos y para las Partes 1 y 2 de los Productos Regionales. El resultado es que la distribución sin ningún tipo de optimización para los Productos Metropolitanos cuesta un total de 17,3 millones de unidades monetarias (UM), para los Productos Regionales Parte 1 cuesta 2,4 millones de UM y para los Regionales Parte 2 cuesta 2,5 millones de UM. El total de la distribución para los productos enfocados es de 22,2 millones de UM. Este será el benchmark a mejorar mediante la optimización.

Costo Con Optimización

En cuanto al costo usando la optimización, éste se compone de 2 partes: el costo de redistribución del stock (MWH) y el costo de Delivery o Fulfillment. Si bien en el modelo también están las variables de incumplimiento de demanda, esta variable tenía el objetivo de ayudar a SCIP a

priorizar que demanda atender primero y qué demanda atender con última prioridad, con lo cual se lo puede considerar un costo ficticio. Aun si no fuera así, y se quisiera contabilizar ese costo de oportunidad de alguna manera, debido a que el benchmark cumple e incumple con la demanda igual que en la fase optimización, no tendría sentido calcular el mismo número para los dos casos.

Costo de MWH

Para calcular el costo de MWH se debe recurrir a las variables M de la salida de SCIP. M representa en el modelo la cantidad de unidades que se mueven entre depósitos desde un depósito de origen a un depósito de destino, donde el stock esperará ser demandado y transportado hasta un comprador. Luego también en la sección *Costos de MWH* se calculó la matriz de costos volumétricos de hacer estos movimientos. El cálculo del costo es el siguiente, al igual que en la función objetivo del modelo:

Siendo oo el depósito de origen, od el depósito de destino y p el producto:

$$\text{Costo} = \sum MWHCostMatrix[oo, od, p] * M[oo, od, p] * Volumen[p]$$

El resultado es que los costos de mover el stock entre depósitos tal como indicó el modelo es para el MWH de Productos Metropolitanos es de 329 mil UM, para los Regionales Parte 1 de 176 mil UM y para los Regionales Parte 2 de 178 mil UM. El total consolidado es de 682 mil UM. El costo de este tipo de movimientos es considerablemente más económico que el de transporte al comprador, como fue aclarado previamente.

Costo de Fulfillment

En el caso de este costo, se procede exactamente igual que en el cálculo sin optimización, con la salvedad de que ahora sí se respetará el depósito de origen de las variables X devueltas por SCIP. La variable X del modelo representa la cantidad de unidades entregadas desde un depósito hasta un estado de un producto. El cálculo es el siguiente:

Siendo o el origen, d el destino y p el producto:

$$\text{Costo} = \sum DeliveryCostMatrix[o, d, p] * X[o, d, p] * Volumen[p]$$

Como resultado, se obtiene que los costos de Fulfillment o Delivery para el caso optimizado son de 15,7 millones de UM para los Productos Metropolitanos, de 2,2 millones de UM para los Productos Regionales Parte 1 y de 2,3 millones de UM para los Productos Regionales Parte 2. Esto totaliza un costo de 20,2 millones de UM.

Beneficio de la Optimización

Simplemente con el objetivo de agrupar todos los resultados y hacer una comparación de ambos escenarios (sin y con optimización), se presenta en la *Figura 22* todos los costos calculados hasta el momento, cada uno en su universo de productos.

La comparación se efectúa tomando el único costo del escenario sin optimización contra los dos costos del escenario con optimización. Como puede apreciarse, el grupo con mayor reducción de costos es el de los Productos Metropolitanos, con un ahorro nominal de 1,22 millones de UM y un 7,1% de reducción de costos. En los casos de Productos Regionales Parte 1 y 2 se genera un ahorro nominal de 0,03 millones de UM y 0,04 millones de UM respectivamente, lo que representa un 1,3% y 1,6% respectivamente. En todos los casos se percibe un ahorro debido a la optimización que implica redistribuir el stock a lo largo de la red con el objetivo de la cercanía al usuario.

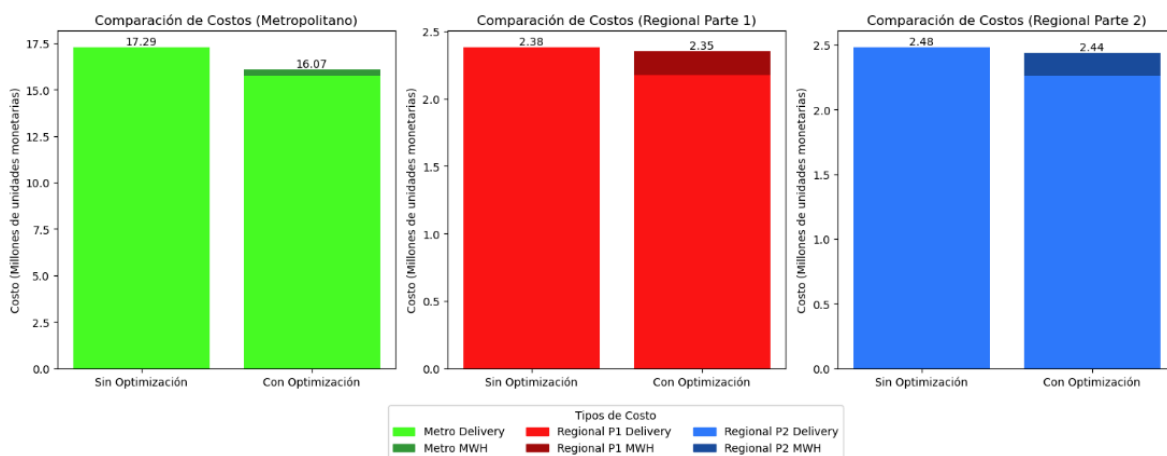


Figura 22: Comparación de costos entre escenarios sin y con optimización separado por etapas de optimización

La razón por la que el mayor ahorro se produce en el caso Metropolitano es que esos productos tienen un volumen de ventas considerablemente mayor, como fue demostrado en secciones anteriores, y eso hace que los ahorros se separen apreciablemente de los Regionales.

En la *Figura 23* se encuentra la misma representación comparando ambos escenarios, aunque sin dividir por universo de producto. Esto muestra la magnitud del ahorro de costos totales en la logística del conjunto de productos estudiados por implementar el MWH. Se puede ver que el ahorro nominal es de 1,30 millones de UM, lo cual representa un ahorro del 5,9% (intermedio entre los valores de los universos por separado).

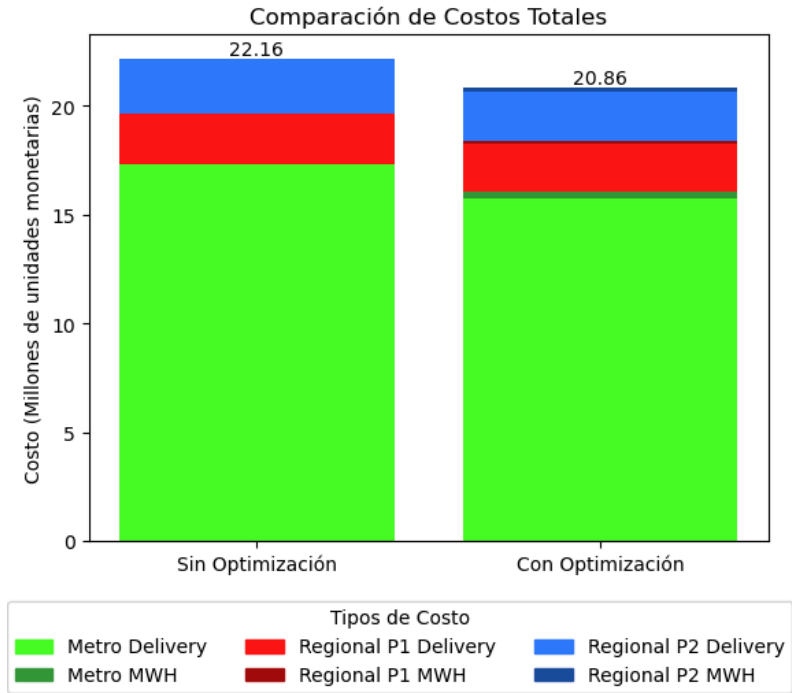


Figura 23: Comparación de costos totales entre escenario sin y con optimización.

Conclusiones e Implicancias de Negocio

Durante esta última sección se estarán repasando todas las conclusiones recogidas a lo largo del proceso seguido y se pondrá sobre relieve las utilidades e implicancias de negocio que trae la presente investigación a la mesa de estrategias para pensar redes de fulfillment.

Conclusiones

El presente trabajo tenía como objetivo principal optimizar la gestión del stock de una red de fulfillment, mediante la alocaión del stock de forma inteligente en los nodos de la red intentando seguir la demanda y acercando los productos que los compradores valoran obtener rápido a sus puntos de demanda.

Luego de haber seguido un meticuloso proceso de obtención, análisis, depuración y procesamiento de la información necesaria para este ambicioso objetivo, luego de haber creado modelos de clusterización, predictivos y de optimización y luego de haber programado en Python un sistema completo de optimización repetible para distintos datos de entrada, se concluye que es posible mejorar y optimizar las redes logísticas, que es una actividad necesaria y que rinde sus frutos en términos económicos.

Perspectiva Económica

Para el caso de estudio presentado, se ha logrado optimizar los costos de la red en un 5,9% en todo el universo de productos estudiado, y un 7,1% en el mejor cluster de productos (llamado Metropolitano). Esto implica ahorros por 1,3 millones de unidades monetarias (UM). El período de este ahorro es mensual, debido a que la demanda fue tomada de un mes real de operaciones. Es decir que se puede estimar un ahorro nominal de 15,6 millones de UM al año.

Un aspecto adicional para incluir dentro de las conclusiones económicas es el que atañe a una de las hipótesis tomadas como premisa para simplificar el modelo original. Durante el proceso, se asumió que cada producto solamente se encontraba alocado en un depósito, lo cual es poco realista si se considera que cada producto en verdad lo venden varios vendedores y cada uno envía su stock al depósito más cercano. El hecho de que los productos ya estén en parte distribuidos en la red ocasiona que se pueda cosechar parte de los beneficios de realocarlos sin parte de los costos que ello implica. Esto se debe a que además se empezaría a entremezclar el stock y se podría abastecer las ventas desde pilas de stock de cualquier vendedor desde el depósito más conveniente. Si bien la compañía ya hace esto, no lo hace en la escala necesaria para conseguir los beneficios de tener el stock de los productos catalogados distribuidos a lo largo de la red. Escalar esta actividad, unido a la distribución natural del stock de distintos vendedores, aportaría una eficiencia adicional al proceso de optimización que contribuiría a mejorar el aspecto económico de esta iniciativa. Modelar este comportamiento habría sido complejo y habría llevado a tomar más hipótesis, volviendo la solución un poco más rígida.

En términos de cómo funciona el modelo presentado, la anulación de esta hipótesis no implica ninguna modificación y la implementación del código sería completamente equivalente. La única discrepancia respecto a lo planteado en el presente trabajo de investigación es que la matriz de

stock inicial, que es un dato de entrada del sistema de optimización creado, reflejaría este cambio y tomaría incluso mayor importancia la restricción que impide triangulaciones, que no se pudo implementar en la optimización por limitaciones de recursos computacionales, pero se suplió con un pequeño script para modificar las soluciones óptimas. La hipótesis en cuestión obliga a esta matriz a tener solamente un valor distinto de cero por cada columna, mientras que su anulación permite mayor libertad en ese sentido.

Perspectiva Financiera

Se podría también tomar lo realizado por la optimización como un caso de negocio que se puede evaluar, no sólo económicamente como ya se hizo, sino también financieramente. Si se considerara el gasto en MWH como una inversión que se realiza y el ahorro en costos de delivery como el retorno a dicha inversión, se tiene que con una inversión mensual de 0,68 millones de UM se logra bajar el costo de delivery de 22,16 millones de UM a 20,20 millones de UM, lo que representa un flujo positivo (ahorro) de 1,96 millones de UM. Esto implica una tasa de retorno de la inversión intra mensual del 188%. Debido a que esta operación de optimización se puede repetir todos los meses de forma regular, y que la inversión y el ahorro se generan en el mismo mes y casi de continuo, no es necesario aplicar una tasa de descuento entre ambas. Se podría decir que el aporte de valor a la compañía es de la diferencia entre ambos números (1,3 millones de UM al mes). Sin embargo, para valuar el proyecto, se puede calcular en forma de un *Perpetuity*, con una tasa de descuento. La tasa de referencia del país en que se ubica la red de fulfillment estudiada (cuyo nombre no ha sido revelado para proteger la identidad de la compañía) es de alrededor de 14% anual, lo que equivale a un 1,098% mensual. Como hipótesis, no se asume ninguna tasa de crecimiento en la aplicación de la fórmula, ya que no se tiene forma de estimar una. Esta hipótesis es conservadora debido a que una tasa de crecimiento del *Perpetuity* aumentaría el valor presente de la solución, al restarse con la i en el denominador del cálculo. La fórmula con la que se calcula el valor actual de un *Perpetuity* es la siguiente:

$$\text{Perpetuity Present Value} = \frac{C}{i} = \frac{1,3 \text{ millones}}{0,01098} = 118,4 \text{ millones}$$

Se puede estimar que un flujo positivo mensual adicional de 1,3 millones de UM tiene un valor presente de 118,4 millones de UM descontado a una tasa de interés del 1,098% mensual. Esto equivale a que si la compañía decidiera comprar un producto enlatado que hiciera esta labor de optimización de forma mensual, debería estar dispuesta a pagar hasta un máximo de 118,4 millones de UM para ponerlo en funcionamiento.

Perspectiva de Demanda

Una conclusión adicional observada durante este proceso se encuentra del lado de la demanda. Si bien la mayor parte de los esfuerzos fue puesto del lado de la oferta de productos, se ha mencionado un detalle sobre el lado de la demanda. Este aspecto no ha sido tenido en cuenta a la hora de realizar la optimización debido a que el objetivo buscaba nada más (ni nada menos) que optimizar los costos logísticos de la red. Sin embargo, en este punto es necesario volver a traerlo para que su efecto se una a las conclusiones, aunque no haya sido medurado.

Durante la clusterización de los productos, en la primera sección de este trabajo, se mencionó que los usuarios valoran en algunos productos el hecho de tener una promesa de entrega más corta o, lo que es lo mismo, tener los productos más cerca. Esto era conocido debido a que la tasa de conversión en algunos productos aumentaba a medida que las promesas de entrega se acortaban, mientras que otros productos se mantenían constantes o aumentaban menos. Esto fue modelado con un cálculo de sensibilidad de la tasa de conversión a la promesa de entrega, y esta variable fue utilizada para clusterizar a los productos. De alguna manera se puede afirmar que la perspectiva de demanda está presente en las conclusiones volcadas hasta el momento, y se estaría en lo correcto, aunque incompleto, ya que se ha considerado la influencia de la demanda pero su efecto no está factorizado en los resultados.

Lo que no se consideró es que la demanda aumentaría debido a la redistribución del stock a lo largo de la red, ya que muchos usuarios que valoran promesas cortas habrían convertido más. Debido a este efecto, las ventas deberían aumentar en virtud de mejorar las promesas de entrega en todo el territorio. Nuevamente, no se consideró este efecto en la cuantificación de los resultados debido a que se apuntaba a la optimización de los costos, sin embargo es necesario contemplarlo en esta sección.

El modelo entrenado de K-Means clusteriza los productos en 20 clústers y solamente 3 de ellos eran finalmente Productos Metropolitanos. En la *Figura 8* se aprecia que la sensibilidad de la conversión promedio de estos 3 clústers (N°5, 13 y 16) son 1,384, 1,392 y 1,277 respectivamente. Esto denota tasas de conversión entre un 27% y un 39% más altas con promesas rápidas. Luego también algunos de los clústers de Productos Regionales cuya sensibilidad de la tasa de conversión es de 1,549, 1,538 y 1,514, lo que denota tasas de más de un 50% de diferencia entre la conversión de promesas rápidas que de promesas lentas.

Esto sugiere que la compañía, mediante esta optimización, no solo lograría reducir sus costos, sino también mejorar en la cantidad de conversiones y lograría que más usuarios empiecen a comprar en el mundo digital en lugar del físico o que compren en este marketplace y no en el de la competencia. Esto a su vez generaría mayor transaccionalidad en la plataforma, atrayendo a más vendedores y reforzando los efectos de plataforma vigentes en el marketplace.

Implicancias de Negocio

Además de los beneficios, cuantificados o no, que fueron mencionados para el negocio del marketplace ocasionados por la decisión de optimizar la locación del stock de los vendedores a lo largo de la red de fulfillment, se mencionan a continuación algunas implicancias adicionales.

La primera implicancia, quizás la más obvia, es que los recursos computacionales de los que se disponía no fueron suficientes para cumplir el objetivo de optimizar el modelo planteado. Esto, como fue expresado en su momento, obliga a resignar la optimalidad de la solución y, por consiguiente, lleva a concluir que una empresa sin dichas limitaciones podrá correr el modelo originalmente planteado, llegando a resultados potencialmente mejores en lo económico y en la eficiencia operativa.

Riesgos

Otra implicancia a considerar son los riesgos. Si bien se habló ya de un flujo de fondos y el cálculo de una *Perpetuity*, no se habló de los riesgos que trae este tipo de optimización. De hecho, no son en absoluto triviales, por lo que se mencionará dichos riesgos y posibles formas de mitigarlos, buscando que no se materialicen y destruyan el valor creado por el proyecto.

El primero de los riesgos visibles, es la predicción de la demanda. En el presente documento se utiliza un mes de demanda real, pero la compañía debería alimentar el modelo de optimización con la demanda futura proyectada en lugar de con la demanda pasada. El riesgo de predecir la demanda es obvio, ya que la demanda cuenta con su propia volatilidad y los modelos de *forecasting* siempre tienen su error de predicción. De hecho, por definición, todo *forecast* está equivocado, la cuestión es por cuánto. Parte de la mitigación de este riesgo ya está incluida en este trabajo cuando se intenta seleccionar muy bien los productos que participarán de la optimización.

Si uno tomara una publicación común de este marketplace y observara sus ventas, se daría cuenta rápidamente de que la gran mayoría de las publicaciones tiene bajo nivel de ventas y muy volátiles. Esto las convierte en el peor escenario a la hora de *forecastear* esas ventas. Sin embargo, si se considera que las publicaciones de productos catalogados permiten entremezclar el stock y el volumen de ventas y son los productos más vendidos y con demandas más estables a lo largo del tiempo, fácil es entender cómo el hecho de seleccionar estos productos para la optimización contribuye a reducir el riesgo de errores de *forecasting*.

Otro de los aspectos que contribuiría a mitigar los riesgos de un *forecast* equivocado, es generar modelos que entiendan la estacionalidad de productos. Un ejemplo simple y claro sería que es una buena idea distribuir en la red árboles de navidad durante noviembre, pero es muy mala idea distribuirlos en enero, ya que nadie los comprará hasta la siguiente navidad.

La consecuencia de que este riesgo se materialice se puede modelar pensando en términos de errores de tipo 1 y errores de tipo 2. Un error de tipo 1 sería abastecer una venta desde un depósito lejano en lugar de haber distribuido el stock y abastecer la venta desde un depósito más cercano. Esto es lo que hoy hace la compañía cuando no distribuye su stock. El error de tipo 2 sería enviar un producto a un depósito lejano, solamente para abastecer con ese stock una venta cercana al depósito original. En este caso se estaría empeorando la estructura de costos en lugar de mejorarla. Otra consecuencia sería ocupar espacio de depósitos pequeños con stock que no rota, volviendo la operación más cara. Por estas razones es esencial mitigar este riesgo.

El segundo riesgo que se detecta es la mayor probabilidad de daños en productos que acarrea la manipulación extra que reciben los productos a realocar. Si bien es inevitable que suceda, la compañía ya cuenta con medidas que le permiten mitigar este riesgo y que su incidencia se encuentre en un punto aceptable para su operación.

Un aspecto que podría clasificarse como un tercer riesgo y que tiene relevancia es la relación con los vendedores. Debido a que se quiere distribuir stock propiedad de terceros, es importante contar con la confianza de los vendedores en este proceso, por lo que la compañía tiene que idear una forma dentro de su marketplace de dar transparencia a los vendedores de qué es lo que está sucediendo con sus productos. Al final de cuentas se espera que vendan más, por ende si se logra

que confíen en la compañía, seguirán enviando su stock a la red de fulfillment. De materializarse el riesgo de la desconfianza del vendedor, la consecuencia sería que retiren sus publicaciones o que envíen menor cantidad de stock, lo que haría imposible distribuirlo debido a sus bajas cantidades y truncaría el logro de esta eficiencia.

Posibilidades adicionales que ofrece el sistema de optimización

Si bien los beneficios de una implementación como la presentada están claros, se pueden destacar algunos aspectos en los que se podría obtener un beneficio colateral para la toma de decisiones.

Un sistema como el desarrollado se podría utilizar para simular cambios en la red. Entre otras cosas, se podría simular cómo cambiaría la optimización y sus beneficios si se abriera un nuevo depósito, si se cerrara un depósito existente o si se recategorizara un depósito para que acepte o deje de aceptar Productos Regionales (por ejemplo, se podría considerar simular que un depósito Metropolitano empiece a aceptar Productos Regionales). Incluso se podría simular invertir en agrandar la capacidad de un depósito existente y se podría simular una reducción de capacidad temporal en algún depósito (por ejemplo debido a un problema).

También un sistema así podría permitir simular mejoras en los costos de transporte de la red, permitiendo a los equipos de mejora continua priorizar los transportes que buscarán volver más eficientes según el impacto de esas eficiencias en los costos de operación de la red.

Se podría simular incluso diferentes formas de clusterizar los productos, permitiendo encontrar formas más eficientes de decidir qué productos distribuir en la red y a dónde enviarlos.

Por último, otra de las implicancias sería que el sistema ofrece a la compañía un incentivo para seguir catalogando más productos y encontrar “familias” de publicaciones que vendan lo mismo. De esta forma, se podría ampliar la base de productos elegibles para la optimización y generar mayores eficiencias.

Fuentes

1. Koch, T. (2004). *Rapid mathematical prototyping* (Doctoral dissertation). Technische Universität Berlin.
2. Bolusani, S., Besançon, M., Bestuzheva, K., Chmiela, A., Dionísio, J., Donkiewicz, T., van Doornmalen, J., Eifler, L., Ghannam, M., Gleixner, A., Graczyk, C., Halbig, K., Hedtke, I., Hoen, A., Hojny, C., van der Hulst, R., Kamp, D., Koch, T., Kofler, K., Lentz, J., Manns, J., Mexi, G., Mühmer, E., Pfetsch, M. E., Schlösser, F., Serrano, F., Shinano, Y., Turner, M., Vigerske, S., Weninger, D., & Xu, L. (2024). *The SCIP Optimization Suite 9.0* (Technical Report). Optimization Online. <https://optimization-online.org/2024/02/the-scip-optimization-suite-9-0/>
3. Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, E. (2011). *Scikit-learn: Machine learning in Python*. Journal of Machine Learning Research, 12, 2825–2830.
4. Buitinck, L., Louppe, G., Blondel, M., Pedregosa, F., Mueller, A., Grisel, O., Niculae, V., Prettenhofer, P., Gramfort, A., Grobler, J., Layton, R., VanderPlas, J., Joly, A., Holt, B., & Varoquaux, G. (2013). *API design for machine learning software: Experiences from the scikit-learn project*. En ECML PKDD Workshop: Languages for Data Mining and Machine Learning (pp. 108–122).
5. The pandas development team. (2020, febrero). *pandas-dev/pandas: Pandas* (versión más reciente). Zenodo. <https://doi.org/10.5281/zenodo.3509134>
6. Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., Wieser, E., Taylor, J., Berg, S., Smith, N. J., Kern, R., Picus, M., Hoyer, S., van Kerkwijk, M. H., Brett, M., Haldane, A., Fernández del Río, J., Wiebe, M., Peterson, P., Gérard-Marchant, P., Sheppard, K., Reddy, T., Weckesser, W., Abbasi, H., Gohlke, C., & Oliphant, T. E. (2020, septiembre). *Array programming with NumPy*. Nature, 585(7825), 357–362. <https://doi.org/10.1038/s41586-020-2649-2>
7. Hunter, J. D. (2007). *Matplotlib: A 2D graphics environment*. Computing in Science & Engineering, 9(3), 90–95. <https://doi.org/10.1109/MCSE.2007.55>
8. Chen, T., & Guestrin, C. (2016). *XGBoost: A scalable tree boosting system*. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 785–794). ACM. <https://doi.org/10.1145/2939672.2939785>
9. Richert, W, Coelho, L.P. (2013). *Building Machine Learning systems with Python*. Packt Pub Ltd
10. Ricker, F.R., & Kalakota, R. (2001). *Order Fulfillment : The Hidden Key to e-Commerce Success*
11. Merriam, Ken. (2007). *Reducing total fulfillment at costs at Amazon EU through network design optimization*
12. Guasch Rodriguez, David. (2013). *Reducing Total Fulfillment Costs through Distribution Network Design Optimization*
13. Bazaraa, M., Jarvis, J., Sherali, H. (1977). *Linear Programming and Network Flows* (4°). Wiley

14. **Bognar, Matt. (2021).** *Gamma Distribution*. Department of Statistics and Actuarial Science, University of Iowa. <https://homepage.divms.uiowa.edu/~mbognar/applets/gamma.html>
15. **GraphOnline. (2015).** *Graph Online*. <https://graphonline.top/es/>
16. **Argentina Lo Mejor. (s.f.).** *Densidad De Población en Argentina*. <https://argentalomejor.com/wp-content/uploads/2018/05/poblacion-argentina.jpg>
17. **BrazilMap360. (2002).** *Brazil population density map*. <https://brazilmap360.com/img/0/brazil-population-density-map.jpg>
18. **Commission for Environmental Cooperation. (2020).** *North American Environmental Atlas - Population Density*. https://www.cec.org/wp-content/uploads/Population_Density_2020_landing_page.jpg