



**UNIVERSIDAD  
TORCUATO DI TELLA**

**MASTER IN MANAGEMENT + ANALYTICS**

**MODELO DE OPTIMIZACIÓN DE COMPRA PARA  
UN DISTRIBUIDOR DE BEBIDAS**

**TESIS**

Diego Gustavo Berti Uldry

Mayo 2022

Tutor: Javier Marengo

## Resumen

A lo largo de los años, las empresas han buscado mejorar sus procesos con el objetivo de hacerlos más rentables, menos costosos o más eficientes. Especialmente, los involucrados en la industria del consumo masivo, los cuales en conjunto forman lo que se denomina *supply chain*. Con el foco en ser más eficientes y rentables, en este trabajo vamos a presentar un modelo de programación lineal entera que nos proporcione como resultado la cantidad óptima a comprar de ciertos productos de manera tal de no quebrar stock en los depósitos, satisfacer la demanda y minimizar el incumplimiento del stock de seguridad de cada SKU. Particularmente, vamos a centrarnos en la operación diaria de un Distribuidor de bebidas, el cual le compra los productos de manera diaria a un único proveedor. Los resultados del modelo permiten aspirar tanto a beneficios económicos como a nivel operacional de procesos. Dados los resultados, podemos obtener un beneficio económico de \$1.5 Mio de pesos argentinos o USD 7.000 en dos días de utilización del programa expresado como "costo por pedir de más" para el Distribuidor. Por otro lado, se aspira a reducir el tiempo total del flujo de armado de pedido en un 64,29%, lo cual representa 135 minutos menos por día del Analista de Stock en la planificación de la compra. A su vez, se detalla un plan de implementación para incorporar el modelo para la operatoria diaria del negocio. Los datos utilizados son proporcionados por el Distribuidor.

## Abstract

Over the years, companies have sought to improve their processes in order to make them more profitable, less expensive or more efficient. Especially those involved in the mass consumption or retail industry. The stakeholders that take part into this network are called supply chain. Focusing on being more efficient and profitable, in this work we present an integer linear programming model that gives us as a result the optimal quantity to buy a certain amount of products in order to not run out of stock in warehouses, satisfy demand and minimize non-compliance with the safety stock of each SKU. In particular, we focus on the daily operation of a Wholesaler from a retail industry in beverage, which buys daily products from a single supplier. The results of the model allow us to aspire to economic benefits as well as outstanding operational level of processes. Given the results, we can obtain an economic benefit of \$1.5 Mio in pesos argentinos or USD 7,000 using the program for two days expressing this number as "cost for over-ordering" for the Wholesaler. On the other hand, the aim is to reduce the total time of the purchase process by 64.29%, which represents 135 minutes less per day for the Stock Analyst in order planning. At the same time, an implementation plan is detailed to incorporate the model for the daily operation into the business. The data used is provided by the Wholesaler.

# Índice

<b>Índice</b>	<b>3</b>
<b>1. Introducción</b>	<b>5</b>
1.1. Contexto	5
1.2. Literatura previa	6
1.4. Problema	8
1.5. Objetivo	9
1.6. Datos y software de programación	10
<b>2. Datos</b>	<b>11</b>
2.1 Gestión de datos del Distribuidor	11
2.2 Análisis descriptivo	12
2.3 Inputs del Modelo	18
<b>3. Metodología</b>	<b>19</b>
3.1 Modelo de Compra	19
3.1.1. Conjuntos e índices	19
3.1.2. Parámetros	20
3.1.3. Variables	20
3.1.4. Función objetivo	21
3.1.5. Restricciones	22
3.2. Estimación del parámetro de Demanda	24
3.3. Indicadores de Performance	26
3.3.1. Costo adicional por pedir de más	27
3.3.2. Tiempo total en armado de pedido	27
3.4. Solver de programación y lenguaje de modelado	28
3.5. Implementación de datos en lenguaje ZIMPL	29
3.5.1. Tabla SKUs	29
3.5.2. Tabla demanda_diaria	30
3.5.3. Tabla stock_inicial	30
3.5.4. Tabla litro	30
3.5.5. Tabla lata	31
	3

3.5.6. Tabla bultos_x_pallet	32
3.5.7. Tabla depositos	32
<b>4. Resultados</b>	<b>33</b>
4.1. Desempeño y primeros resultados	33
4.2. Performance: Modelo vs Realidad	37
4.3. Implementación del modelo en la operación del Distribuidor	40
4.4. Posibles mejoras a futuro para el Modelo	42
4.4.1. Estimación del parámetro de demanda	42
4.4.2. Modificaciones al modelo actual	42
4.4.2.1 Planificación de compra: Horizonte temporal ampliado	43
4.4.2.2 Restricciones adicionales	45
4.4.2.3 Modificaciones a la Función objetivo	47
4.4.3. Gestión de productos en los depósitos	48
4.4.4. Utilización de otros softwares de optimización	48
<b>5. Conclusiones</b>	<b>50</b>
<b>Referencias</b>	<b>52</b>
<b>Anexo A. Script Modelo de Compra</b>	<b>54</b>

# 1. Introducción

## 1.1. Contexto

### **La industria del consumo masivo y su cadena de valor (*supply chain*)**

Desde los inicios de la Revolución Industrial, allá por 1760, los patrones de consumo fueron cambiando, como así también la forma en que se producían los bienes que llegan a las manos de los consumidores. Precisamente, los avances en la tecnología y su impacto en la capacidad de producción podían suplir esa demanda creciente debido a nuevas condiciones de vida, dando origen a la industria del *consumo masivo*.

Durante los años posteriores, esta industria fue mejorando considerablemente su proceso punta a punta, no solo dentro de cada empresa en particular, sino con cada uno de sus principales *stakeholders*, ya sean puntos de venta, proveedores, plantas, distribuidores, etc. A este conjunto de actores se lo denomina en la práctica como cadena de valor o *supply chain* y el objetivo de quienes forman parte de ella es que funcione lo más eficientemente posible, ya sea con el objetivo de minimizar los costos asociados al proceso o bien con el objetivo de maximizar las ganancias vinculadas a cada uno de sus negocios. Esta necesidad de *eficiencia* se debe a que en un contexto mundial donde la globalización incrementa la competencia día a día, sobrevivir depende en gran parte de ser la empresa con menores costos, como así también la de mayores ganancias dentro de su cadena de valor.

Sin embargo, lograr esta *eficiencia* no depende solamente de las decisiones de una de las partes, sino de todo el conjunto involucrado. Según Arthur F. Veinott Jr, “estas decisiones son hechas en un ambiente que involucra incertidumbre en la demanda, costos, precios, *lead times*, calidad, etc”. En otras palabras, mejorar la cadena valor implica tomar decisiones que no son aisladas y que cada parte del proceso se relaciona entre sí, haciendo que esto sea un proceso complejo, pero no imposible.

### **El rol del Distribuidor y la necesidad del uso de algoritmos para la optimización**

Como mencionamos anteriormente, *supply chain* es un conjunto interconectado de diferentes actores, donde cada uno cumple un rol específico; uno de ellos es el *Distribuidor*. El mismo se encarga de ser el responsable de entregar el producto hasta los distintos clientes. Esta parte de la cadena de valor hace referencia al área logística, siendo junto al sector de producción uno de los sectores con más oportunidad de mejora y optimización.

Por ejemplo, tenemos los siguientes casos: i) cuánto y cuándo se transporta de un depósito a otro ii) cómo organizamos el inventario de manera óptima iii) qué ruta debemos hacer con el fin de recorrer la menor cantidad de kilómetros iv) cómo hacer el pedido de compra al proveedor de manera de no quebrar stock ni tener demasiado producto en los depósitos (este tipo de problemática vamos a abordar en este trabajo).

En este trabajo en particular, estamos en contacto con un Distribuidor para el cual la necesidad de optimizar cada una de estas decisiones es fundamental, dado que el volumen de producto, inventario, depósitos, clientes y flota logística que posee es grande, y entonces cualquier decisión impacta de manera significativa en su negocio diario. Sin embargo, el entorno en el que se maneja no le permite utilizar herramientas o algoritmos sofisticados para la toma de decisiones diarias, ya sea porque nunca se detuvo a pensarlo, no conoce cómo hacerlo o no posee el presupuesto y/o los datos necesarios para contratar a un tercero que le diseñe un algoritmo de optimización. Por ese motivo, resulta interesante aplicar herramientas de programación y optimización combinatoria en este tipo de escenarios.

## **1.2. Literatura previa**

El objetivo de esta sección consiste en realizar un repaso por la amplia literatura que se encuentra detrás de los problemas de optimización. Especialmente, el que nos concierne en este trabajo. La bibliografía es amplia y posee muchos frentes que vamos a detallar a continuación.

Anteriormente dejamos planteada la necesidad de los integrantes de la amplia cadena del *supply chain* de mejorar sus procesos en pos de ser más rentables y eficientes. Esto que se entiende como una necesidad de negocio pertenece a una rama de la literatura académica conocida como *Operational Research (OR)*. La misma es una disciplina científica que utiliza métodos analíticos avanzados para ayudar a tomar mejores decisiones a nivel operacional en distintos sectores: privado, público, educativo, sin fines de lucro, etc. Por ejemplo, en Johnes (2015), el autor plantea la utilización de metodología OR para atacar una amplia variedad de problemas en el sistema educativo como la construcción de nuevos centros educativos cerca de otros, la logística diaria de transportar estudiantes a la escuela, creación de currícula y administración de materias. Para cualquiera de estos problemas hay un objetivo y un conjunto de restricciones asociadas. De la misma forma, Verícourt & Sousa Lobo (2008) plantean un enfoque OR para optimizar la decisión entre inversión y consumo que tiene una Organización sin Fines de Lucro (ONG). Los autores hacen alusión al primer término como la capacidad de la ONG de obtener ganancias, mientras que

denominan consumo al gasto correspondiente a servir a sus voluntarios o a la comunidad que atiende. El objetivo del trabajo consiste en modelar un problema multiperiodo en el que cada período la ONG tiene que decidir entre un objetivo u el otro.

Ahora bien, el sector en el que se enfoca la tesis pertenece a la rama privada de la economía. Precisamente, la industria del consumo masivo o *retail* y sus diversos problemas han sido el foco de la disciplina de *Operational Research*. Como por ejemplo, optimización de producción y fabricación de bienes, ruteo de vehículos en redes complejas de distribución, modelos de manejo de inventarios, coordinación entre los diferentes involucrados en la *supply chain*, etc. Trabajos como Tadei et al. (1995) plantean la planificación de producción de bienes perecederos para la industria de alimentos en el mercado europeo. El autor detalla un modelo de optimización con tres objetivos: i) minimizar los costos asociados al inventario, ii) minimizar los costos de personal y iii) mantener cada turno de los trabajadores constante en cada línea de producción. Estos objetivos están sujetos a un conjunto amplio de restricciones donde predominan las relacionadas a las líneas de producción.

Por otro lado, tenemos papers que abordan problemáticas relacionadas al manejo del inventario. En Tsao, Mangotra, Lu & Dong (2012), los autores resaltan el problema de las compañías que poseen redes complejas de distribución con una amplia variedad de centros nacionales y regionales, donde las decisiones principales radican en cómo distribuir estos centros y cuál sería la política de inventario que minimice el costo de toda la red. Siguiendo esta misma línea, Minner (2003) realiza una revisión de múltiples modelos de inventario dentro del *supply chain* para compañías que tengan una gran cantidad de proveedores. Desde otro punto de vista, existen modelos de inventario en base a la estacionalidad en la demanda. Por ejemplo, el trabajo de Ehrental, Honhon & Woensel (2014), investiga el valor de considerar la estacionalidad de la demanda en el manejo de inventarios. Los autores resaltan que si no se tiene en cuenta esto se tiende a constantes choques entre la oferta y la demanda a nivel del almacenamiento de producto en los depósitos. En otras palabras, al no saber los períodos de estacionalidad es muy probable que para momentos de demanda alta no haya stock y para momentos de baja el depósito colapse de producto. Gran parte de nuestro trabajo en esta tesis se basa en este concepto y, más aún, debido a la fuerte estacionalidad que presenta la demanda del Distribuidor.

De la misma manera, gran parte de los trabajos de OR buscan mejorar la performance en cuanto al proceso logístico que implica el movimiento de bienes de un lugar a otro. Principalmente, el transporte de mercadería se divide en dos: i) desde la Planta de producción hasta el Centro de Distribución (CD) o depósito y ii) del CD hasta el punto de

venta (PDV) o consumidor final. Al primer trayecto se lo conoce como *Logística de Primera Milla (FM<sup>1</sup>)*, mientras que al segundo se le llama *Logística de última Milla (LM<sup>2</sup>)* y es el foco principal de las agendas de los directivos de las empresas en términos de mejora logística. Según Juhász & Bányai (2018), es la parte más costosa y problemática dentro del *supply chain*, debido a que el proceso de entrega se realiza a cada PDV de manera particular con lo cual esto trae aparejado costos extras como combustible, horas extra de choferes, etc. Con el objetivo de reducir estos costos extras, trabajos como Sonneberg et al. (2019) proponen el uso de vehículos autónomos no tripulados (AUGV<sup>3</sup>), de manera tal de minimizar los costos asociados a la entrega de productos en la última milla. De la misma forma, Giuffrida (2022) realiza una reseña de literatura relacionada a la optimización de la logística de última milla y propone el uso de algoritmos de Machine Learning para mejorar estos procesos vinculados al transporte de los productos.

Como veremos más adelante, nuestro trabajo toma ciertas características de la bibliografía que venimos analizando hasta ahora. En términos operacionales, el Distribuidor se encuentra en ambos trayectos logísticos. Por un lado, pertenece a la logística de primera milla ya que transporta el producto de la Planta de origen y hacia sus depósitos; por otro lado, es el encargado del transporte desde este último punto hacia los consumidores finales constituyendo de esta manera la logística de última milla. Desde otro punto de vista, la solución que vamos a plantear toma conceptos de modelos de planificación de producción o de inventarios, ya que tenemos un horizonte temporal sobre el cual decidir y un conjunto de restricciones.

## 1.4. Problema

Dentro de las decisiones que mencionamos anteriormente, para nuestro Distribuidor una de las más importantes es la de determinar cuánto producto comprar a su proveedor, de manera tal de no *quebrar stock<sup>4</sup>* o *sobre stockearse* demasiado. Hoy en día, la mayoría de estos actores toma esta decisión sin un modelo concreto o un análisis complejo, por lo que nos alienta a pensar que podría haber una forma más sofisticada y automática de tomar la decisión de cuánto producto comprar. Concretamente, el Distribuidor que vamos a considerar en este trabajo toma esta decisión sobre la base de la información que tiene disponible: cómo viene la *venta* de cada producto o *SKU<sup>5</sup>*, su objetivo comercial y el *stock*

---

<sup>1</sup> First Mile

<sup>2</sup> Last Mile

<sup>3</sup> Autonomous Unmanned Ground Vehicles

<sup>4</sup> Quedarse sin stock de uno o más productos en el depósito.

<sup>5</sup> *SKU: Stock Keeping Unit*. Definición utilizada para hacer referencia a los distintos productos que tiene una empresa de consumo masivo o de una gran escala de producción/distribución.

de cada uno en los diferentes depósitos. En otras palabras, no hay un modelo o un sistema formal que tome estos datos como input y devuelva una sugerencia de cuánto producto debería comprar el Distribuidor.

Esto lleva a que por momentos, si la empresa se encuentra con una demanda estacional (lo cual aplica a nuestro caso), se vea afectada por falta de stock durante periodos de temporada alta y sobrestock durante los meses de baja. Ambos problemas representan una pérdida para el Distribuidor, ya que si no tiene producto para vender pierde la potencial ganancia de esa venta. Por otro lado, tener demasiado producto en los depósitos implica costos asociados a mantenerlos y, aun peor, la posibilidad de que estos tengan una fecha de vencimiento y tengan que ser descartados, como le sucede al caso de este trabajo.

## **1.5. Objetivo**

Sobre la base de lo presentado en las subsecciones anteriores, partimos de un escenario en donde no se ha construido nada anteriormente por lo que resulta interesante abordar esta problemática con un foco más computacional.

El objetivo de la presente tesis consiste en elaborar un modelo de programación lineal entera que determine la cantidad óptima factible de productos que este Distribuidor debe comprar para satisfacer la demanda del mes corriente, sin quebrar o acumular stock. Específicamente, el objetivo del modelo consiste en minimizar el incumplimiento del stock de seguridad de cada producto.

Se trata de un problema multiproducto y con un horizonte temporal diario. Haciendo hincapié en esto, el trabajo tomará como base de estudio la operación de un Distribuidor, el cual compra productos a su proveedor. Los mismos se conforman por bebidas alcohólicas (cervezas, vinos y espumantes) y no alcohólicas (gaseosas, energizantes, jugos, etc). Por ende, tienen una fecha de vencimiento, la cual no se toma en cuenta para este modelo. Esto implica que acumular mucho stock en el depósito y no venderlo obliga a desechar este producto más tarde.

Concretamente, estamos en contacto con un Distribuidor para la región de Cuyo (Argentina) con el objetivo de que este modelo le sea útil para su operatoria diaria. Tiene una demanda estacional, donde la temporada alta comprende el periodo de Septiembre-Febrero y la baja durante Marzo-Agosto.

Tanto el modelo como los resultados obtenidos serán utilizados por el Distribuidor para mejorar la toma de decisiones con respecto a cuánto y qué producto comprar sobre la base de la demanda estimada para el periodo correspondiente. De esta manera, pasaremos de

un enfoque manual basado en análisis de tendencias, performance de ventas y revisión de stocks a un modelo formal y automático que toma como input estos mismos datos y devuelva un número que el negocio tome como referencia de su operatoria diaria.

## **1.6. Datos y software de programación**

Con respecto a la información que vamos a utilizar en este trabajo, tanto para el análisis descriptivo de los datos como para los inputs que el modelo va a consumir son proporcionados por el Distribuidor. En relación al programa de optimización, vamos a usar como solver SCIP, mientras que el lenguaje de modelado va a ser ZIMPL.

Los datos se conforman principalmente de avances de venta históricos (diarios, semanales y mensuales), inventario de stock por depósitos y conversiones de medida para los SKU (bultos, pallets y hectolitros). Los mismos van a estar separados en siete tablas en total que comprenden desde los códigos de cada SKU, hasta la cantidad de bultos por pallet de cada uno de ellos. En cuanto al formato, todas las tablas van a estar en una forma *.dat*, ya que el software de optimización utilizado en la tesis requiere este tipo de codificación.

Cabe mencionar que todos los archivos son del año corriente (2022) y se encuentran en formato Excel. Una vez recibidos, son analizados para asegurarnos que no contengan errores y mantengan los lineamientos correctos. Finalmente, convertimos los archivos correspondientes de un formato *.xlsx* a uno *.dat*.

## 2. Datos

### 2.1 Gestión de datos del Distribuidor

El volumen de datos que maneja el Distribuidor es amplio, variado y cambia rápidamente. Cuando decimos que es amplio y variado nos referimos a que comercializa una gran cantidad de productos, los cuales pertenecen a distintas marcas, categorías, calibres y segmentos. Por ende, al tener un amplio portfollio de SKUs se debe hacer un inventario diario de cada uno de ellos al igual que el seguimiento de su venta. Por otro lado, cuando hacemos alusión a que los datos cambian rápidamente es porque los productos varían todo el tiempo, es decir, aparecen SKUs nuevos y salen del mercado otros. Por ejemplo, los períodos de temporada baja suelen funcionar como “meses de prueba” para evaluar ciertos productos que van a ser producidos masivamente para la temporada de verano. Como así también, la producción de SKUs que se discontinua porque no son rentables o compiten en el mismo segmento que otro producto y no se busca que haya un enfrentamiento entre dos SKUs de la misma marca. Además, el Distribuidor se encuentra en un país con un alto índice de inflación, con lo cual los precios a los que debe comprar los productos y vender los mismos cambian rápidamente.

En relación a la temporalidad de los datos, se cuenta con información en todos los niveles. Principalmente, esto se debe a que el Distribuidor mide su performance en términos de cuanto vende, ya sea por día, mes o año. La información diaria la utiliza para medir cuánto le falta vender para llegar al objetivo mensual. El mismo es fijado por su proveedor. Con respecto a los datos mensuales, el Distribuidor compara las ventas del mes en curso contra el mes anterior o, simplemente, contra el mismo mes del año anterior. Esta última comparación le permite saber si para el mismo del año pasado vendió más o no que el actual y de esa manera evitar los efectos de la estacionalidad. Por ese motivo, cuenta con información histórica que se almacena en los sistemas del Distribuidor o, en su defecto, en Excel.

En cuanto a los sistemas que emplea, el Distribuidor posee dos herramientas informáticas que son brindadas por su propio proveedor. Una de ellas se utiliza para la toma de pedidos a sus diferentes clientes. Este último consiste en una aplicación en el celular que utilizan los vendedores del Distribuidor cuando visitan a sus puntos de venta y ellos mismos le anotan en el teléfono lo que quieren pedir. El segundo programa se emplea para administrar el stock disponible. Este le permite al Distribuidor ver el stock de los SKUs por depósito. No obstante, el equipo encargado del manejo de inventario hace un control

diario, ya que el sistema no es del todo confiable. Ambos sistemas no son complejos. Sin embargo, el principal programa que utiliza el Distribuidor es Excel para la realización de reportes como administración de inventarios y avances de venta.

Podemos decir que esta última herramienta es la que predomina en el día a día de la operación. A pesar de que el stock y la venta la tengan en sistemas aparte, el mismo personal del distribuidor baja los archivos planos de ambos y crea reportes en Excel con la misma información. La razón detrás de esto se debe a que no confían totalmente en los sistemas que son proporcionados por su proveedor y los mismos no tienen una modalidad más amigable para analizar los datos.

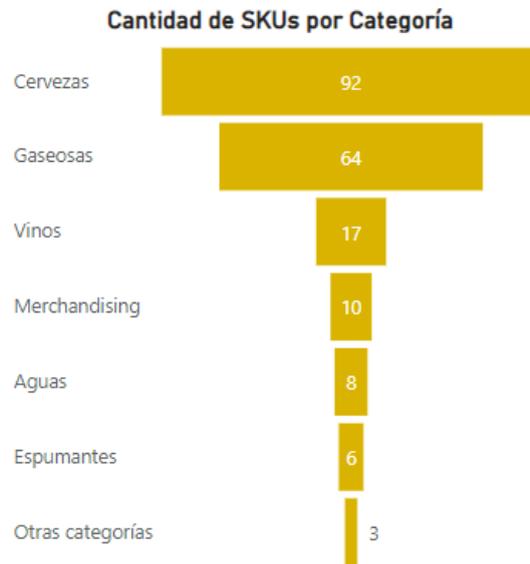
En términos generales, la situación a nivel sistemas y gestión de los datos del Distribuidor es precaria para la gran cantidad de datos que maneja y los volúmenes de venta que tiene durante el año.

## **2.2 Análisis descriptivo**

En pos de entender el tipo de negocio que abordamos en este trabajo, vamos a estudiar algunos datos sobre el día a día del Distribuidor.

En primer lugar, vamos a enfocarnos en los productos que comercializa el Distribuidor. El mismo posee un portfolio de 200 SKUs. Los mismos se dividen en categorías, calibres y segmentos. A su vez, los productos poseen una marca que está directamente relacionada con el tipo de target de cliente al que se busca apuntar. Esta segmentación se debe a diferentes razones. En primera instancia, por una cuestión de ordenamiento de depósitos, ya que diferentes calibres representan distintos tamaños y pesos con lo cual no todos ellos ocupan el mismo lugar en el inventario. Por otro lado, las fechas de vencimiento son distintas según la categoría, por ejemplo, no es lo mismo SKUs que pertenecen a la clase de Vinos que los de Cerveza o Gaseosa. Luego, lo que se denomina zona de carga o descarga de camiones influye en su distribución, ya que estos transportan generalmente productos de una misma categoría y, en casos particulares, llevan un cargamento variado (productos de más de una categoría). También, la necesidad de separarlos se debe a que la demanda para cada SKU es diferente y, por ende, para cada categoría. Además, el distribuidor tiene como requisito de su proveedor mantener esta categorización, ya que le permite tener un seguimiento más detallado y ordenado de la venta de cada una. De manera tal de impulsar estrategias de descuento específicas para ciertos SKUs, aumento de producción para algunos o discontinuar la fabricación de otros. Por este último motivo es que la cantidad de productos y categorías pueden variar a lo largo del tiempo. Por ejemplo, la categoría de Vinos es bastante reciente, ya que el proveedor adquirió una bodega el año pasado.

**Figura 1. Categorías**

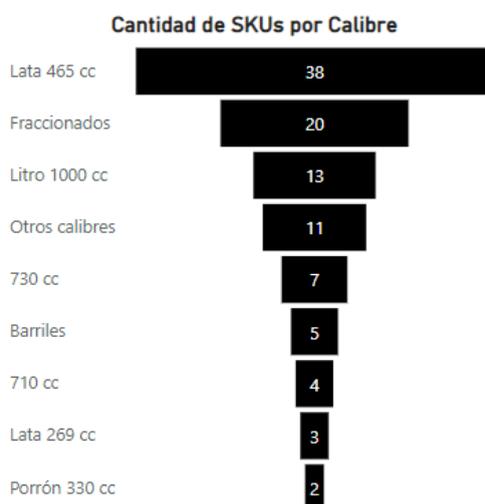


Dicho esto, en la Figura 1 podemos ver las diferentes categorías con las que el Distribuidor identifica a sus productos. En total son siete categorías, donde la de Cervezas contiene la mayor cantidad de SKUs, seguida de las Gaseosas y el Vino. Con respecto a la categoría de Merchandising, representa los productos que el Distribuidor entrega como concesión o regalos a sus clientes. Por ejemplo, una heladera de alguna marca, vasos de vidrio, gorras, remeras, etc. Por último, vemos que existen Otras categorías que el Distribuidor utiliza para asignar nuevos productos hasta que se le asigne una clase en particular. Esto se debe a que dentro de ésta ingresan SKUs los cuales el proveedor emplea para realizar cierto testeo de cómo puede performar un nuevo tipo de producto, ya sea por calibre, marca o sabor.

Con respecto a los calibres, los mismos hacen referencia al tamaño del packaging de los SKU. Estos son variados y van desde los más grandes que son los Barriles, hasta las Latas de 269 cc. En total el distribuidor comercializa nueve calibres. Cabe mencionar que productos que pertenecen a una marca pueden tener más de un mismo calibre. Por ejemplo, los SKUs 2057 y 17358 corresponden a la misma marca, pero son dos calibres diferentes. El primero es un producto de Litro 1000 cc y, el otro, es de Lata 469 cc. Como mencionamos anteriormente, el calibre es fundamental para ubicar los productos en los depósitos. Además, esta característica va a ser importante en nuestro modelo, ya que, la capacidad de carga del camión depende directamente del calibre del SKU. Por ejemplo, en el caso de productos de calibre Litro 1000 cc la capacidad máxima del camión son 26 pallets o 1300 bultos.

En la Figura 2, podemos visualizar la cantidad de productos según su calibre. Vemos que tenemos mayor cantidad de SKUs de Lata 465 cc, mientras que tan solo dos productos pertenecen al calibre Porrón 330 cc.

**Figura 2. Calibres**



Los productos son almacenados en depósitos; precisamente, el Distribuidor cuenta con cinco depósitos ubicados en distintas provincias de la región de Cuyo (Argentina). Estos depósitos son: Acercar, Catriel, RDLS, SG y Tricor. En todos ellos, se almacenan todos los productos, es decir, no hay depósitos especializados en ciertos SKU, sino que cada uno de ellos tiene todos los productos.

Siguiendo la misma línea de productos, los mismos se clasifican según su venta o rotación/picking<sup>6</sup>. Esta clasificación cuenta de tres tipos: *A* (alta rotación), *B* (media rotación) y *C* (baja rotación). Esta clase de segmentación es bastante común en las empresas, ya que busca un mejor manejo del inventario y, de esa manera, lograr una manera más eficiente de gestión del depósito y optimización del stock. Esta clasificación se basa en la idea del Principio de Pareto o regla 80-20 según Dunford (2014), donde los productos *A* representan el 80% o más de la venta, pero no son más que el 30% de la cantidad de SKU, mientras que los productos *B* y *C*, representan el 20% o menos de la venta. Gráficamente, en la Figura 3 observamos cómo se segmentan los mismos en base a la venta del mes de Abril:

---

<sup>6</sup> El picking o la actividad de preparación de pedidos consiste en la retirada y combinación de cargas no unitarias para conformar el pedido de un cliente. Puede llevarse a cabo en casi cualquier tipo de depósito y se produce siempre que se necesite juntar paquetes, piezas, productos o materiales para, una vez reunidos, proceder a su traslado.

**Figura 3.** Venta total Abril según Segmentación de SKU



Como podemos observar, la mayor parte de la venta pasa por los productos de mayor rotación (A) y el resto se reparte entre los SKU B y C.

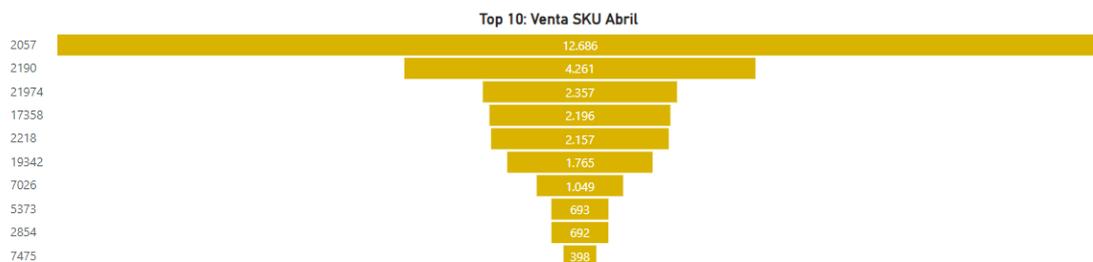
Adicionalmente, en la Tabla 1 vemos la cantidad de SKUs según su segmentación y su porcentaje correspondiente, de esta manera, vemos claramente cómo cumplimos con la regla de Pareto de forma práctica:

**Tabla 1.** Segmentación de SKU: Cantidad y Porcentaje

SKU	Cantidad	%
A	60	30%
B	30	15%
C	110	55%

A modo ilustrativo, en la Figura 4, vemos los diez productos más vendidos del mes de Abril, donde destacamos que los SKUs que pertenecen a este Ranking son de clase A y pertenecen a la categoría de Cervezas o Gaseosas.

**Figura 4 .** Top 10: Venta SKU Abril

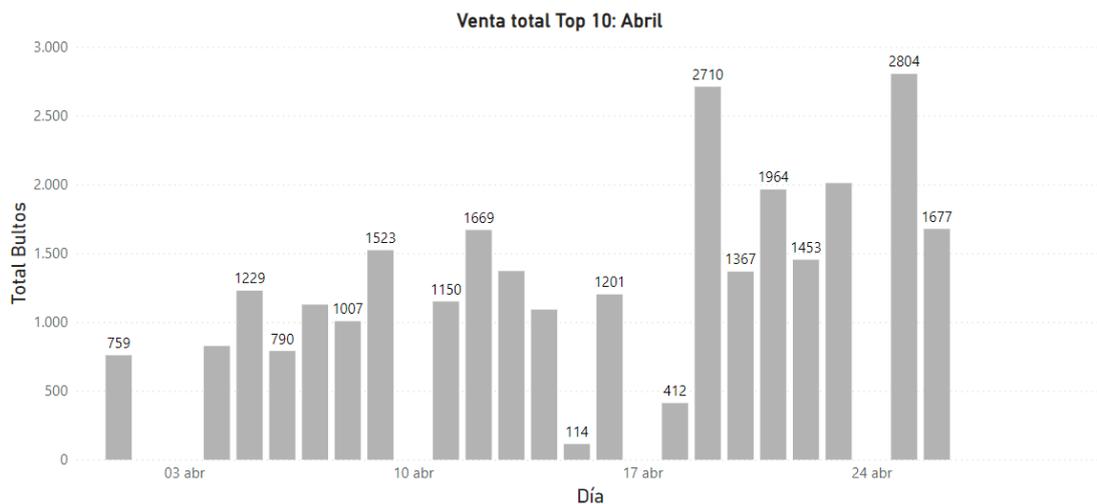


Ahora bien, en cuanto a la venta y su evolución en el tiempo, ya mencionamos que el Distribuidor se encuentra en una industria que posee una marcada estacionalidad durante el año. El período de Octubre a Marzo se entiende como temporada alta y los meses de

Abril a Septiembre como baja. Desafortunadamente, no contamos con la información anual para ver estos picos de estacionalidad. Sin embargo, para el año 2022 tenemos los datos de venta por mes de marzo y abril. Para el primero, la venta total fue de 70.000 bultos, mientras que la de abril fue aproximadamente 40.000. Esto representa una diferencia porcentual de 30.000 bultos, es decir que la caída de la venta de un mes de la temporada alta a uno de la baja es aproximadamente 42%. Principalmente, esto se debe a que el consumo de bebidas alcohólicas como la cerveza es mayor para los meses de temperatura alta y menor para períodos de frío.

Haciendo foco en esto para el mes de Abril, vamos a detallar la venta de manera diaria de los 10 SKUs más vendidos de ese mes para entender el comportamiento de la demanda diariamente. En la Figura 5, podemos visualizar esto:

**Figura 5. Venta Top 10: Abril**

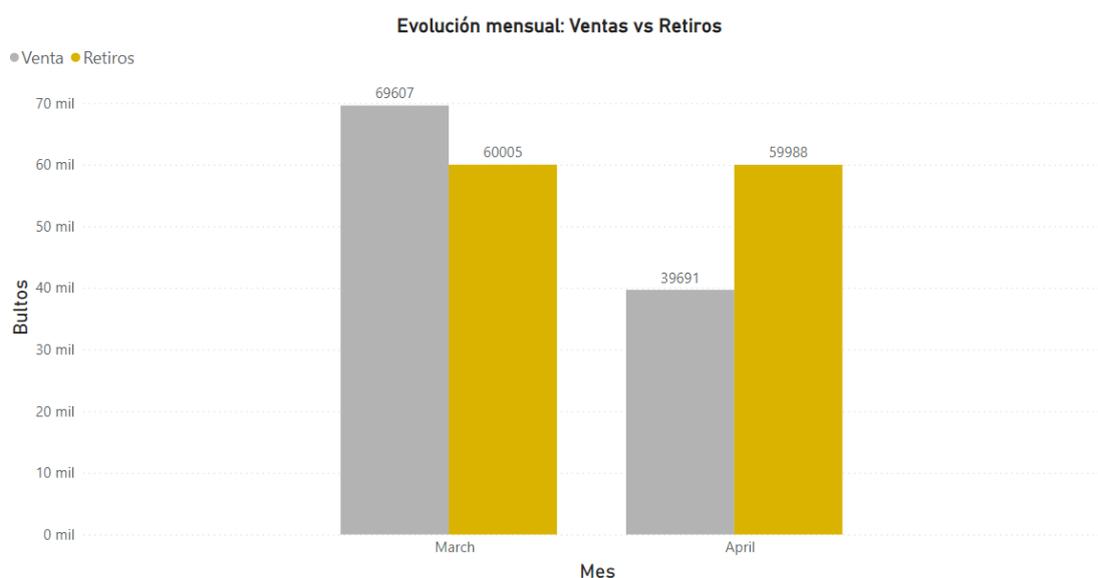


En el gráfico, vemos que la demanda se comporta diferente para los primeros días del mes, comparado con los últimos. Por ejemplo, para el período del 1-04 al 18-4, observamos un estado constante en la demanda de casi 1800 bultos. En cambio, del día 19-4 en adelante, tenemos ventas por arriba de los 3000 bultos para algunos días. La razón de esta variación se debe a distintos frentes, ya sea por parte del Distribuidor como por la demanda. Para el primer caso, los primeros días del mes el Distribuidor se encuentra en un escenario en el que está relajada, ya que le queda casi todo el mes para cumplir su objetivo de venta. Por ese motivo, cuando se acerca el final del mes, el Distribuidor se preocupa por cumplir con su meta mensual y vende la mayor cantidad de producto posible. Desde el lado de la demanda, los clientes poseen un mayor poder adquisitivo a finales de mes, ya que muchos de ellos cobran sus salarios para esta fecha. Cabe aclarar que los días en los que no hay

venta corresponden a los domingos, durante esos días el Distribuidor no trabaja. Lo mismo ocurre para los feriados.

Esta variación refleja la posición del Distribuidor de cara a su demanda, en términos de como comprar y administrar stock frente a una venta incierta. Para resaltar este punto, en la Figura 6, vemos para los meses de marzo y abril lo que el Distribuidor retiró, en otras palabras, lo que compró comparado con lo que fue su venta para los mismos meses:

**Figura 6. Evolución mensual: Ventas o Retiros**



Este gráfico permite ilustrar la operación del Distribuidor y su posición frente al manejo de stock y como hace las compras de productos en base a una demanda y lo que ya tiene en sus depósitos. Vemos que, durante el mes de Marzo vendió más de lo que compró, esto indica que la diferencia resultante entre lo que adquirió durante ese mes y lo que vendió fue cumplido por medio del stock. Por otro lado, el mes de Abril se condice con lo que mencionamos anteriormente sobre la estacionalidad y los meses de temporada baja, acá vemos una venta menor, pero una cantidad de retiros mayor. Esto se debe principalmente a dos cuestiones. La primera, durante los meses de temporada baja el Distribuidor “compra de más” para stockearse para períodos donde la demanda es mayor, ya que en el verano no hay stock para ciertos SKUs. En segunda instancia, el Distribuidor compra más, ya que su proveedor le va a subir el precio. Esto es bastante habitual debido a que el Distribuidor se encuentra en un país con un índice de inflación bastante alto con lo cual los precios cambian todo el tiempo y no solo para esta industria.

Dado esto último, la decisión de cuánto comprar y cómo manejar el stock ante una demanda incierta es el objetivo de este trabajo y en las secciones siguientes vamos a abordar este problema.

## **2.3 Inputs del Modelo**

Los datos que emplea el modelo son los mismos que venimos comentando anteriormente. Estos corresponden a los datos de venta y de stock para cada producto y depósito. Cabe aclarar que para el primero debemos realizar ciertas modificaciones para llegar al parámetro deseado, el cual explicamos con más detalle en el siguiente capítulo.

En términos de stock utilizamos la cantidad en bultos de cada SKU para los cinco depósitos. Este dato posee una frecuencia diaria y el Distribuidor lo obtiene desde su sistema, pero de igual forma realiza un conteo físico que luego registra en un archivo de Excel y envía. El recuento de stock y manejo de inventario por parte del Distribuidor es en bultos, a diferencia de la unidad de medida que utiliza cuando realiza una compra de productos que es en pallets. Esto se debe principalmente a que la variedad de productos que se cargan en el camión desde el depósito hasta el cliente o punto de venta es más variada que la que se carga desde la planta al depósito. Las compras que realiza el distribuidor suelen ser parecidas y pedir bastante cantidad de un producto, por eso tiene sentido pedir cantidades mayores medidas en pallets. Mientras que el despacho de productos hacia sus clientes, es más heterogéneo y es razonable organizar el stock en unidades más pequeñas. Por el contrario, la venta no se sigue ni en bultos ni en pallets sino en hectolitros. Esto se debe principalmente porque un producto de una misma marca puede tener diferentes calibres y, por ende, la cantidad de bultos y pallets difiere considerablemente. Por ejemplo, los SKUs 2057 y 17358 corresponden al mismo producto, pero el primero es de calibre litro y el segundo de lata. Ambos son lo mismo, pero representan diferentes cantidades tanto en bultos como en pallets. Entonces, para que el Distribuidor haga un seguimiento de la venta de este producto necesita utilizar una unidad de medida en común para ambos y esta son los hectolitros.

A modo de unificar una sola unidad de medida para resolver el problema de optimización, vamos a utilizar la medida de bultos tanto para el stock diario como para la demanda en todos los depósitos. Adicionalmente, vamos a utilizar datos de conversión para obtener los resultados en pallets. De esa forma, el output que obtenemos del modelo va a ser de mayor utilidad para el Distribuidor, ya que el pedido lo realiza en pallets y el manejo de inventario en bultos.

## 3. Metodología

El enfoque que se va a utilizar en el trabajo consiste en la formulación de un modelo de programación lineal entera para este problema. Considerando el caso en cuestión, se asemeja a un problema de modelado de inventario. Por ejemplo, se intenta utilizar enfoques similares a trabajos como el de Viveros & Salazar (2010) o, también, Roushdy (2016). Sin embargo, a diferencia de éstos, para nuestro problema vamos a considerar la producción como un proceso aislado que solamente consiste en comprar distintos productos a un precio dado por un único proveedor y considerando ciertas restricciones propias de la operatoria diaria del Distribuidor.

Concretamente, el objetivo del modelo es dar como resultado la cantidad óptima en bultos de los SKU considerando los datos de stock y demanda dado un conjunto de restricciones. Ahora bien, para llegar a esto necesitamos un software de optimización, para ello, en este trabajo particular vamos a utilizar SCIP como solver de programación y el lenguaje de modelado ZIMPL para escribir nuestro modelo de programación lineal entera. El resultado que se espera obtener es la cantidad óptima a comprar de cada SKU para cada depósito de manera diaria.

A continuación, vamos a detallar el modelo de optimización y sus correspondientes métricas para evaluar su performance.. Las subsecciones siguientes se organizan de la siguiente manera: 3.1) *Modelo de Compra*; 3.2) *Estimación del parámetro de Demanda* ; 3.3) *Indicadores de Performance*; 3.4) *Solver de programación y lenguaje de modelado*; 3.5) *Implementación de datos en lenguaje ZIMPL*.

### 3.1 Modelo de Compra

#### 3.1.1. Conjuntos e índices

El conjunto que vamos a utilizar es solamente uno y representa todos los SKUs:

$$P = \text{conjunto de SKUs}$$

Dentro de este, vamos a tener dos subconjuntos independientes y corresponden a los productos de calibre de litro y lata, respectivamente:

$$\text{Litro} = \text{conjunto de SKU de calibre Litro, donde Litro} \subseteq P$$

$$\text{Lata} = \text{conjunto de SKU de calibre Lata, donde Lata} \subseteq P$$

Para clarificar esta presentación, vamos a utilizar tres índices diferentes para identificar a cierto producto para un día en específico y su depósito correspondiente.

$i = \text{código de producto}; i \in P$

$t = \text{días del mes}; T = \{0, 1, 2, 4, \dots, 31\}$

$w = \text{depósito}; W = \{SG, Catriel, RDLS, Acercar, Tricor\}$

### 3.1.2. Parámetros

Los parámetros son tres y son los siguientes:

$d_{iw} = \text{demanda del producto } i \text{ para el depósito } w$

$b_i = \text{cantidad de bultos por pallet del producto } i$

$\alpha = \text{multiplicador de demanda}$

Como vimos en el Capítulo 2,  $d_{iw}$  y  $b_i$  son datos dados para el modelo, ya que es información con la que contamos de antemano, una calculada por nosotros (como explicamos en la sección pasada) y la otra obtenida a través del Distribuidor, respectivamente.

Con respecto al parámetro  $\alpha$ , este es una constante que representa la cantidad de días de venta o rotación de inventario que el Distribuidor considera necesarias, dependiendo la temporada del año, para mantener cierto nivel de stock en el depósito y saber cuánto producto tiene disponible para la venta. En la realidad, el Distribuidor se maneja en base a los días de venta que tiene, es decir, la cantidad de stock que tiene para cierto SKU sobre la demanda del mismo. Por ejemplo, tenemos un stock de 1000 bultos para el producto 2057 y su demanda es de 500, los días de venta o rotación de inventario para ese SKU es de 2 días, es decir, con esa cantidad puede satisfacer hasta dos días de demanda.

### 3.1.3. Variables

Nuestro modelo va a utilizar cuatro variables:

$x_{itw} = \text{compra del producto } i, \text{ el día } t, \text{ para el depósito } w$

$s_{itw} = \text{stock del producto } i, \text{ el día } t \text{ para el depósito } w$

$w_{itw} = \text{stock de seguridad incumplido para el producto } i, \text{ el día } t \text{ y el depósito } w$

$p_{itw} = \text{compra de pallets del producto } i, \text{ el día } t, \text{ para el depósito } w$

Las primeras dos variables son iguales a los que plantean modelos del estilo *lot sizing*, mientras que las últimas son específicas del tipo de industria y operación en la que se encuentra el Distribuidor. Más adelante, cuando pasemos a ver el objetivo del modelo y lo que vamos a optimizar, la variable  $w_{itw}$  se convierte en una pieza clave. Así mismo, la variable  $p_{itw}$ , que hace referencia a la unidad de medida en la que se encuentran agrupados los productos, nos permite simplificar los resultados que nos arroja el modelo y de forma tal que sea más práctico para el Distribuidor. Recordemos que en el día a día, el Distribuidor realiza sus pedidos en la unidad de medida pallet, mientras que el seguimiento de stock lo hace en bultos y, por último, la venta la sigue en hectolitros. Por este motivo, utilizamos dos de las tres unidades mencionadas. Para el caso de los hectolitros, no nos modifica el cálculo para el pedido, pero sí hacemos una conversión cuando calculamos el parámetro de demanda  $d_{itw}$ , ya que la información que recibimos está en hectolitros y debemos convertirla a bultos.

### 3.1.4. Función objetivo

Dados los parámetros y las variables vamos a presentar nuestro modelo de optimización:

$$\min \left\{ \sum_{i=1}^{200} \sum_{t=0}^{31} \sum_{w=1}^5 w_{itw} \right\} \quad (1)$$

Recordemos que el objetivo de nuestro modelo es minimizar el incumplimiento del stock de seguridad de un SKU de manera tal de satisfacer la demanda, no quebrar stock y un conjunto de restricciones adicionales que detallaremos en breve. Funcionalmente, este valor va a estar medido en bultos para cada SKU, pero dada la definición de una de las restricciones vamos a poder obtener el valor de una variable en pallets para que sea aún más útil al Distribuidor.

Cabe destacar que, si bien el modelo utiliza todos los días del mes para determinar la cantidad óptima de cada SKU, en la práctica vamos a utilizar solo el día corriente que se está realizando el pedido. Esto se debe al tipo de industria en la que se encuentra el Distribuidor, donde la demanda se comporta de manera estacional y no le permite tener una planificación de compra totalmente precisa. De hecho, a lo largo de la semana y durante el mes el Distribuidor no pide el mismo día o con la misma frecuencia por semana, es decir, dos días seguidos. Como mencionamos anteriormente, la industria en la que se encuentra el Distribuidor posee dos puntos marcados de la demanda: i) temporada alta

durante los meses de calor y ii) temporada baja en los meses de frío. Por ese motivo, el modelo se utiliza para determinar la cantidad del día corriente y no una planificación de compra más grande. Como así también, se debe a los datos disponibles y la operatoria del negocio, la es diaria.

### 3.1.5. Restricciones

En primer lugar, definimos las variables de compra ( $x_{itw}$ ) y de stock ( $s_{itw}$ ) en las ecuaciones (2) y (3), respectivamente:

$$x_{itw} = b_i * p_{itw} \quad \forall i \in P, \forall t \in T, \forall w \in W \quad (2)$$

$$s_{itw} = s_{i,t-1,w} + x_{itw} - d_{iw} \quad \forall i \in P, \forall t \in T, \forall w \in W \quad (3)$$

La ecuación (2) define a la cantidad a comprar como el producto de bultos por palet de cada SKU. El objetivo de definir así la variable de compra se debe a que el Distribuidor realiza el pedido a su proveedor en pallets, pero su inventario lo lleva en bultos. De este modo, definir la variable de decisión se asemeja a la realidad operativa del problema y permite un entendimiento mayor del resultado. Con respecto a la ecuación (3), el stock del día corriente se define como la cantidad sobrante del día de ayer (dato que utiliza nuestro modelo), más lo que compramos, es decir, lo que nuestro modelo nos da como resultado y, por último, le restamos la demanda que tenemos para ese día. Esta ecuación obliga al modelo a cumplir siempre la demanda del día.

Ahora bien, la restricción (4) define la cantidad de stock necesario de un SKU para cada depósito, de manera tal de satisfacer cómo mínimo la demanda del mismo para cada depósito multiplicado por la constante  $\alpha$ , que denominamos como multiplicador de la demanda. Este representa la cantidad de días de venta expresados en los bultos. En otras palabras, cuánto producto tengo en el depósito para satisfacer  $\alpha$  días de venta.

Como definimos en la ecuación (3), el stock se compone del producto remanente del día anterior, más la compra y menos la demanda; este valor tiene que ser mayor o igual a la cantidad de bultos necesarios para satisfacer  $\alpha$  días de venta. Lo que la variable  $s_{itw}$  no pueda cumplir, lo va a hacer  $w_{itw}$  que representa el stock de seguridad incumplido, el cual nuestro modelo busca minimizar.

$$s_{itw} + w_{itw} \geq \alpha * d_{itw} \quad \forall i \in P, \forall t \in T, \forall w \in W \quad (4)$$

Luego, sumamos dos restricciones para los SKU de calibre litro y lata que representamos en la ecuación (5) y (6), respectivamente:

$$\sum_{i \in Litro \cap P} x_{itw} \leq 1300 \quad \forall i \in Litro \cap P, \forall t \in T, \forall w \in W \quad (5)$$

$$\sum_{i \in Lata \cap P} x_{itw} \leq 2400 \quad \forall i \in Lata \cap P, \forall t \in T, \forall w \in W \quad (6)$$

La razón de sumar estas dos cotas superiores al modelo es que la operación del Distribuidor para ciertos SKU es constante a lo largo del año. Los productos de calibre litro y lata son bastante comunes y de una alta rotación en ambas temporadas, por lo que es habitual pedir un camión completo de alguno de estos productos. Físicamente, un camión puede transportar, en el caso de productos de litro, 26 pallets que representan 1300 bultos o 24 palets que suman un total de 2400 bultos para el caso de un SKU de lata. Esta restricción aplica para todos los depósitos, es decir, cómo máximo se puede pedir un camión completo de un producto de litro por depósito y no un camión para todos. Dado que tenemos estas cotas superiores, la decisión del Distribuidor no es trivial. Esto quiere decir que de no haber compras máximas, alcanza solamente con comprar lo necesario para satisfacer  $\alpha$  días de venta. Por ende, sin estas restricciones no hay problema que optimizar.

El resto de los calibres que no pertenecen al litro o lata poseen un máximo que le representa completar un camión. Sin embargo, no es común en la operación del Distribuidor realizar una compra de un camión completo para productos que no sean de litro o de lata, ya sea porque la demanda de estos calibres no es alta o porque el Distribuidor posee zonas de venta donde no se comercializan estos tamaños. Por tal motivo, solo se consideran las restricciones (5) y (6) para el modelo, pero existe la posibilidad que esto cambie y el Distribuidor solicite sumar una o más cotas superiores de compra al modelo porque su operación cambia. Por ejemplo, se introduce un nuevo calibre como la Lata 710 cc y la demanda crece exponencialmente debido a la fuerte suba de la venta de este producto y el proveedor no puede producir una cantidad para satisfacer la misma. En ese caso, el proveedor impone máximos de compra al Distribuidor para un SKU que antes podía comprar una cantidad arbitraria sin restricciones.

$$x_{itw}, s_{itw}, w_{itw} \geq 0 \quad \forall i \in P, \forall t \in T, \forall w \in W \quad (7)$$

$$p_{itw} \in Z \quad \forall i \in P, \forall t \in T, \forall w \in W \quad (8)$$

En la ecuación (7), definimos las restricciones de no negatividad, haciendo que el modelo sepa de antemano que todos los valores son positivos o cero.

Una vez presentado el modelo, cabe aclarar que el mismo se resuelve para todos los depósitos al mismo tiempo. Sin embargo, existe la posibilidad de resolverlo para cada depósito por separado, es decir, correr el programa cinco veces. En este trabajo vamos a utilizar la estrategia mencionada en primer lugar, ya que los tiempos de resolución (como veremos en el capítulo de Resultados) son rápidos. En términos computacionales, es lo mismo correr el modelo para todos los depósitos que separarlo para cada uno en particular. No obstante, si en el futuro los datos se modifican, se agrega una cantidad significativa de SKUs o incluso más depósitos y vemos que la performance del modelo toma más tiempo, la opción de separar la solución existe y es posible.

### 3.2. Estimación del parámetro de Demanda

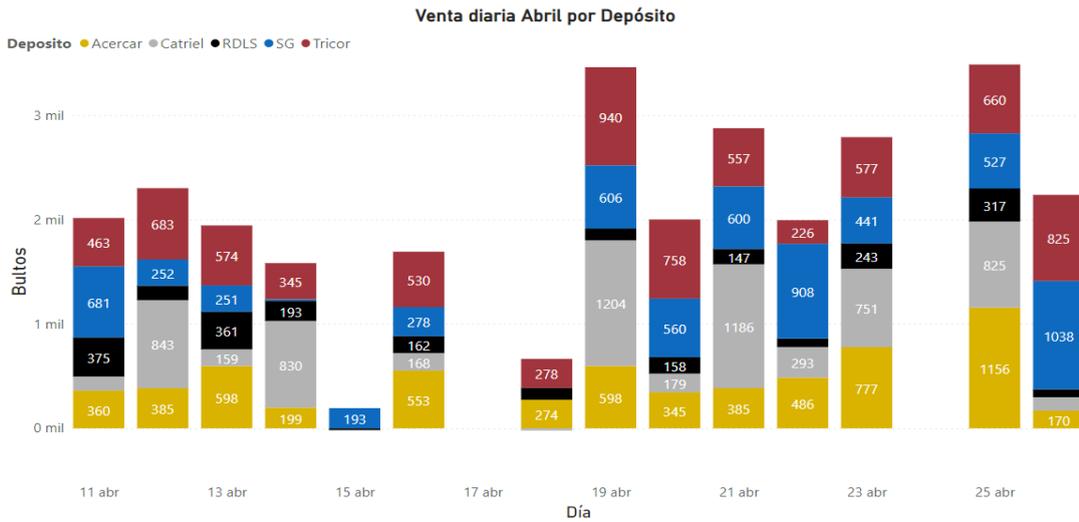
Como venimos mencionando a lo largo de la tesis, nuestro modelo toma diferentes inputs para determinar la cantidad óptima que debería comprar el Distribuidor. Por ejemplo, la demanda para cada producto. Sin embargo, este parámetro no viene dado de manera explícita por el Distribuidor, sino que debemos hacer cálculos adicionales para obtenerlo.

A continuación, detallamos el proceso para llegar a un número concreto de demanda, el cual fue validado y consensado con el Distribuidor. Este nuevo método de cálculo nos permite obtener un valor de demanda para cada SKU más acertado que la metodología tradicional con la que lo calcula el Distribuidor. El mismo toma la venta de cada producto en hectolitros y solamente lo multiplica por un porcentaje arbitrario mes a mes. A modo de ejemplo, la demanda que se espera para el mes de abril del SKU 2057 es la venta del mismo multiplicada por 0,7. En otras palabras, el Distribuidor supone que durante el mes de Abril va a vender un 30% menos para todos los SKUs. Este es un supuesto que realiza el Distribuidor, ya sea porque conoce su propio negocio y sabe que vende mes a mes o simplemente no tiene un proceso de cálculo más sofisticado que el que utiliza actualmente.

Dado que nuestro modelo calcula la compra que se debería realizar de manera diaria, necesitamos la venta para la misma periodicidad. A su vez, la demanda para cada SKU varía según donde se encuentra almacenado. Como vimos, cada depósito contiene todos los productos, ya que la distancia entre ellos va desde 200 a 700 km. Por tal motivo, es

entendible que la demanda varíe, ya que los costos logísticos de transportar todos los días productos de un depósito a otro son bastante altos. Para ilustrar esta variación de la demanda por depósitos podemos observar la Figura 7, la cual muestra datos históricos del mes de abril:

**Figura 7. Venta real diaria Abril por Depósito**



Ahora bien, dada esta venta diaria y por depósito pasamos a calcular el parámetro de demanda que va a utilizar nuestro modelo.

Debido a la estacionalidad que ya mencionamos y lo incierto de la demanda, vamos a utilizar el promedio diario de venta de la última semana y las últimas dos semanas por depósito y por SKU. En otras palabras, las últimas semanas de venta nos van a servir de “estimación” para entender cuál puede llegar a ser la demanda para los días que tenemos que correr el modelo. Este promedio va a ser diferente según el segmento al que pertenece cada SKU. Para los productos A, vamos a tomar el máximo valor entre el promedio diario de venta por depósito de la última semana y de las últimas dos semanas. En cambio, para los SKUs que se encuentran dentro de los segmentos B y C, el parámetro de demanda que vamos a utilizar va a ser la venta promedio por depósito de la última semana. Esta forma de tomar o “estimar” la demanda nos permite no recaer demasiado en largos periodos de datos, ya que, como mencionamos anteriormente, la estacionalidad afecta mucho la operatoria diaria. Por otro lado, calcular el parámetro con datos lo más actualizados posible y sin variaciones significativas permite estimar de manera más precisa al valor real.

A modo de ejemplo, vamos a calcular el parámetro demanda para el SKU más vendido de abril, el producto 2057. En Tabla 2 podemos observar el promedio diario de venta de la última semana (19/4 - 26/4) y el de las últimas dos semanas (11/4 - 26/4) por depósito. Dado esto y debido a que este producto es de clase A, tomamos el máximo valor entre estos valores y lo definimos como nuestro parámetro de demanda:

**Tabla 2.** Cálculo de demanda: Producto 2057

2057					
	SG	Catriel	RDLS	Acercar	Tricor
US	386	637	34	383	420
U2S	279	442	44	339	322
<b>demanda</b>	<b>386</b>	<b>637</b>	<b>44</b>	<b>383</b>	<b>420</b>

Con respecto a los periodos de tiempo utilizados (últimas semanas del mes), estos se van a ir actualizando semana a semana, es decir, a lo largo de la semana que nuestro modelo esté operativo, el parámetro de demanda que va a utilizar es un dato dado por las últimas dos semanas. A modo de ejemplo, la Figura 8 explica claramente para cada semana en las que el Distribuidor realiza un pedido, el período que se toma para calcular el parámetro de demanda:

**Figura 8.** Metodología de uso del dato demanda.

Semana	Marzo	Abril	Mayo	Junio
1				Compra 4
2			Compra 3	
3		Compra 2		
4	Compra 1			

Semanas de Compra  
 Demanda utilizada

Por ejemplo, para la cuarta semana de Marzo, el modelo utiliza como demanda la venta de las semanas 2 y 3 del mes correspondiente. De la misma forma, la Compra 3, se nutre de información de la primera semana de mayo y la última de abril.

### 3.3. Indicadores de Performance

Una vez definido el modelo con sus variables y respectivas restricciones, tenemos que determinar con qué métricas vamos a evaluar su desempeño, de manera tal de entender si el modelo que planteamos en la teoría está a la altura de la operatoria diaria del Distribuidor.

Para calificar el rendimiento del modelo vamos a proponer dos métricas que hacen referencia al uso y a los resultados del programa. Estas son: 1) Costo (en pesos

argentinos-AR- y dólares norteamericanos-USD-) adicional por pedir de más y 2) Tiempo total en el armado del pedido. Por un lado, estos dos indicadores nos van a permitir entender si el modelo arroja mejores resultados en cuanto a comprar óptimamente utilizando de manera eficiente los datos de stock y demanda, mientras que por otro, le va a permitir al equipo o al recurso dedicado a realizar la compra enfocar su trabajo en tareas que agreguen valor a la empresa, ya que el tiempo dedicado a contar stock, ver cómo viene la venta y en base a eso determinar un número adecuado de cuánto comprar va a ser una tarea del pasado.

A continuación, detallamos con una precisión mayor ambas métricas.

### **3.3.1. Costo adicional por pedir de más**

Este indicador consiste en cuantificar en dinero el costo adicional que tuvo el Distribuidor por haber comprado de más dado el stock y la venta de un cierto SKU.

El concepto “pedir de más” implica realizar una compra de uno o más SKU mayor que lo que determina nuestro modelo. Esta definición abarca, tanto los casos en que el Distribuidor efectivamente compró más que lo que el modelo indicó como cuando el programa nos dice que no compremos nada y el Distribuidor si lo hizo. En ambos casos, existe un costo adicional que hubo que afrontar y pudo haberse evitado al haber usado el modelo.

Para visualizar este número, vamos a tomar una semana típica del Distribuidor en el que realizó algunos pedidos y vamos a compararlo con lo que arroja nuestro modelo. Con el objetivo de que los resultados sean robustos, vamos a mostrar la venta real, el stock y los días de venta reales para comprobar si el número que obtenemos es razonable con los datos. En cuanto a costo, el mismo va a estar medido en pesos argentinos (AR) y en dólares estadounidenses<sup>7</sup> (USD). Con respecto al multiplicador de la demanda, vamos a tomar  $\alpha = 5$ . Tomamos este valor, ya que el Distribuidor utiliza este número para los primeros meses de la temporada baja como mínima cantidad de días de venta en los depósitos para todos los productos. Es razonable fijar esta cifra, ya que considera tener como mínimo aproximadamente una semana de stock para cubrir la venta en caso de que no haya producto o la demanda cambie bruscamente.

---

<sup>7</sup> Se tomará el promedio entre el valor de Compra y de Venta del dólar Blue para ese día. En el caso de que ese día haya sido feriado o fin de semana, se tomará el día hábil siguiente.

### **3.3.2. Tiempo total en armado de pedido**

Con respecto a esta métrica, simplemente consiste en comparar el tiempo que le lleva armar el pedido al Analista de Stock, mirando los inventarios, solicitando un reporte de ventas al área correspondiente, revisando objetivos, etc, contra revisar los resultados que arroja el modelo y tener una guía rápida para realizar la compra.

Actualmente, el proceso de decisión de compra para el Distribuidor es precario. Un Analista se encarga de realizar el pedido consultando depósito por depósito cuál es el stock, revisando cómo viene el avance de ventas, los objetivos del mes y, por último, el presupuesto asociado para hacer la operación. Todo este proceso de análisis le lleva bastante tiempo al área, sin mencionar que la decisión de compra está directamente relacionada con el *know-how* de la persona que se encuentra en la posición. Por lo cual, nos lleva a pensar que si este individuo no se encuentra un día, está de vacaciones, etc, el pedido que se realiza no es el mejor. Por otro lado, realizar todas las actividades implica descargar grandes volúmenes de datos de los sistemas que luego tiene que manipular de manera manual en un archivo de Excel y esto le lleva mucho tiempo. Por ese motivo, se busca optimizar el tiempo total del proceso de armado de pedido no solo con el modelo sino también con otras automatizaciones a lo largo de este flujo. Como por ejemplo, el uso de Macros en Excel.

Por estos motivos, consideramos esta métrica igual de importante que la anterior. No solo mejora cuantitativamente los resultados, sino que hace de una tarea manual y repetitiva un proceso sustentable y automatizado respetando las mismas reglas de negocio que aplica hoy el área de compras.

Para cuantificar esta métrica vamos a medir el tiempo total del armado del pedido en minutos, lo vamos a comparar contra lo que le lleva hoy al Analista de Stock hacer lo mismo. Este último dato es proporcionado por el mismo Distribuidor y fue conversado con el área correspondiente.

### **3.4. Solver de programación y lenguaje de modelado**

Como mencionamos, el software de programación lineal que vamos a utilizar va a ser SCIP, mientras que el lenguaje en el que vamos a modelar nuestro problema de optimización va a ser ZIMPL.

Concretamente, vamos a crear una carpeta que contenga tanto los inputs que ya mencionamos anteriormente en el formato *.dat* como así también el modelo escrito en el lenguaje ZIMPL y almacenado en un formato *.zpl*. Luego, el mismo se corre en la consola de

una computadora, de manera tal que los resultados que obtenemos se van a visualizar en la misma consola, sin tener la posibilidad de guardarlos en algún formato, como por ejemplo *xlsx*. Esto es una desventaja del solver utilizado, por ese motivo se propone para versiones futuras utilizar algún otro programa de optimización para resolver este problema.

Igualmente, con el objetivo de que el modelo sea útil para el que toma las decisiones de compra, lo que obtenemos a través de la consola va a ser convertido en un formato *.xlsx* que indique el código del SKU y la cantidad a comprar para cada depósito tanto en bultos como en pallets y, además, la cantidad en bultos del stock de seguridad que estaría incumpliendo para cada depósito. De esa forma, la lectura se hace más sencilla para el analista de stock y compras de la empresa. Adicionalmente, vamos a medir el desempeño del modelo con tres indicadores concretos que vamos a explicar más adelante.

### 3.5. Implementación de datos en lenguaje ZIMPL

Una vez detallado el modelo y el software de optimización que vamos a utilizar pasamos a describir las tablas en el formato *.dat* que solicita ZIMPL para leer los datos. Como mencionamos en el Capítulo 2, nuestro modelo va a consumir datos de siete tablas diferentes. A continuación, detallamos cada una de ellas:

#### 3.5.1. Tabla *SKUs*

El Distribuidor cuenta con una variedad de productos significativa que representa un total de 200 SKUs. Cada uno de ellos posee un código único que los distingue y permite identificarlos. Ahora bien, la tabla que vamos a utilizar como input para reconocer al portafolio de productos va a ser la siguiente:

**Tabla 3.** *SKU*

SKU	Clase
2057	A
17358	A
24684	A
25385	A
13404	C
7634	A
7651	A
7641	C
2218	A
2201	A

Cabe aclarar que el orden en el que están los códigos permanecen de esa forma de manera obligatoria, ya que el resto de tablas no posee una columna de *id* o identificador del SKU. Por lo tanto, es de suma importancia el trabajo previo de revisión de los datos recibidos, de

manera tal de asegurar la sustentabilidad del modelo y sus resultados. Además, sumamos el segmento de cada uno en caso de que se necesite una restricción adicional relacionada a la clase de producto. Por ejemplo, puede ocurrir que haya cierto límite de compra para productos A, ya sea por falta de stock o alguna política del proveedor.

### 3.5.2. Tabla *demanda\_diaria*

En base a lo visto en la subsección anterior, una vez definido el parámetro de demanda, lo que resta es almacenarlo en el formato de la Tabla 4. Esta posee cinco columnas, correspondientes a cada depósito y cada línea representa un SKU distinto.

**Tabla 4.** *demanda\_diaria*

SG	Catriel	RDLS	Acercar	Tricor
386	637	44	637	420
108	3	17	56	88
10	12	4	9	9
2	0	0	0	0
0	0	0	5	7
1	16	4	6	9
20	3	8	6	8
10	12	4	9	9
34	67	35	68	88
122	1	5	9	2

Vale aclarar que, este dato va a estar medido en bultos.

### 3.5.3. Tabla *stock\_inicial*

Al igual que la Tabla 4, el formato del input de stock es el mismo como así también la unidad de medida (bultos):

**Tabla 5.** *stock\_inicial*

SG	Catriel	RDLS	Acercar	Tricor
1699	1209	638	1011	2049
198	4581	0	1934	2814
200	0	0	0	0
23	0	0	0	0
0	0	0	237	833
413	146	182	363	394
352	69	45	24	1
0	0	0	0	0
281	218	933	1644	383
160	303	1177	641	794

Cabe destacar que esta tabla respeta un proceso de actualización diario.

### 3.5.4. Tabla *litro*

La Tabla 6 contiene únicamente los códigos de los SKU que son calibre de Litro:

**Tabla 6. litro**

SKU
2057
7641
2190
7026
7030
19253
16666
16667
16668
24880
2854
7126
7108

Como mencionamos al inicio, estos productos los destacamos en una tabla aparte debido a que una de las restricciones del modelo es específicamente para estos SKU.

### 3.5.5. Tabla lata

Como la tabla anterior, esta contiene únicamente los códigos de los SKU que son calibre de Lata:

**Tabla 7. lata**

SKU
17358
24684
13404
7634
2218
24959
13503
19254
24961
25183
24374
17932
24372
25189
16811
24373
25182
25225
21810
25119
16768
21853
20360
18588
23112
25346
25383
25658
25613
25761
21867
15234
21866
24879
23424
22608
22440
22438
24642
22588
24371

### 3.5.6. Tabla *bultos\_x\_pallet*

La Tabla 8 nos indica la cantidad de bultos que equivalen a un solo pallet para cada producto. Esta tabla es importante, ya que, los camiones que transportan el pedido del Distribuidor tienen un máximo que mide por pallets y no por bultos. Además, esta tabla nos sirve para luego calcular el peso que tiene un solo bulto dentro de ese pallet, ya que utilizaremos ese dato como restricción adicional en nuestro modelo. La Tabla 8 es la siguiente:

**Tabla 8.** *bultos\_x\_pallet*

Bultos por Pallet
50
100
100
0
220
100
400
50
100
400

### 3.5.7. Tabla *depositos*

La Tabla 6 sólo contempla el nombre de los depósitos:

**Tabla 9.** *depositos*

Depositos
SG
Catriel
RDLS
Acercar
Tricor

## 4. Resultados

En este capítulo vamos a presentar los resultados<sup>8</sup> del modelo de programación lineal entera propuesto en este trabajo. Los mismos van desde el tiempo que le lleva calcular los resultados hasta la cantidad en bultos y pallets que hay comprar, sin olvidar el stock de seguridad incumplido, en caso de haberlo.

Los datos utilizados corresponden al mes de Mayo de 2022. Específicamente, corremos el programa para determinar la cantidad óptima a comprar para las primeras dos semanas del mes, precisamente los días 3, 7, 11 y 14, respectivamente. El input de stock que va a tomar el modelo corresponde al stock real del Distribuidor para estos días para asegurarnos que el programa utiliza los mismos datos que el Analista de Stock utilizó para esos días. Con respecto a la demanda utilizamos el promedio de venta diario por SKU de las últimas dos semanas del mes de Abril para el caso de los primeros dos días, mientras que para los restantes utilizamos la venta de la última semana de Abril y la primera de Mayo. Como mencionamos en el capítulo anterior, el parámetro  $\alpha$  va a tener un valor de  $\alpha = 5$ , número que el Distribuidor considera razonable para los primeros meses de la temporada baja.

A continuación, detallamos los resultados obtenidos con el modelo de optimización.

### 4.1. Desempeño y primeros resultados

En primera instancia, vamos a mostrar el desempeño del modelo con respecto al tiempo de resolución del problema, cantidad de variables y restricciones, entre otras estadísticas que nos arroja SCIP. En la Tabla X, podemos observar las mismas:

**Tabla 10.** Estadísticas salida ZIMPL

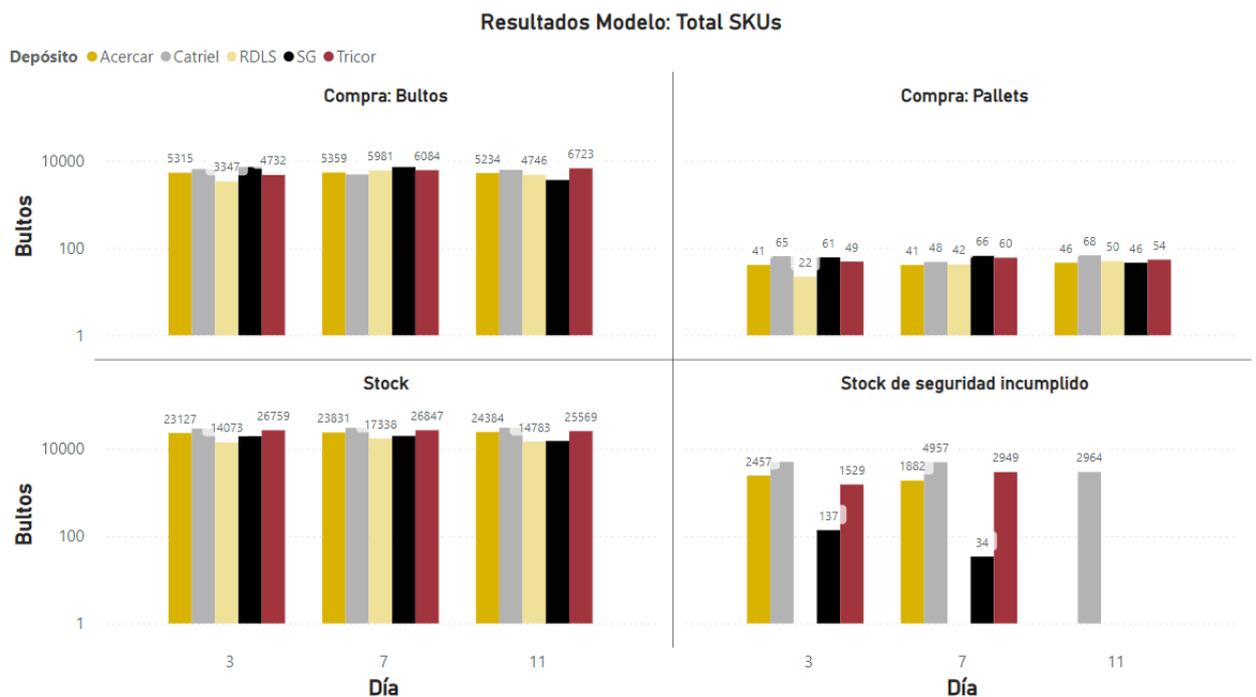
SCIP Status: problem is solved [optimal solution found]	
<b>Total Time</b>	<b>0.00</b>
solving	0.00
presolving	0.00 (included in solving)
reading	0.00
copying	0.00 (2 #copies) (minimal 0.00, maximal 0.00, average 0.00)
<b>Original Problem</b>	
Problem name	modelo.zpl
Variables	4925 (0 binary, 985 integer, 0 implicit integer, 3940 continuous)
Constraints	3950 initial, 3950 maximal
Objective	minimize, 985 non-zeros (abs.min = 1, abs.max = 1)
<b>Presolved Problem</b>	
Problem name	t_modelo.zpl
Variables	10 (4 binary, 3 integer, 3 implicit integer, 0 continuous)
Constraints	4 initial, 4 maximal
Objective	minimize, 7 non-zeros (abs.min = 1, abs.max = 108)

<sup>8</sup> Ver Anexo A

A primera vista, el status del problema figura resuelto, con lo cual hay una solución óptima para nuestra modelo. En cuanto al tiempo de resolución del solver, como podemos ver, le lleva un tiempo ínfimo resolver este problema de optimización. Si hacemos foco en la primera línea de *Total time*, el tiempo de resolución es 0 o aproximadamente 0, ya que no muestra todos los decimales. Este comprende tanto las etapas de resolución, pre resolución, lectura y copiado del problema. Con respecto al modelo en particular, se conforma de 4925 variables, divididas en 985 enteras (estas hacen referencia a los pallets) y el resto continuas, comprendidas en los bultos comprados, el stock, la demanda y el stock de seguridad incumplido. En resumen, el modelo se desempeña bien a nivel computacional y no necesita demasiado tiempo de procesamiento.

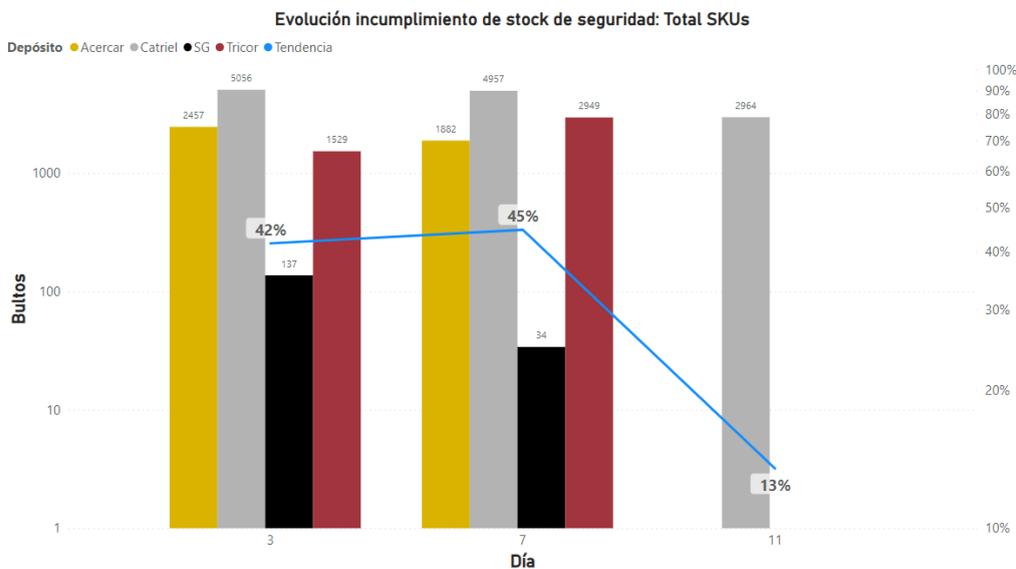
Una vez analizado el desempeño computacional del programa, pasamos a analizar los resultados obtenidos. El modelo nos arroja el valor de cuatro variables: i) Compra en bultos ( $x_{itw}$ ), ii) Compra en palets ( $p_{itw}$ ), iii) Stock ( $s_{itw}$ ) y iii) Stock de seguridad incumplido ( $w_{itw}$ ). Para todos los casos, los valores están por SKU y Depósito, sólo para la variable de stock  $s_{itw}$  el modelo además arroja los valores para los períodos  $t = 0, 1$ , ya que contamos con la información del stock del día anterior y cuanto nos va a quedar en el inventario el día de la compra. Podemos visualizar estos números en la Figura 9:

**Figura 9.** Resultados Modelo por depósito y variable.



Como podemos observar, tenemos los resultados de cada uno de los días y cómo se van modificando los valores a lo largo de ellos. Si vemos el primer cuadrante, no hay una constante en los datos que nos marquen una especie de patrón de compra. Sin embargo, si nos fijamos en el cuadrante de Stock, vemos que para los depósitos, en los cuales la compra se aumenta de un día a otro, el inventario del mismo aumenta. Esto tiene sentido y es lógico dada la definición de stock que vimos en la sección pasada. Cabe destacar, la granularidad de los datos, en especial la segmentación según los depósitos. Hoy en día, el Distribuidor realiza un pedido en total y luego distribuye a lo largo de los depósitos; ahora, el modelo presentado en este trabajo, sabe exactamente cuánto pedir para cada uno de ellos. Por otro lado, en el cuadrante inferior derecho, el stock de seguridad incumplido muestra un comportamiento interesante, sobre el cual hacemos foco en la Figura 10. Podemos observar que, para todos los depósitos excepto Tricor, el stock de seguridad incumplido disminuye y hasta tiende a desaparecer para el día 11, inclusive para este depósito. Esto significa que a lo largo de la semana, el modelo se adapta bastante bien a los datos, principalmente al stock y la demanda.

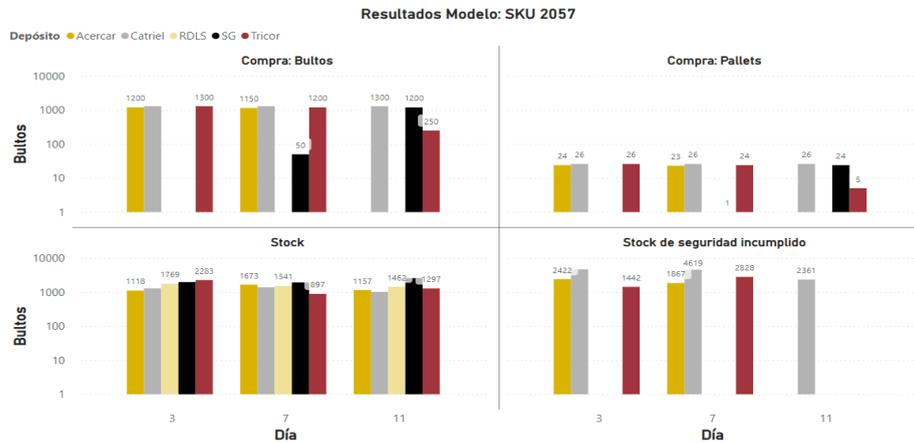
**Figura 10.** Resultados Modelo: SKU 2057



Cabe aclarar que el Distribuidor puede comprar todos los productos para todos los días. Sin embargo, no es habitual en su operatoria este tipo de comportamiento, ya que con el proceso actual que lleva de revisar stock y la venta no necesita comprar todos los productos que posee en su nómina. Lo mismo ocurre para el modelo, ya que puede comprar todos los productos cualquier día a menos que se defina una restricción de compra para ciertos SKUs, pero esto ya es una decisión de negocio del Distribuidor.

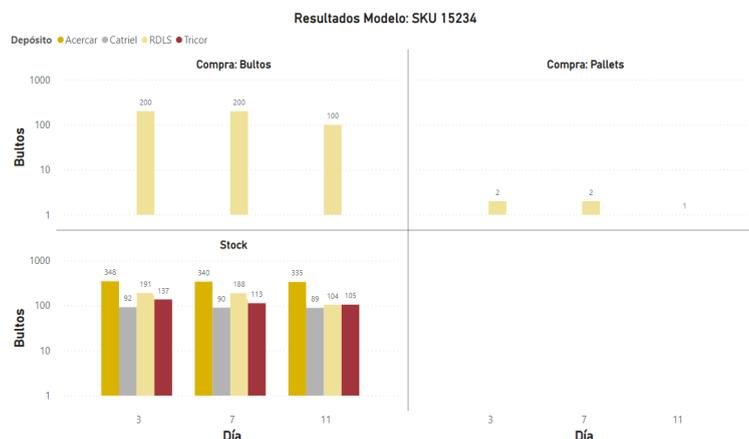
Haciendo foco en los resultados, en las Figuras 11 y 12, mostramos la compra para dos SKU específicos, el 2057 y el 15234. Seleccionamos a estos dos, ya que el primero corresponde a un producto de calibre de litro y el otro a uno de lata.

**Figura 11. Resultados Modelo: SKU 2057**



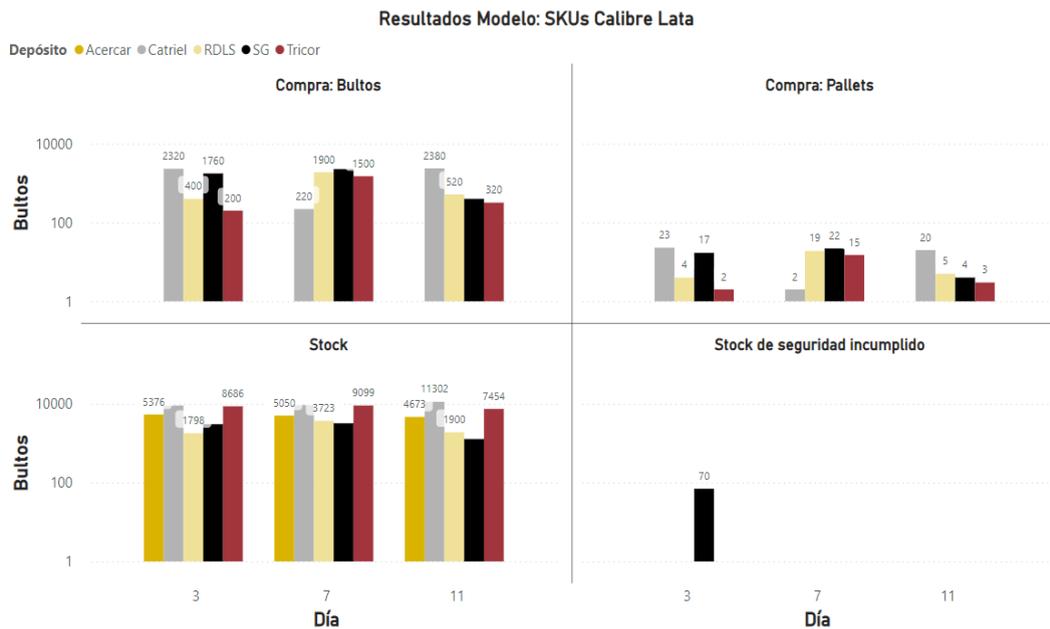
En este primer gráfico, podemos observar la compra para el SKU 2057. A primera vista, lo interesante es la constancia de pedido para dos depósitos Catriel y Tricor, como así también, la evolución del stock de seguridad incumplido para ambos. Evidentemente, la venta y la rotación de stock para estos centros son altos. En base a la venta del Distribuidor, los calibres de litro y lata son los más vendidos y, por ende, los que rotan más en los depósitos. Además, como vimos en la Figura 4, este SKU es el más vendido en el mes de Abril y, según datos históricos, es el producto que más vende el Distribuidor. Notemos que, en los dos cuadrantes superiores, la compra para cada depósito no supera los 1300 bultos o los 26 palets, respectivamente. Esto se debe a la restricción que le impusimos al modelo de compra máxima para los productos de calibre litro, por ende, eran esperables los resultados.

**Figura 12. Resultados Modelo: SKU 15234**



En la Figura 12, vemos una especie de compra más pasiva o menor por parte del modelo. Para este producto, no se incumple el stock de seguridad, lo cual es un dato positivo para el Distribuidor, ya que respeta la cantidad de días de venta en los depósitos y las compras que realiza no son muy grandes. De la misma forma que el SKU 2057, este posee un máximo de compra por depósito de 2400 bultos o 24 palets, ya que el calibre es de lata. Sin embargo, como el modelo no necesitó comprar demasiado para satisfacer la demanda y mantener un stock de cinco días en cada depósito, no fue necesario alcanzar este máximo. De hecho, en la Figura 12 mostramos el mismo gráfico que venimos observando, pero solo con los productos de lata y ninguno de ellos alcanza el máximo.

**Figura 13. Resultados Modelo: SKU calibre Lata**



Como señalamos, para ningún depósito se alcanza el máximo de compra. Sí lo que podemos ver es que para un SKU hay un incumplimiento del stock de seguridad de 70 bultos. Sin embargo, este número no es muy grande y, además, es solo para uno de los depósitos, que solo se incumple un día. Cabe destacar, en el cuadrante de Stock, la alta cantidad de inventario que el Distribuidor tiene para estos días en todos los depósitos. Por ese motivo, es que no compra demasiado y no incumple casi nada de stock de seguridad.

## 4.2. Performance: Modelo vs Realidad

En base a los resultados presentados anteriormente, vamos a realizar una comparación entre los datos reales del Distribuidor. Por un lado, la compra realizada para los días utilizados y, por otro, el tiempo total que le lleva todo el proceso del armado del pedido.

En primera instancia, observamos los resultados del modelo contra la compra que efectivamente realizó el Distribuidor los días seleccionados. El objetivo de hacer esta comparación consiste determinar la cantidad de producto que el Distribuidor compró de más, es decir, según las restricciones que definimos para el modelo y los datos tanto de stock como de demanda, el modelo determina la cantidad óptima de compra, pudiendo ser menor que la que terminó siendo en la realidad. A esa cantidad “extra” que el Distribuidor compró, la multiplicamos por el precio por bulto que le cobra su proveedor y obtenemos el valor por haber pedido de más. Recordemos que, el precio por el que multiplicamos esta diferencia está en pesos argentinos (AR) y al mismo lo dividimos por el valor del dólar estadounidense (USD) para tener una comparativa con una moneda más estable. En la Tabla 11, observamos estos resultados:

**Tabla 11. Comparación resultados: Modelo vs Realidad**

Fecha	SKU	Venta real Bultos	Stock	Compra real	Días de venta	Costo de pedir de mas (\$)	Costo pedir de mas (USD)	Compra modelo	Diferencia
3-may-22	8101	3	176	60	59	\$ 52.080,00	USD 258,21	0	-60
3-may-22	19342	67	1405	360	21	\$ 202.440,00	USD 1.003,67	120	-240
3-may-22	20433	1	90	252	180	\$ 398.552,01	USD 1.975,96	84	-168
11-may-22	7026	5	330	400	73	\$ 327.920,40	USD 1.613,78	200	-200
11-may-22	8101	18	315	60	18	\$ 52.080,00	USD 256,30	0	-60
11-may-22	19342	58	1863	420	32	\$ 151.830,00	USD 747,19	240	-180
11-may-22	25979	7	53	110	8	\$ 111.034,31	USD 546,43	0	-110
11-may-22	25980	1	45	110	45	\$ 111.034,31	USD 546,43	0	-110
<b>TOTAL</b>				<b>1772</b>		<b>\$ 1.406.971,03</b>	<b>\$ 6.947,97</b>	<b>644</b>	

A primera vista, vemos una baja significativa en la cantidad comprada de 1772 a 644 bultos la cual representa una reducción de aproximadamente un 65%. Esto implica que el modelo le hace comprar al distribuidor lo necesario para satisfacer la demanda diaria y mantener un stock en el depósito para cinco días de venta. En términos económicos, el costo adicional por “pedir de más” fue de \$1.5 Mio de pesos argentinos o USD 7000, para ambos días. Por ejemplo, en el día 3 y el SKU 8101, el Distribuidor compró 60 bultos y nuestro modelo determinó no comprar nada, ya que la cantidad de días de venta que posee este producto es casi 60, es decir, un total de dos meses stock y, aún así, el Distribuidor realizó un pedido. Este patrón continúa para el día 11, donde de nuevo el programa determina no comprar nada, mientras que en la realidad se vuelve a realizar un pedido por la misma cantidad de bultos. Si bien los días de venta se redujeron más de la mitad que el día anterior, lo cual tiene sentido, ya que pasó más de una semana y la venta avanza, aún así el modelo sostiene la decisión de no comprar. Lo mismo ocurre para los productos 25979 y 25980 en el día 11, en ambos la compra óptima es de 0 a pesar de los días de venta que tiene cada uno. Para el resto, podemos ver que el modelo determina una cantidad menor de la que efectivamente el Distribuidor compró. Como por ejemplo, el producto 7026, el modelo determina comprar la mitad de la que se compró ese día. Cabe destacar que este es un SKU de segmento A, con lo cual tiene una alta rotación, donde en el

mes de abril fue el séptimo más vendido en general y, dentro de los calibres de litro, es el segundo con más demanda.

Cabe aclarar que esta diferencia económica de \$1.5 Mio no significa un ahorro para el Distribuidor, ya que él mismo realizó la compra de esos bultos adicionales. De hecho, no podemos considerarlo cómo un “costo adicional”, ya que tarde o temprano esa cantidad va a ser vendida, excepto que sea un producto B o C de muy baja rotación y con una fecha de vencimiento demasiado cercana. No obstante, el modelo que planteamos en este trabajo busca dar la cantidad óptima en base a las restricciones y necesidades de negocio que fueron planteadas por el Distribuidor. Desde otro punto de vista, podemos considerar esta cifra como un costo de oportunidad perdido para utilizar ese monto para otro tipo de gasto. Por ejemplo, el Distribuidor cuenta con una amplia flota de camiones que requieren mantenimiento y combustible todo el tiempo, esta cifra podría haber sido destinada para estos gastos.

Evaluamos ahora nuestro modelo en la operación concreta, es decir, en el proceso de armado de pedido que realiza el Distribuidor. El mismo consiste de varios pasos que se resumen en el conocimiento del comprador. El proceso va desde la consulta del stock de manera virtual y física, ambos chequeos son necesarios para conocer con cuánto inventario se cuenta a la hora de hacer la compra. Luego, se hace un seguimiento de la venta de los días anteriores para evaluar cuál es el SKU que se está vendiendo más o menos y, por último, se consulta con el área de ventas los objetivos del mes y cuánto es la cantidad a la que tienen que llegar a vender para fines del mismo. Todo este proceso lo lleva una persona que se denomina Analista de Stock. En la Tabla 12, vemos los tiempos estimados para cada parte del proceso:

**Tabla 12.** Proceso de armado de pedido: Actual vs Modelo

<b>Paso a paso Armado de pedido</b>			
#	Proceso	Tiempo (Minutos)	
		Actual	Usando el Modelo de Compra
1	Bajar Stock de sistema	25	5
2	Realizar control físico	30	30
3	Comparar Stock físico vs Real	60	30
4	Bajar Avance de ventas del sistema	25	5
5	Revisar Ventas	10	0
6	Armado de pedido	60	5
<b>Total</b>		<b>210</b>	<b>75</b>
<b>Ahorro (tiempo)</b>	<b>Minutos %</b>	<b>135 -64,29%</b>	

En primera instancia, vemos una reducción en el tiempo total del proceso de 135 minutos que representan una eficiencia de aproximadamente 64,29% en todo el flujo. Estamos

hablando que la tarea que realiza el Analista de Stock pasa de 3 horas y media a 1 hora y 15 minutos.

Esto se debe principalmente a que no solo buscamos optimizar la tarea del armado de pedido, sino que también nos enfocamos en las tareas previas relacionadas al mismo. En el caso de las actividades 1, 3 y 4, se realizó una automatización del armado de los reportes de stock y venta mediante Macros utilizando el lenguaje de programación Visual Basic. Logrando así reducir esas actividades al menor tiempo posible. De la misma manera, los archivos necesarios para correr el modelo están en un formato que no es el solicitado por el software de optimización y mediante Visual Basic convertimos esos datos para que el programa ZIMPL los lea correctamente.

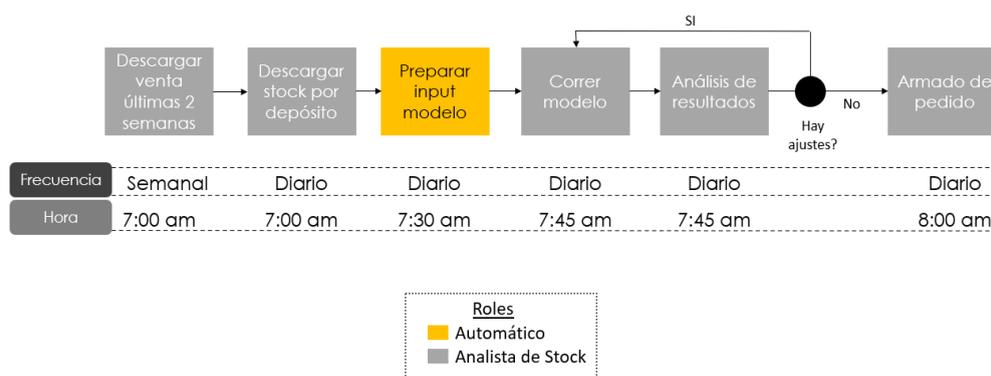
Esta ganancia de tiempo le permite al Analista de Stock tomar decisiones más estratégicas como por ejemplo cómo almacenar el stock en los depósitos, que SKU se entrega primero, etc. Por otro lado, la parte de la revisión de ventas ya no es necesaria, ya que el modelo toma estos parámetros y los entiende de antemano sin necesidad de que la persona encargada entienda estos reportes.

### 4.3. Implementación del modelo en la operación del Distribuidor

Como último punto, vamos a explicar cómo es la propuesta inicial de la incorporación del modelo y sus resultados a la operatoria diaria del Distribuidor. El objetivo es que sea útil para la toma de decisiones y le permita generar procesos más eficientes tanto a nivel económico como operacional. Por el contrario, la idea es no sumarle trabajo adicional al Distribuidor.

En la Figura 14, podemos observar el proceso punta a punta donde interviene el modelo de optimización de compra así como el rol del Analista de Stock en el día a día:

**Figura 14.** Proceso del Modelo de optimización de Compra



A primera vista, vemos que casi todas las actividades excepto la del envío de las ventas son de frecuencia diaria. Recordemos que el modelo utiliza los datos diarios de stock, mientras que en el caso de la demanda, utiliza el promedio diario de venta por SKU de las últimas dos semanas. Por otro lado, la hora en la que se realiza el proceso de armado de pedido es durante la mañana, tanto la información de stock como la de venta se encuentra actualizada a partir de las 7:00 am. Por ende, la hora límite para realizar la compra es a las 9:00 am. En caso de que el Analista de Stock no llegue a realizar la compra antes de esa hora, el pedido se contabiliza para el día siguiente. Por ese motivo, debe preparar los datos y tener los resultados del modelo antes de esa hora. Cabe destacar que la actividad relacionada a la preparación de inputs para el modelo se realiza de manera automática. Como comentamos anteriormente, el armado de reportes de stock y de venta fueron automatizados a través de la creación de Macros y esto no se limita solamente a estos reportes sino también a los datos que toma el modelo. Estas automatizaciones están disponibles para el Analista de Stock y el mismo es el responsable de ejecutarlas como así también correr el modelo. Para esta última parte, se capacita al Analista y se le deja un manual de procedimiento claro que le explique: i) cómo correr el programa en la consola de la computadora, ii) cómo leer los resultados y pasarlos a un archivo de Excel, iii) como realizar cambios sencillos en el archivo *.zpl* original, iv) casos de contingencia y v) el formato de los datos y vi) contactos de emergencia. En caso de no haber modificaciones o errores cuando se corre el modelo el Analista de Stock procede a armar el pedido.

Con respecto a los tiempos de implementación del modelo, se considera un período de 8 semanas. En la Figura 15, podemos ver el cronograma detallado del plan:

**Figura 15.** Plan de implementación

Descripción	Mes 1				Mes 2			
	1	2	3	4	1	2	3	4
Período de Cierre								
Capacitación Analista de Stock								
Período de prueba de Modelo: Analista								
Armado de pedido con Modelo								

Creemos que es razonable que sean dos meses, ya que para la primera y última semana del mes el Distribuidor se encuentra en el período de cierre y los tiempos que le puede dedicar son reducidos. Además, la capacitación al Analista de Stock nos va a llevar un período aproximado de dos semanas más que nada para prepararlo en caso de contingencias que puedan aparecer y no tanto en cómo correr el modelo, ya que es un código simple. Luego, se van a utilizar dos semanas destinadas a la prueba del modelo, tanto para sus resultados como para que el Analista de Stock haga el proceso punta a punto por sí mismo. Por último,

tomamos la octava semana como el punto de partida para la utilización del modelo por parte del Distribuidor de forma autónoma.

## **4.4. Posibles mejoras a futuro para el Modelo**

Para trabajos posteriores o posibles mejoras al modelo, podemos considerar diferentes propuestas que van desde una mejor estimación del parámetro de demanda hasta nuevas propuestas de función objetivo o restricciones. A continuación detallamos algunas ideas para colaboraciones futuras.

### **4.4.1. Estimación del parámetro de demanda**

Por motivos de tiempo, en este trabajo proponemos un método de estimación del parámetro de la demanda simple. Esto se debe a que el foco de la tesis se basa en un modelo de optimización y no en realizar un *forecast* de demanda riguroso, sino que buscamos tener un parámetro que simplemente sea razonable para el modelo. Sin embargo, consideramos que este valor puede llegar a ser mejor utilizando métodos más sofisticados de cálculo como algoritmos de Machine Learning, Deep Learning o Series de Tiempo.

En el trabajo de Kochak & Sharma (2015), los autores remarcan la dificultad de predecir la demanda de bienes de consumo. Estos proponen estimar este parámetro utilizando redes neuronales artificiales (ANN<sup>9</sup>) con el objetivo de mejorar las decisiones de negocio en cuanto a producción y manejo de inventarios. Por otro lado, Carbonneau, Laframboise & Vahidov (2008) evalúan distintas técnicas avanzadas de Machine Learning como redes neuronales, redes neuronales recurrentes y support vector machines (SVM) para estimar la demanda al final del *supply chain*. Los autores los comparan con otros métodos más simples como estudio de tendencias, moving average (MA) y regresiones lineales. Estos llegan a la conclusión de que los mejores métodos son redes neuronales recurrentes y SVM, pero que estadísticamente no son significativas.

De esta manera, vemos que hay diferentes técnicas que pueden determinar un valor más acertado que el que se estima en este trabajo.

### **4.4.2. Modificaciones al modelo actual**

El modelo presentado en este trabajo se adapta a las necesidades del negocio y la operación del Distribuidor. Sin embargo, se pueden considerar distintos enfoques tanto para la función objetivo como para nuevas restricciones que se pueden adicionar.

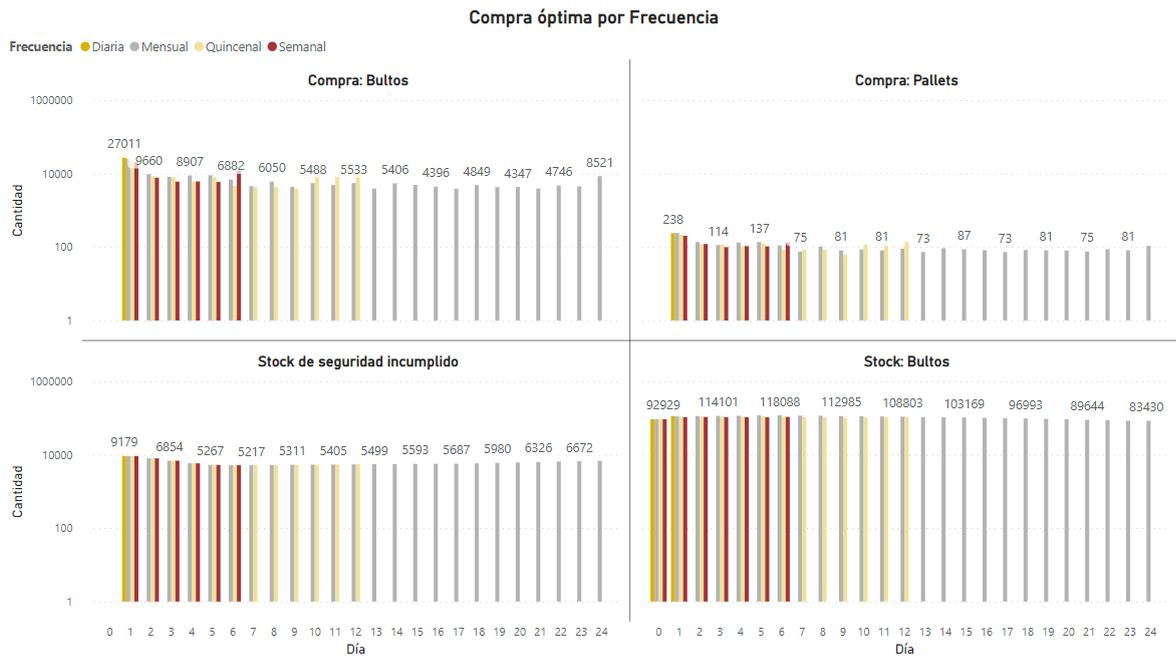
---

<sup>9</sup> Artificial Neural Network

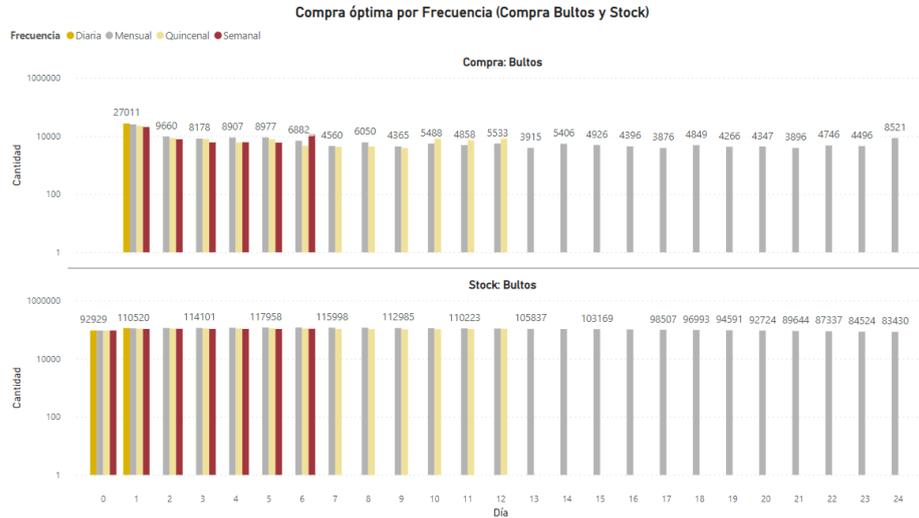
### 4.4.2.1 Planificación de compra: Horizonte temporal ampliado

Como observamos a lo largo de este trabajo, el modelo que se presenta busca determinar la cantidad óptima de compra para el Distribuidor para tan solo el día corriente. Esto podría llegar a considerarse simple dado las múltiples complejidades que se le presentan en el día a día. Por ello, es posible considerar ampliar el horizonte temporal del modelo, de manera que le permita al Distribuidor una manera más eficiente de organizar su stock, compra y venta. Para esto, vamos a evaluar el modelo para cuatro tipos de horizontes temporales: i) diario, ii) semanal, iii) quincenal y iv) mensual; con el objetivo de observar el comportamiento del modelo para las distintas frecuencias. En todos los casos tomamos el stock del Distribuidor el día 3-5 y la demanda estimada las últimas dos semanas anteriores (del 17-4 al 28-4). En la Figura 16 observamos los resultados para todas las variables y en la Figura 17 ampliamos los resultados para solamente las variables de compra y stock:

**Figura 16. Compra óptima por Frecuencia**

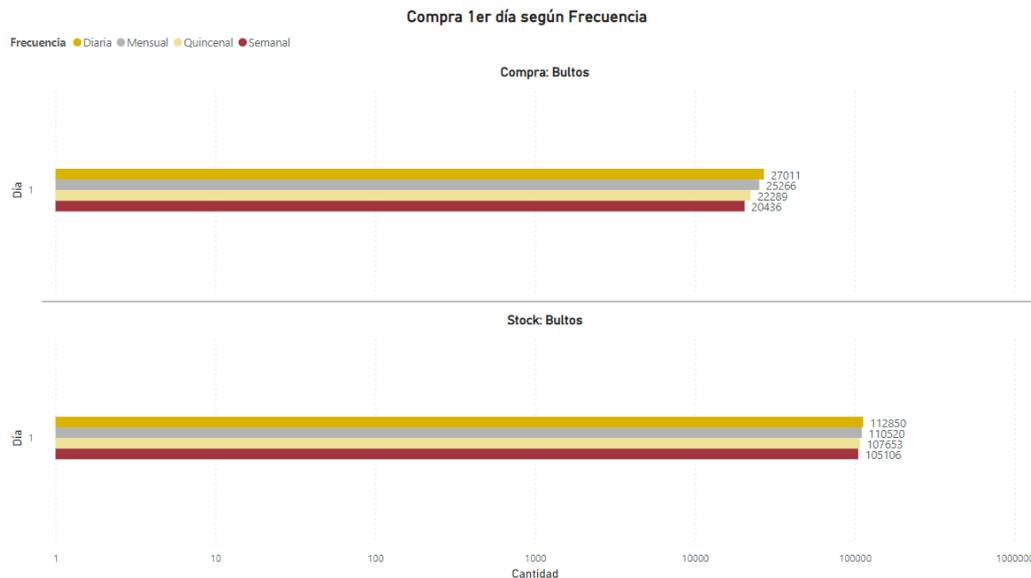


**Figura 17. Compra óptima por Frecuencia (Compra: Bultos y Stock)**



En la Figura 16, vemos que no parece haber una diferencia notoria en la compra para los distintos días. Sin embargo, en la Figura 17 podemos observar un comportamiento diferente del modelo para el primer día de decisión. A primera vista observamos que el modelo original (cantidad óptima para el día corriente) es el que decide comprar más, después le sigue el de planificación mensual, quincenal y, por último, semanal. De manera tal de visualizar con mayor claridad los resultados para el primer día de decisión observamos la Figura 18:

**Figura 18. Compra óptima 1er día por Frecuencia**



Como podemos ver, el modelo que arroja la cantidad óptima a comprar para un solo día es el mayor. Esto parece ser razonable, ya que al no evaluar el stock y la demanda de los días subsiguientes el modelo resuelve comprar lo que necesita para ese momento dado las restricciones planteadas en este trabajo como la cantidad mínima en el depósito y satisfacer la demanda estimada. No obstante, resulta interesante ver que el modelo decide comprar para el primer día casi la misma cantidad que el resultado original, pero considerando una planificación mensual. Probablemente se debe a que resuelve comprar una gran cantidad los primeros días y luego el resto del mes se abastece con el stock. Por otro lado, considerando una planificación semanal la cantidad que determina el modelo es la menor dado los cuatro escenarios.

Ahora bien, dada la industria en la que se encuentra el Distribuidor y la estacionalidad presente en la misma, hace que sea difícil planificar un horizonte temporal en el que organice el pedido que va a hacer para más de un día, una semana o incluso el mes. Este tipo de planificación va a depender de la industria y comportamiento de la demanda de la misma para adecuar el modelo a esas necesidades. En el caso del Distribuidor que se toma de ejemplo en este trabajo, la demanda varía constantemente durante el año y, especialmente, dentro de cada mes. Por lo general, los primeros y últimos días la demanda es muy alta, mientras que durante el mes el comportamiento es estable, esto hace que el Distribuidor realice los pedidos no siempre el mismo día o durante el mes. Sin embargo, para el caso del Distribuidor utilizado en este trabajo, podría considerarse aumentar gradualmente el horizonte temporal de decisión del modelo de manera tal de realizar una planificación de compra más eficiente. No obstante, como mencionamos anteriormente, esto va a depender de la industria y de la empresa en particular, ya que, la demanda puede ser constante, pero particularmente la organización posee particularidades que hace que sea difícil mantener una planificación a mediano o largo plazo.

#### **4.4.2.2 Restricciones adicionales**

Las restricciones propuestas en este trabajo se adaptan a las necesidades planteadas por el Distribuidor debido al tipo de negocio y la disponibilidad de datos. Sin embargo, podemos evaluar nuevas restricciones que mejoren el funcionamiento y la certeza del modelo.

En primer lugar, podemos pensar en el tipo de producto que compra el Distribuidor. En el caso de este trabajo es un bien perecedero y dada la política del proveedor del Distribuidor, no puede vender cualquier SKU que tenga menos de 90 días para su vencimiento. Por ende, podemos pensar esta consideración como una restricción adicional al modelo en base a la fecha de vencimiento del producto en la que especifique que utilice

los SKU de los depósitos que menos días le quedan para llegar a 90, o bien, comprar a su proveedor los SKU que tengan más de 180 días por vencerse . De esa manera, el Distribuidor se asegura que como mínimo tiene tres meses para vender esos SKUs. En términos matemáticos, puede considerarse agregar un índice a la variable  $x$  que sea la cantidad de días que le quedan por vencer. También, se puede considerar una segmentación de productos, pero no por rotación sino por cantidad de días por vencer. De esa forma, se le indica al modelo que los SKUs que están a pocos días de vencer que se venden primero y los que están lejos de esa fecha que los mantenga en stock en el caso de que haya cumplido la demanda.

En segundo lugar, podemos considerar restricciones de capacidad máxima de los depósitos. Dado que el espacio físico con el que cuenta el distribuidor es finito puede pensarse en restricciones que limiten la compra de producto en el que caso que este sobrepase el depósito. Esto puede variar dado el tamaño de cada depósito o los costos asociados del almacenamiento. Por ese motivo, resulta importante entender las dimensiones del espacio físico con el que cuenta el Distribuidor para guardar el stock y los costos asociados.

Por último, podemos sumar como restricción al modelo los días que le tarda al Distribuidor recibir su compra. En este caso en particular no aplica, pero puede ocurrir que el Distribuidor realice la compra de sus productos y no le llega el mismo día sino  $t$  días más tarde debido a que posee otro envase, están esperando mayor cantidad de pedidos para enviar a esa zona, etc. Dado esto, no puede contar con esa cantidad para satisfacer la demanda día corriente sino que debe hacerlo con el stock que tiene el depósito. Considerando esto podemos agregar restricciones al modelo dado el tiempo que va a tardar en llegar el SKU al depósito del Distribuidor.

Las restricciones adicionales planteadas anteriormente fueron tenidas en cuenta para ser sumadas al modelo, pero debido a motivos de disponibilidad de datos como la fecha de vencimiento del SKU al momento de la compra y capacidad máxima de los depósitos no fue posible sumarlas al modelo de este trabajo. Sin embargo, algunas de ellas pueden ser tenidas en cuenta en empresas dentro de la misma industria del Distribuidor, o bien, fuera de ella. No obstante, como mencionamos anteriormente, va a depender de tres cuestiones fundamentales como son el tipo de industria, la operación de la organización y la disponibilidad de los datos.

#### 4.4.2.3 Modificaciones a la Función objetivo

Para empezar, podemos pensar la misma función objetivo de este trabajo, pero con una variación. En la tesis se plantea un modelo que minimiza el incumplimiento del stock de seguridad independientemente del SKU, ya sea de diferente calibre, tipo de producto o clase. Por ende, puede ser útil para el Distribuidor ponderar el incumplimiento según cierto parámetro. En el caso del presente trabajo, podemos proponer un parámetro en base a la rotación del inventario, es decir, asignar un peso mayor a SKUs de clase A y un valor a los productos B y C, respectivamente. Por ejemplo, el trabajo plantea la segmentación o clase de SKU en base a la regla de Pareto 80-20, para el caso del parámetro podemos aplicar la misma lógica donde el incumplimiento del stock de seguridad de los productos clase A valga 0.8 y los del resto 0.2 o algún valor otro valor. De forma matemática podemos pensar la función objetivo de la siguiente manera:

$$\min \left\{ \sum_{i=1}^{200} \sum_{t=0}^{31} \sum_{w=1}^5 (0.8 * wa_{itw} + 0.2 * wbc_{itw}) \right\} \quad (9)$$

$$\forall i \in P, \forall t \in T, \forall w \in W$$

Las variables que vemos en la ecuación (9) las definimos de la siguiente forma:

$wa_{itw}$  = stock de seguridad incumplido del producto  $i$ , clase A, el día  $t$  para el depósito  $w$

$wbc_{itw}$  = stock de seguridad incumplido del producto  $i$ , clase B y C, el día  $t$  para el depósito  $w$

De igual manera, podemos evaluar otra forma de estimar el parámetro de la función objetivo con un método más sofisticado como por ejemplo algoritmos de *Machine Learning* o *AI* (Artificial Intelligence).

Por otro lado, minimizar el costo total de compra de SKU puede ser una variante a la función objetivo de este trabajo. En términos matemáticos podemos pensar en una función de la siguiente forma:

$$\min \left\{ \sum_{i=1}^{200} \sum_{t=0}^{31} \sum_{w=1}^5 p_{itw} * x_{itw} \right\} \quad (10)$$

$$\forall i \in P, \forall t \in T, \forall w \in W$$

La ecuación (10) define la minimización total de costos en donde  $p_{itw}$  representa el precio por bulto del SKU  $i$ , el día  $t$  y para el depósito  $w$ . A su vez, la variable  $x_{itw}$  se define como la cantidad en bultos del SKU  $i$ , el día para el depósito  $w$ . Esta nueva forma de plantear la función objetivo puede ser útil para empresas o industrias que tengan un presupuesto

acotado o donde los precios varíen demasiado. En el caso del Distribuidor utilizado para este trabajo, la función objetivo original se adapta en gran medida a su operatoria diaria, ya que no posee problemas de liquidez y la forma de pago a su proveedor es una ventaja que le permite pagar incluso después de la fecha en que se recibe la mercadería. No obstante, resulta una opción válida utilizar funciones objetivo de mínimo costo siempre y cuando le sea útil a la organización.

#### **4.4.3. Gestión de productos en los depósitos**

Hoy en día, el Distribuidor aloca los productos en base a la venta, pero no utiliza algún depósito como central, sino que tiene todos los productos en todos lados, con lo cual este es un desafiante problema para abordar. Por ende, nos encontramos en una nueva problemática que pertenece a la rama de *Management* de Inventario.

Como trabajo complementario a éste, se puede considerar como problemática a resolver cómo distribuir la compra óptima (resultado de este trabajo) en los distintos depósitos. En el trabajo de Tsao, Mangotra, Lu & Dong (2012), los autores resaltan lo complejo de las redes de distribución en los negocios actuales y proponen un modelo de aproximación continua (CA<sup>10</sup>) para representar la red de distribución. Los mismos utilizan técnicas de programación no lineal para resolver este problema de optimización con el objetivo de minimizar el costo total de distribución de la red.

Este tipo de enfoque es razonable para la operación que presentamos en este trabajo para el Distribuidor, ya que posee una considerable cantidad de depósitos que almacenan todos los productos y la demanda entre ellos es diferente. Se puede considerar combinar la propuesta del trabajo de Tsao, Mangotra, Lu & Dong (2012) con alguna técnica de estimación de demanda presentada anteriormente. De esa forma, continuamos optimizando la red de distribución del Distribuidor punta a punta.

#### **4.4.4. Utilización de otros softwares de optimización**

En el presente trabajo se utiliza el software de optimización SCIP, pero empleando el lenguaje de modelado ZIMPL. Sin embargo, se puede considerar el uso de otras herramientas de optimización, ya sean de código abierto o no para resolver el problema en cuestión.

Un primer enfoque que podemos pensar es utilizar el solver de Excel. Este sería un camino plausible, ya que el uso del mismo no es complicado y hasta el mismo personal del

---

<sup>10</sup> Continuous Approximation

Distribuidor puede utilizarlo sin requerir una capacitación extensa. En el trabajo Viveros & Salazar (2010), los autores desarrollan un modelo de planificación de producción de un sistema multiproducto con múltiples líneas de producción, el cual fue resuelto a través MS Excel con uso Premium Solver Platform. Por otro lado, Mokhtar & Mohamed (2014) plantean resolver un problema de optimización de portfolio de activos financieros mediante el uso de CPLEX. Según ellos, con este solver se alcanzan buenos resultados dentro de una ventana de tiempo razonable en el caso que la cantidad de observaciones pasadas y activos que tenga el modelo sean bajas. Tanto Premium Solver Platform como CPLEX son softwares de optimización pagos por los que hay que afrontar un costo relativamente alto para poder usarlos en la práctica.

Cabe destacar que el uso de un solver u otro depende completamente del tipo de problema que se busca resolver y la cantidad de datos. Sin embargo, existen casos donde los solvers comerciales poseen una mejor performance que los de tipo *open source*. En Meindl & Templ (2012), luego de una comparación entre solvers comerciales y gratuitos, sugiere que los primeros tienen un desempeño ligeramente mejor.

## 5. Conclusiones

En la presente tesis se expone un modelo de programación lineal entera con el objetivo de obtener como resultado la cantidad óptima a comprar de ciertos productos en pos de no quebrar stock, satisfacer la demanda y, principalmente, minimizar la mayor cantidad posible de incumplimiento de stock de seguridad posible para cada uno de ellos.

A lo largo del trabajo, se detalla la operación diaria que conlleva un Distribuidor, el cual enfrenta diferentes tipos de obstáculos a lo largo procesos obsoletos o que han quedado pequeños para la complejidad de la realidad que atraviesa día a día. Uno de ellos es el armado del pedido, de manera tal de respetar su inventario y satisfacer una demanda estacional durante el año. Dado esto, el modelo de optimización que se formula se basa en las necesidades del Distribuidor. Como por ejemplo, la cantidad máxima a pedir para SKU de cierto calibre, la cantidad mínima de stock en sus depósitos, etc. Capturadas todas las decisiones e inquietudes de negocio se adaptó un modelo de programación estilo *lot-sizing*, a un programa capaz de tomar datos reales de stock y demanda y convertirlos en un pedido concreto que le sea útil al Distribuidor.

En cuanto a resultados, observamos que el modelo le trae beneficios al Distribuidor. Por un lado económicos, ya que comparamos la performance del modelo con respecto al pedido que se hizo en la realidad y se hubiese obtenido una cifra de aproximadamente \$1.5 Mio de pesos argentinos o su equivalente en dólares estadounidenses de USD 7.000, comprendido como el “costo de pedir de más”. Como aclaramos en el capítulo de Resultados, esto no significa un ahorro para el Distribuidor, ya que es dinero que efectivamente se gastó, pero sí podemos considerarlo como un costo de oportunidad de haber utilizado esa cifra para otro gasto. Por ejemplo, el mantenimiento de los camiones. Por otro lado, se logra una eficiencia en los procesos, debido a que la utilización del modelo le reduce al Distribuidor 135 minutos por día las tareas que lleva a cabo el Analista de Stock, de manera tal que pueda dedicarse a otras actividades que sumen más valor, como por ejemplo, organización de stock en los depósitos, despacho de productos en zonas de carga, etc. Esta reducción en el tiempo total del flujo está directamente relacionada con la utilización del modelo de compra como así también las automatizaciones redujeron el tiempo en el armado de reportes.

Cabe aclarar que el modelo está funcionando de manera parcial en la operatoria diaria del Distribuidor. Esto se debe a que no se ha iniciado el proceso de implementación planteado anteriormente, ya que estamos esperando la fecha de inicio por parte del Distribuidor. Por

otro lado, cuando nos referimos a funcionamiento parcial queremos decir que el modelo no lo corre el Analista de Stock sino que se le envían los resultados parciales para algunos días de la semana (los días que realizan pedidos) y toman la cantidad resultante del modelo como guía para armar el pedido. Sin embargo, las automatizaciones realizadas dentro del proceso del armado de compra sí fueron implementadas con el objetivo de mejorar el flujo total.

A modo de conclusión, el problema abordado en este trabajo comprende una minúscula parte de la compleja operación a la que se enfrenta el Distribuidor día a día. Sin embargo, pequeños cambios como los que vimos en este trabajo pueden presentar grandes beneficios, ya que la escala y la cantidad de producto, clientes y red logística que maneja en este rubro es muy grande. Por ende, motivamos a trabajos e investigaciones futuras a proponer soluciones que tal vez puedan no ser muy revolucionarias, pero en esta industria las pequeñas mejoras hacen la diferencia. Principalmente, debido a cuestiones operacionales más que estratégicas.

# Referencias

- Viveros, E. R. y Salazar H. E. (2010). *Modelo de Planificación de Producción para un Sistema Multiproducto con Múltiples Líneas de Producción*. Revista Ingeniería de Sistemas. Volumen XXIV. 89-102.
- Veinott, A. (2001). *Lectures on supply-chain optimization*. Stanford University, Stanford, CA.
- Roushdy, B. (2014). Integer Programming Model for Inventory Optimization for a Multi Echelon System.
- Özer, Ö., & Wei, W. (2004). *Inventory Control with Limited Capacity and Advance Demand Information*. *Operations Research*, 52(6), 988–1000. <http://www.jstor.org/stable/30036647>.
- Tsao, Y.-C., Mangotra, D., Lu, J.-C., & Dong, M. (2012). *A continuous approximation approach for the integrated facility-inventory allocation problem*. *European Journal of Operational Research*, 222(2), 216–228. doi:10.1016/j.ejor.2012.04.033
- Minner, S. (2003). *Multiple-supplier inventory models in supply chain management: A review*. *International Journal of Production Economics*, 81-82, 265–279. doi:10.1016/s0925-5273(02)00288-8
- Juhász, J., & Bányai, T. (2018). *Last mile logistics: an integrated view*. IOP Conference Series: Materials Science and Engineering, 448, 012026. doi:10.1088/1757-899x/448/1/012026
- Giuffrida, N., Fajardo-Calderin, J., Masegosa, A. D., Werner, F., Steudter, M., & Pilla, F. (2022). *Optimization and Machine Learning Applied to Last-Mile Logistics: A Review*. *Sustainability*, 14(9), 5329. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/su14095329>
- Francis de Véricourt, Miguel Sousa Lobo, (2009). *Resource and Revenue Management in Nonprofit Operations*. *Operations Research* 57(5):1114-1128.
- Mokhtar, M. , Shuib, A. , Mohamad, D. (2014). *Mathematical Programming Models for Portfolio Optimization Problem: A Review*. World Academy of Science, Engineering and Technology, Open Science Index 86, International Journal of Mathematical and Computational Sciences, 8(2), 428 - 435.

- Ashvin Kochak and Suman Sharma (2015). *Demand Forecasting Using Neural Network for Supply Chain Management*, International Journal of Mechanical Engineering and Robotics Research, Vol. 4, No. 1, pp. 96-104.
- Carbonneau, R., Laframboise, K., & Vahidov, R. (2008). *Application of machine learning techniques for supply chain demand forecasting*. *European Journal of Operational Research*, 184(3), 1140–1154. doi:10.1016/j.ejor.2006.12.004
- Marc-Oliver Sonneberg, Max Leyerer, Agathe Kleinschmidt, Florian Knigge, Michael H. Breitner (2019). *Autonomous Unmanned Ground Vehicles for Urban Logistics: Optimization of Last Mile Delivery Operations*. In Tung Bui, editor, *52nd Hawaii International Conference on System Sciences, HICSS 2019, Grand Wailea, Maui, Hawaii, USA, January 8-11, 2019*. pages 1-10, ScholarSpace / AIS Electronic Library (AISeL).
- B. Meindl and M. Templ, “Analysis of commercial and free and open source solvers for linear optimization problems,” ESSnet commom tools Harmon. Methodol. SDC ESS, vol. 1, no. 1, pp. 1–14, 2012, [Online]. Available: <http://www.statistik.tuwien.ac.at/forschung/CS/CS-2012-1complete.pdf>
- Ehrental, J. C. F., Honhon, D., & Van Woensel, T. (2014). *Demand seasonality in retail inventory management*. *European Journal of Operational Research*, 238(2), 527–539. doi:10.1016/j.ejor.2014.03.030
- Dunford, R., Su, Q., & Tamang, E. (2014). *The pareto principle*.
- <https://web.archive.org/web/20120120095833/http://www.informs.org/About-INFORMS/About-Operations-Research>
- <https://www.cotizacion-dolar.com.ar/dolar-blue-historico-2022.php>

# Anexo A. Script Modelo de Compra

```
#####-CARGA DE DATOS-#####
```

```
# Conjunto de SKUs
```

```
set P := { read "skus.dat" as "<1s>" };
```

```
# Conjunto de depositos
```

```
set W := { read "depositos.dat" as "<1s>" };
```

```
# Conjunto de periodos
```

```
set T := { 1 };
```

```
# Stock inicial
```

```
param stockinicial[P*W] := read "stock_3-5.dat" as "n+";
```

```
# Demanda diaria
```

```
param demanda[P*W] := read "demanda_17-4 al 28-4.dat" as "n+";
```

```
# SKUs de litro
```

```
set Litro := { read "litro.dat" as "<1s>" };
```

```
# SKUs de lata
```

```
set Lata := { read "lata.dat" as "<1s>" };
```

```
# Cantidad de bultos por pallet
```

```
param bxp[P] := read "bultos_x_pallet.dat" as "<1s> 2n";
```

```
# Cantidad de días de venta
```

```
param alpha := 5;
```

```
#####-VARIABLES-#####
```

```
# Variables
```

```
var x[P*W*T] >= 0; # Compra diaria
```

```
var s[P*W*(T union {0})] >= 0; # Stock
```

```
var p[P*W*T] integer; # Pallets
```

```
var w[P*W*T] >=0; #Stock de seg incumplido
```

```
#####-FUNCION OBJETIVO-#####
```

```
# Funcion objetivo
```

```
minimize fobj: sum <i,j,t> in P*W*T: w[i,j,t];
```

```
#####-RESTRICCIONES-#####
```

```
# Compra
```

```
subto compra: forall <i,j,t> in P*W*T:
```

```
    x[i,j,t] == bxp[i]*p[i,j,t];
```

```
# Stock
```

```
subto stock: forall <i,j,t> in P*W*T:
```

```
    s[i,j,t] == s[i,j,t-1] + x[i,j,t] - demanda[i,j];
```

```
# Stock inicial
```

```
subto inicial: forall <i,j> in P*W:
```

```
    s[i,j,0] == stockinicial[i,j];
```

```
# 5 dias de stock minimo en cada deposito
```

```
subto stockrestante: forall <i,j,t> in P*W*T:
```

```
    s[i,j,t] + w[i,j,t] >= alpha * demanda[i,j];
```

# Maximo compra de 1300 bultos para SKUs litro

subto maxlitro: forall <j,t> in W\*T:

sum <i> in (Litro inter P):  $x[i,j,t] \leq 1300$ ;

# Maximo compra de 2400 bultos para SKUs lata

subto maxlata: forall <j,t> in W\*T:

sum <i> in (Lata inter P):  $x[i,j,t] \leq 2400$ ;