



**“Pronóstico de demanda en retail:  
la importancia del planificador”**

**Autor: Sebastián Bauer**

**Tutor: Pablo Roccagliata**

**Escuela de Negocios – MBA**

**Abril 2020**

## **Agradecimientos**

Quiero agradecer en este trabajo al importante apoyo brindado durante todo este último tiempo a mi familia y especialmente a mi novia por alentarme en mi desarrollo profesional.

A mi empresa que me dio la posibilidad de continuar formándome y a mis compañeros del intensivo por el valioso aporte en el intercambio realizado tanto dentro como fuera del aula.

Por último, a la universidad por estar siempre cerca de nuestra formación.

## Resumen Ejecutivo

El siguiente trabajo de investigación presenta las diferentes formas con las que se puede pronosticar la demanda y los modelos en los cuales es posible apoyarse para ello, basando la tesis en una empresa muy importante dentro del país del sector *retail*.

En una primera instancia, se analizará la importancia de pronosticar y las consideraciones a tener en cuenta a la hora de construir un pronóstico para luego ahondar en los distintos modelos disponibles con los que se cuentan y una breve aplicación cuantitativa que fundamenta su uso.

En el desarrollo de la tesis también se podrá observar un análisis de distintos proveedores de software enlatado para la implementación de una solución que permita ayudar a gestionar inventarios y pronosticar demanda de forma óptima. También se presentarán los criterios utilizados por la empresa en cuestión a la hora de tomar una decisión sobre la elección sobre uno de ellos.

Por último, se describirá en la parte final una breve visión de cómo reaccionar ante sucesos imprevistos que alteren considerablemente la demanda, analizando específicamente el efecto del COVID-19 y su afectación en la demanda para la empresa objeto de estudio.

## Palabras clave

Pronóstico de demanda, supply chain, forecast, comercial planning.

## Índice

<b>CAPÍTULO I: IMPORTANCIA DEL PRONÓSTICO .....</b>	<b>5</b>
Entendiendo su importancia .....	5
Gestión de inventarios como base .....	5
Herramientas de pronóstico.....	6
La importancia de los juicios en los pronósticos .....	6
<b>CAPÍTULO II: CÓMO CONSTRUIR UN PRONÓSTICO.....</b>	<b>8</b>
Principios para la previsión de demanda.....	8
Previsión de nuevos artículos.....	10
Fundamentos para construir modelos .....	11
Categorías de Modelos.....	12
Demanda no observada .....	19
<b>CAPITULO III: INVESTIGACIÓN EMPÍRICA .....</b>	<b>21</b>
Situación actual – Presentación Empresa JJ .....	21
Análisis cuantitativo de aplicación de modelos.....	21
<b>CAPÍTULO IV: SOLUCIONES PARA PRONOSTICAR DEMANDA .....</b>	<b>28</b>
Gestionando inventarios con hojas de cálculo .....	28
Soluciones efectivas .....	29
Principales <i>vendors</i> de soluciones .....	30
Análisis de implementación en caso estudio.....	33
<b>Bibliografía.....</b>	<b>41</b>



## Introducción

Los cambios que suceden hoy en día como consecuencia de factores económicos, políticos o modas, entre otros, afectan frecuentemente el comportamiento de los consumidores lo cual repercute en la estimación de inventarios para hacer frente a las ventas. Este difícil problema hace que comience a tomar importancia en las organizaciones el rol del planificador de demanda. Para ello, se pueden crear mediante distintos modelos estadísticos distintas fórmulas o pronósticos sobre la demanda o utilizar softwares que ya tienen cargados distintos modelos. Estos softwares pueden ser públicos, es decir, de código abierto, donde la comunidad se encarga de actualizar y mejorar los mismos, o propietario, en los cuales las empresas ofrecen enlatados donde en general no se conoce el detalle de las implementaciones.

En el presente trabajo se investigará acerca de cómo estimar la demanda, la información necesaria para realizarlo y si es beneficioso utilizar modelos estadísticos para pronosticar la demanda o es preferible hacerlo de forma rudimentaria. En el caso de elegir un software empaquetado para que nos ayude con la optimización del pronóstico, también se analizará cómo definir criterios para evaluarlo.

## Objetivos generales

El objetivo principal es optimizar el cálculo del pronóstico de demanda facilitando la obtención de mejores resultados que contribuyan a una óptima gestión de inventarios y por ende a mejorar los resultados de negocio.

## Objetivos específicos

Dentro de los objetivos más específicos del presente trabajo se encuentran:

- Conocer los distintos modelos estadísticos para elegir el de mejor aplicación en cada caso particular.
- Tener en cuenta qué criterios se deberán considerar a la hora de implementar una solución para el pronóstico de demanda.
- Cómo reaccionar ante cambios inesperados de la demanda.

## Metodología

El tipo de investigación realizado fue descriptivo. En el presente trabajo se describirán los distintos modelos existentes para el pronóstico, así como también las distintas soluciones que pueden implementar las empresas en la búsqueda de mejorar su gestión de inventarios.

Se investigó durante el trabajo acerca de las claves a tener en cuenta a la hora de hacer un *forecast* basado en información histórica y de qué forma complementarlo con el juicio de expertos.

---

## CAPÍTULO I: IMPORTANCIA DEL PRONÓSTICO

### Entendiendo su importancia

La determinación de la demanda potencial a la que se enfrentará la empresa es un dato estratégico clave, no solo a la hora de abastecer nuestras tiendas, sino que también a la hora de negociar con los proveedores. Generalmente éstos ofrecen descuentos o bonificaciones por niveles de compra. Algunas veces los objetivos son fijos, otros son estratificados por niveles de compra y otras veces por *sell out*. Esto hace que la decisión de compra no solo afecte los niveles de stock sino los resultados financieros de la compañía. En algunas ocasiones, el desafío de querer llegar a una mayor bonificación o reintegros del proveedor por niveles de compra hace perder de vista el stock necesario para satisfacer la demanda y no generar *sobrestocks* de dicho producto. Este *sobrestock* genera a su vez un impacto en un renglón del estado de resultados afectando las pérdidas, conocido como obsolescencia de mercadería. Ante esta situación, resulta fundamental realizar un análisis de pronóstico de demanda para alinearse y obtener mejores negociaciones con los proveedores de forma de maximizar las ganancias financieras y alcanzar niveles óptimos de stock que mejoren los resultados generales de la compañía.

### Gestión de inventarios como base

La gestión de los inventarios es un punto importante en las empresas dado el peso que tiene la mercadería y el costo que implica tenerla inmovilizada. El análisis de la demanda para tener un pronóstico certero no solo es importante para cumplir con el cliente, sino que tener excesos de stock termina generando problemas de vencimientos, roturas y obsolescencia lo cual termina repercutiendo en mermas para la compañía. A su vez, un stock por debajo de la demanda real genera quiebres y pérdidas de oportunidad de ventas no solo del artículo en cuestión sino también de otros ya que esto puede provocar la pérdida del cliente.

Previo a comenzar a definir los niveles de stock a mantener es imperioso conocer cuál es la política de la empresa en materia de inventarios y, en caso de que no estuviera definida, trabajar en ese punto. Si bien en cada rubro las empresas tienen comportamientos similares en cuanto a los días de inventario a mantener en stock, cada empresa puede determinar un valor aceptado sobre los que quiere trabajar. Existen empresas más conservadoras que

prefieren permanecer por encima de la media ya que les genera tranquilidad, mientras que otras especulan con los días necesarios para cubrir el *lead time*. Cualquiera sea la política establecida será esta la referencia para la toma de decisiones.

## Herramientas de pronóstico

Dada la importancia antes mencionada con respecto a estimar adecuadamente la demanda resulta clave elegir el mejor método estadístico teniendo en cuenta sus supuestos y error implícito que proporcione los mejores resultados.

Hoy en día existen distintos softwares que realizan esta combinación de modelos permitiéndole al usuario ingresar determinados datos a través de los cuales se calculan los modelos y estimaciones. Muchos, a su vez, cuentan con una opción de simulación para el caso de querer modificar distintos parámetros como, por ejemplo, el nivel de servicio, stock de seguridad, etc. para un artículo o grupo de artículos y analizar sus posibles impactos. Esto siempre se realiza luego de aplicados los modelos o volviendo a aplicarlos con los nuevos datos ingresados. Luego se calculan intervalos de pronóstico para poder cuantificar la incertidumbre. Existen al menos 70 modelos diferentes entre lineales y no lineales para pronósticos cuantitativos. La literatura si bien compara y explica los distintos modelos, los hallazgos no sugieren para ciertas condiciones qué modelo es mejor que otro, sino que el consenso es usar ensambles, combinando distintos modelos y analizando para cada situación puntual qué modelos explican mejor el comportamiento.

Otro punto importante a aclarar es que si bien muchas veces se utilizan las ventas como proxy para estimar demanda estos conceptos son diferentes. La demanda corresponde a la intención de los consumidores sobre determinados bienes y servicios, mientras que la venta es el intercambio real que sucede con la transacción. Los quiebres de stock no permiten reflejar en las ventas la correlación de la demanda. Sucede algo parecido cuando los consumidores no encuentran el producto deseado y lo sustituyen por otro traccionando la de un artículo no demandado.

## La importancia de los juicios en los pronósticos

El juicio de los expertos es bastante utilizado y necesario en la práctica para entender qué es lo que está pasando. Podría ser el caso del lanzamiento de un nuevo producto, la entrada de un nuevo competidor o situaciones externas inéditas y, en estas cuestiones, quien mejor pueda adaptar el pronóstico a la realidad es quien más conoce del tema. De todos modos,

este juicio no deja de estar exento de sesgos y limitaciones por lo cual su uso exclusivo podría traer inconvenientes.

Algunos de los problemas que pueden desarrollar los juicios son que, al depender fundamentalmente del conocimiento humano, muchas veces se pondera con mayor importancia acontecimientos recientes, ignorando algunos más alejados en el tiempo. También, el efecto psicológico que tienen algunos factores en el comportamiento humano, y con ello, en las decisiones que se toman podría afectar el juicio de las personas. Por último, también es importante resaltar la influencia que tiene el anclaje sobre puntos de referencia ya conocidos en la predicción.

Para paliar estos efectos adversos del juicio personal se podrían tomar algunas consideraciones para ayudar a disminuir en alguna medida los sesgos mencionados:

- Fijar objetivos claros y concisos evitando ambigüedades.
- Implementar un enfoque sistémico utilizando por ejemplo una *checklist*.
- Documentar formalmente y justificar cada supuesto.
- Realizar evaluaciones sistemáticas del pronóstico obteniendo *feedback*.
- Separar usuarios de pronosticadores.

---

## CAPÍTULO II: CÓMO CONSTRUIR UN PRONÓSTICO

### Principios para la previsión de demanda

Pronosticar la demanda no es tarea sencilla ya que existen diversas variables que la afectan en simultáneo y, a su vez, las distintas áreas presentan necesidades contrapuestas. Por un lado, el departamento de Ventas reclama altos niveles de disponibilidad para satisfacer los pedidos, el departamento Financiero vela por reducir al mínimo los costos de inventarios y *Supply Chain* queda interpuesto en el medio bajo presión para equilibrar el nivel de servicio deseado y la inversión en stock. (SlimStock, 2018) A continuación, se analizarán algunos principios importantes a tener en cuenta a la hora de realizar las previsiones:

#### 1. Clasificar la demanda

Previo a aplicar las técnicas más apropiadas de previsión resulta de gran utilidad agrupar los artículos en función de sus características similares. Los productos nuevos, maduros, estacionales y aquellos que están finalizando su ciclo de vida deben ser tratados de manera diferente.

#### 2. Depurar los datos tanto como sea posible

El proceso de cálculo de la previsión en el *retail* tiene por naturaleza una gran cantidad de datos que vienen desde el punto de venta y es necesario limpiar los mismos previo a realizar los cálculos. Aquí resulta fundamental entender la procedencia y qué tipo de datos se están utilizando ya que es uno de los requisitos básicos de su alfabetización. Por un lado, existen los datos primarios que son los que se obtienen directamente del mundo real sobre los cuales se tiene el control de cómo se registraron y almacenaron. Estos registros se crean intencionalmente con un propósito analítico específico. Por otro lado, existen los llamados datos secundarios que son los heredados de otras personas. Los datos heredados pueden ser importantísimos para el análisis, pero una pesadilla para la inferencia estadística. La gestión, auditoría y depuración de la información resulta de vital importancia para evitar el cuestionamiento de los datos. La calidad de los datos es fundamental para una mejor toma de decisiones. Por eso, contar con datos heredados puede generar ruidos, interferencias y desconfianza en los resultados que harán que sea difícil volver atrás. Además, otras áreas del negocio podrían perder la confianza en los pronósticos lo cual supone una amenaza para el planificador. En caso de estar obligado a trabajar con la información proveniente de datos heredados, se debería hacer foco en los siguientes problemas:

- **Propósito:** si los datos se recolectaron con el mismo objetivo.
- **Aptitud:** si se confía en el equipo que se encargó de recolectar los datos.
- **Objetividad:** si los datos no están contaminados por los prejuicios y opiniones de sus autores.
- **Claridad:** si la documentación evita que se malinterprete el contenido de los datos.
- **Procesamiento:** si los datos se han procesado sin sufrir transformaciones o alteraciones ni estar afectados por sesgos.

### 3. Utilizar múltiples métodos de pronóstico

Esto contribuirá a ser más precisos y mejorar el trabajo. No es necesario crear algoritmos propios ya que los factores externos nunca son suficientemente predecibles con exactitud ni rapidez lo que enlentecería cada actualización del modelo.

### 4. Evitar reajustar todos los SKU de forma masiva y constante

No resulta efectivo ni eficiente realizar este tipo de proceso con la misma frecuencia. Puede resultar útil definir parámetros de control para identificar y procesar solo aquellos artículos que lo requieran.

### 5. Mantener un equilibrio entre el pronóstico de compra y el *budget*

Generalmente, en el *retail* trabajan por separado quienes realizan el *forecast* de estimación de demanda y las cantidades a adquirir de cada producto de quienes realizan los presupuestos financieros. Es fundamental fortalecer este vínculo para lograr los objetivos que se propone la compañía, de lo contrario, esas discordancias llevarán a brechas difíciles de explicar ante el directorio.

### 6. Aprender de los errores de predicción

Saber identificar las causas, factores y consecuencias que han provocado los errores es de gran ayuda, así como también conocer el impacto que tuvieron sobre otros indicadores del inventario como roturas de stock, quiebres, *sobrestock*, objetivos de venta y otros.

## Previsión de nuevos artículos

La responsabilidad de hacer previsiones de artículos nuevos en las empresas de *retail* recae sobre el comprador. Esta misma tarea depende normalmente de las áreas de Marketing o Ventas. No obstante, en la actualidad es cada vez más común observar que los departamentos de Logística o *Supply Chain* son los que toman las riendas de este proceso de negocio al ofrecer una visión objetiva, equilibrada y económicamente rentable para la organización.

El objetivo de que estos departamentos se encarguen de las previsiones está relacionado con satisfacer tanto el enfoque comercial como las exigencias financieras y operativas en el lanzamiento de artículos nuevos al mercado. Si bien la incertidumbre en lo que respecta a artículos nuevos es algo que existirá siempre, también es cierto que el proceso puede ser controlado y mejorado de forma continua, facilitando la identificación de factores relevantes para hacer las previsiones de la manera más eficiente posible.

A la hora de predecir el comportamiento de artículos nuevos es de utilidad tener en cuenta las siguientes consideraciones que pueden ayudar a mejorar el proceso:

- Establecer un método cualitativo para determinar los productos, centros y tiendas que muestran un comportamiento similar, con el objetivo de poder sentar las bases de unas buenas previsiones. El uso de analogías ponderadas es uno de los métodos más conocidos y fiables, y es una técnica que forma parte de las funciones estándar de los sistemas de gestión de la demanda.
- Definir una regla de mínimos para establecer las previsiones iniciales de artículos nuevos. Siempre es necesario partir de una cifra, la cual debería definirse por quien ha tomado la decisión de incluir el artículo como parte del surtido. Sin embargo, es una buena práctica y cada vez más frecuente, que otros departamentos intervengan en ello aportando experiencia, estadísticas y visibilidad. La información del proveedor también se debe tener en cuenta.
- Establecer una clasificación estándar para identificar rápidamente cuáles son los artículos nuevos dentro de la estructura del surtido. Esto es crucial para poder anticiparse y reaccionar a cambios en la demanda, así como para definir la estrategia de inventarios en cada etapa del ciclo de vida.

- Calcular las ventas medias lo más rápido posible. Por ejemplo, en el caso de los artículos de moda es muy importante identificar los patrones, por lo que contar con información al día resulta de gran importancia para predecir las ventas futuras.
- Reflexionar, mejorar y volver a reflexionar. El proceso de gestión de artículos nuevos es altamente dinámico y exige cambios constantes. Aquello que se lleva a cabo en un momento determinado puede no ser adecuado para el próximo año, por lo que es importante mantener la mente abierta a nuevas formas de actuar.

## Fundamentos para construir modelos

Como se ha observado en el presente trabajo, los pronósticos de demanda se utilizan para predecir de antemano el comportamiento de la misma a los efectos de una mejor planificación, tanto con proveedores externos como internos, así como también la mayor satisfacción del cliente final. Pueden basarse en modelos matemáticos, cuantitativos, o bien aprovechar la experiencia administrativa, el juicio de los clientes o ambas.

El armado de los pronósticos requiere seguir algunos pasos fundamentales para su construcción los cuales se detallan a continuación:

- **Definir el problema:**

Generalmente es la parte más difícil del pronóstico. Requiere detallar cuidadosamente la forma en que será utilizado, comprender para qué lo necesita la empresa y alinearlos estratégicamente con las necesidades de la compañía.

- **Recolección de datos:**

Aquí resulta de igual importancia tanto los datos estadísticos, como la experiencia acumulada de quienes recogen los mismos y utilizan el *forecast*. Normalmente es difícil obtener datos históricos suficientes para aplicar un buen modelo estadístico.

- **Análisis preliminar:**

Lo que se busca en este paso es detectar patrones consistentes, tendencias, la existencia de ciclos de negocio y valores excepcionales. También se analizan las relaciones entre las distintas variables.

- **Selección del modelo más adecuado:**

La elección del modelo que mejor se adapte al pronóstico a realizar dependerá, en cada caso, de la disponibilidad de información histórica, la correlación entre las variables a pronosticar y otras variables explicativas, y la forma en la que se utilizarán en el modelo. Generalmente, se realiza una comparación de dos o tres modelos a los efectos de tener un mejor resultado.

- **Utilización y evaluación del modelo de pronóstico:**

Una vez seleccionado el modelo, se debe analizar los resultados brindados por el mismo comparándolo con los datos observados en la realidad. De esta forma, se podrá estudiar el error que tiene el modelo y ajustarlo si fuera necesario.

## Categorías de Modelos

Existen dos grandes categorías de modelos de acuerdo con los datos obtenidos para la realización del pronóstico: cualitativos y cuantitativos. De todas formas, se puede combinar la utilización de modelos para reforzar o validar los resultados obtenidos por los mismos.

### **Modelos cualitativos:**

En los modelos cualitativos se utilizan como insumo ciertos patrones y modelos estadísticos que ayudan a entender el comportamiento pasado y a predecir el comportamiento futuro. Se utilizan cuando no se tienen datos históricos precisos y se recurre a estimaciones y opiniones. Dentro de los mismos se encuentran:

- **Método Delphi:** parte de la premisa de que la opinión de un grupo de personas es más acertada que la de una sola. Busca construir consensos a partir de las distintas opiniones de expertos iterando las mismas de forma estructurada. Generalmente, se realiza en grupos de entre 5 y 20 personas contando con un facilitador que lleva a cabo el proceso.
- **Pronóstico por analogía:** en este caso lo que se busca es predecir el comportamiento futuro de acuerdo con el juicio de expertos en función del comportamiento de variables similares y datos históricos en circunstancias similares.

- **Pronósticos de escenarios:** lo que se busca en este método es realizar distintos escenarios en base al impacto que puedan tener distintas variables en los objetivos, así como también la relación y efecto que pueden tener entre ellas. Este método brinda distintas posibilidades como, por ejemplo, un escenario “optimista”, otro “pesimista” y uno “neutro” que permita tomar una mejor decisión. Una de sus ventajas con respecto a los anteriores es que permite entender de forma más clara los resultados; sin embargo, no deja de estar afectado por algunos sesgos.
- **Investigación de mercado:** se buscan datos de distintas maneras para probar una hipótesis sobre el mercado.
- **Información de redes de ventas**
- **Información de gerencia comercial y marketing**

### **Modelos cuantitativos:**

Se utilizan cuando se cuenta con datos históricos sobre la variable a pronosticar. La información puede cuantificarse y se podría suponer que el patrón del pasado seguirá ocurriendo en el futuro.

Los métodos cuantitativos se pueden clasificar en relaciones causales y basados en series de tiempo.

Aquellos que utilizan relaciones causales incorporan los factores o variables que pueden influir en la cantidad a pronosticar. Dentro de estos modelos se encuentra la regresión lineal que es una técnica estadística utilizada para estudiar la relación entre dos variables, lo que permite el cálculo para períodos futuros a través de datos históricos que sean confiables, consistentes y precisos. El objetivo es obtener el total de las desviaciones elevadas al cuadrado a un valor mínimo.

Las distintas observaciones repetidas de una demanda forman un patrón que se conoce como serie de tiempo. Dentro de los principales componentes de la serie de tiempo se encuentran: la *aleatoriedad* donde los datos de la demanda tienen variaciones imprevisibles, la *estacionalidad* que refiere a picos o valles en momentos repetitivos asociados a épocas concretas, el *ciclo* cuando existen incrementos o decrementos en períodos más largos de tiempo, la *tendencia* cuando la serie aumenta o disminuye

sistemáticamente a lo largo del tiempo y la *horizontalidad* cuando los datos se comportan como una media constante.

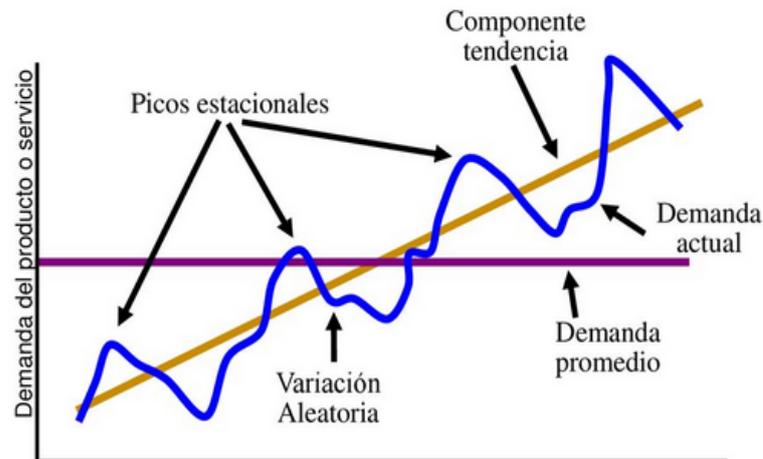


Gráfico 1: Gráfico de series temporales (Murillo Bustamante, 2019)

A continuación, se describen algunos de los principales modelos cuantitativos de series de tiempo en los que se profundizará más adelante:

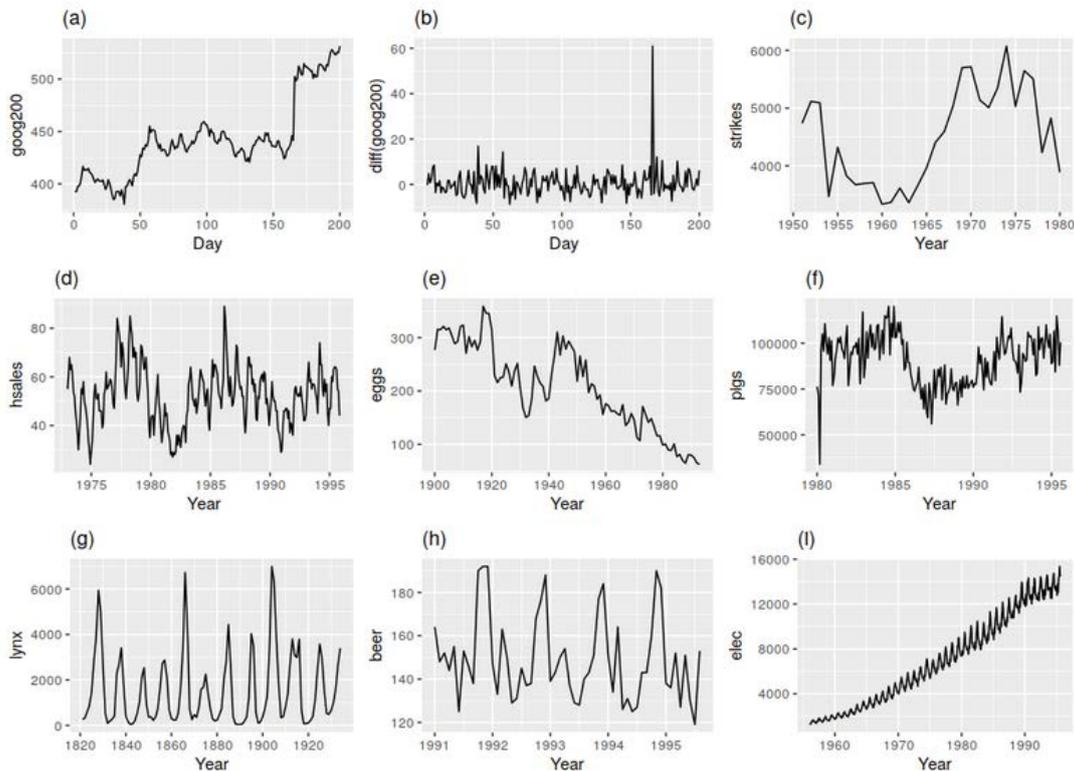
- Modelos regresivos de series de tiempo.
- Modelos basados en promedios móviles.
- Modelo de suavización exponencial.
- Modelo Hot-Winters.
- Modelo Box-Jenkins (ARIMA).

Una serie temporal estacionaria es aquella cuyas propiedades no dependen del momento en que se observa la serie. Por lo tanto, las series con tendencia o estacionalidad no son estacionarias. La tendencia y la estacionalidad afectan el valor de la serie en momentos diferentes. Una serie de ruido blanco es estacionaria, independientemente de cuándo se observe, ya que debería verse muy similar en cualquier momento. ( Athanasopoulos & Hyndman, 2nd edition, May 2018)

Algunos casos pueden resultar confusos, por ejemplo, una serie de tiempo con comportamiento cíclico pero sin tendencia ni estacionalidad, es estacionaria. Esto se debe a que los cíclicos no tienen una longitud fija, por lo tanto, no se podría tener certeza de dónde estarán los picos y valles de los ciclos antes de observar la serie.

Una serie de tiempo estacionaria no tendrá patrones predecibles a largo plazo y los gráficos se verán relativamente horizontales con una variación constante.

En la Gráfica 2 se aprecia el componente de estacionalidad en (d), (h) e (i). En (a), (c), (e), (f) e (i) se observan tendencias y niveles cambiantes de la serie, mientras que (b) y (g) son las únicas series estacionarias.



Gráfica 2: Ejemplos de series de tiempo ( Athanasopoulos & Hyndman, 2nd edition, May 2018)

En el Gráfico (a) se representa la evolución de la cotización de las acciones de Google en un período de tiempo determinado. Como se expone anteriormente, dicha serie no es estacionaria. Sin embargo, el Gráfico (b) muestra la evolución de las variaciones diarias de las cotizaciones de esa acción. En este caso se puede apreciar cómo es posible transformar una serie de tiempo no estacionaria en estacionaria. A esto se lo conoce como diferenciación.

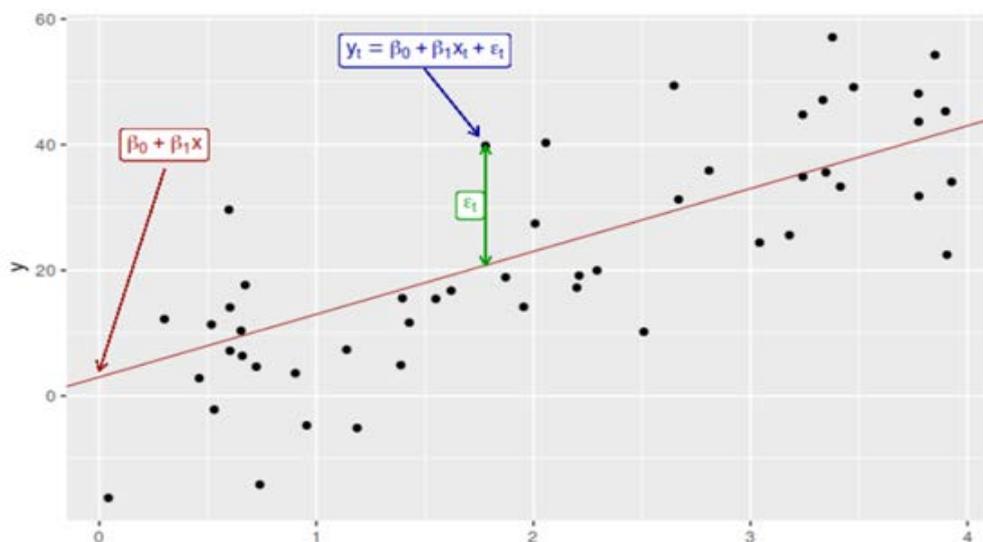
### **Modelos regresivos de series de tiempo:**

Estos modelos asumen que existe una relación lineal entre la variable de serie de tiempo a pronosticar, llamada variable explicada o regresiva "y" otras variables de series de tiempo también conocidas como regresores, predictoras o explicativas "x".

- **Regresión lineal simple:**

Es el más simple de estos modelos donde la variable a pronosticar tiene una única variable explicativa. Cuenta con los coeficientes  $\beta_0$  y  $\beta_1$  que representan la intersección y la pendiente de la curva respectivamente. A su vez, las observaciones de la gráfica cuentan con desviaciones respecto a la curva de regresión a los cuales se les llama “error” y se representa con  $\varepsilon_t$  como se observa en la Gráfica 3 a continuación. ( Athanasopoulos & Hyndman, 2nd edition, May 2018)

$$y_t = \beta_0 + \beta_1 x_t + \varepsilon_t.$$



Gráfica 3: Modelo de regresión simple ( Athanasopoulos & Hyndman, 2nd edition, May 2018)

- **Regresión lineal múltiple:**

Este modelo aplica cuando se cuenta con dos o más variables explicativas siendo su fórmula la siguiente donde  $x_k$  son la cantidad de variables predictoras.

$$y_t = \beta_0 + \beta_1 x_{1,t} + \beta_2 x_{2,t} + \dots + \beta_k x_{k,t} + \varepsilon_t$$

En la ecuación anterior se parte de los supuestos de que el modelo tiene una aproximación razonable a la realidad y que los errores tienen media cero, ya que de lo contrario, se vería afectado por sesgos. Tampoco están autocorrelacionadas, lo que implica pronósticos ineficientes por no explotar todos los datos de forma correcta. Por último, los errores tampoco están relacionados con las variables predictoras, por lo que se debe incluir la información en la parte sistémica del modelo.

- **Estimación de mínimos cuadrados:**

Este modelo busca obtener el valor de los coeficientes  $\beta$  que en la realidad no se pueden obtener a través de los datos, sino que deben estimarse. Para ello, se busca minimizar los errores a través de la suma de los errores al cuadrado.

$$\sum_{t=1}^T \varepsilon_t^2 = \sum_{t=1}^T (y_t - \beta_0 - \beta_1 x_{1,t} - \beta_2 x_{2,t} - \dots - \beta_k x_{k,t})^2.$$

### Modelos basados en promedios de medias móviles:

Previo a la utilización de estos modelos es importante determinar la tendencia y ciclo de la serie. Se pueden utilizar promedios de medias móviles, simples y ponderadas.

- **Promedios simples:**

Es el promedio de las observaciones para una serie de tiempo de  $k$  periodos. Se utiliza normalmente cuando la serie no presenta tendencia ni estacionalidad.

- **Promedio suavizado:**

Este caso toma el promedio de los últimos “ $m$ ” períodos de la serie y los computa al final del último período del intervalo promediado y así sucesivamente. Este método se encarga de reducir el efecto de la tendencia de ciclos achatando el efecto. Por ejemplo, para una serie de tiempo que transcurre desde 1990 al 2020, con  $m=3$ ; en el año 1993 computará el promedio de las observaciones de 1990 a 1993. Para el año 1994, se tendrá en cuenta el promedio de la serie entre 1991 y 1994.

$$\hat{T}_t = \frac{1}{m} \sum_{j=-k}^k y_{t+j},$$

- **Promedio ponderado:**

Aquí se les asigna distinto peso a los distintos períodos de las observaciones de la serie de tiempo.

---

### **Modelos de suavización exponencial:**

Este método entiende que cuanto más antiguas sean las observaciones, de menor manera se verán afectados los resultados más recientes, por lo que se les asigna una ponderación mayor a los últimos periodos de la serie de tiempo.

- **Suavizado exponencial simple:**

Este método se adapta de mejor manera cuando no existe un patrón claro de estacionalidad y tendencia. Los principales métodos son los siguientes:

- **Método Naïve:** asume que la última observación es la única importante y que el resto no aporta información relevante por lo que le proporciona todo el peso a la última observación.
- **Método parámetro ponderado:** este método consiste en definir la importancia que tiene la última observación con un parámetro  $\alpha$ , ubicado entre 0 y 1, aplicando al resto una distribución exponencial de  $1 - \alpha$ .

### **Modelos Holt Winters:**

Este modelo es una extensión del modelo lineal de Holt en el que este último desarrolló un método que toma en cuenta la evolución local lineal de las tendencias de una serie de tiempo y utiliza dos constantes de aislamiento. Determina mediante una ecuación la previsión del nivel de la serie y mediante otra la previsión de tendencia.

Es importante controlar las desviaciones entre los valores reales y los obtenidos en las predicciones para estar alerta cuando el modelo deja de ser representativo de la situación real. Una forma de medir si el pronóstico se ajusta a los cambios observados es el método de rastreo calculado como el cociente de la suma de errores del pronóstico y la desviación absoluta media. Una buena señal de rastreo tiene bajos valores tendiendo a cero.

Winters le agrega al modelo anterior una mejor representación de los datos y una reducción del error tomando una ecuación adicional que contempla la estacionalidad. A este modelo también se lo conoce como modelo de suavización exponencial estacional. ( Athanasopoulos & Hyndman, 2nd edition, May 2018)

---

### **Modelo Box-Jenkins (ARIMA):**

Los modelos ARIMA, también conocidos como modelos autorregresivos integrados de medias móviles, proporcionan otro enfoque para el pronóstico de series de tiempo. Este modelo, junto con el suavizado exponencial, son los dos enfoques más utilizados para el pronóstico de series de tiempo y proporcionan enfoques complementarios al problema. Mientras que los modelos de suavizado exponencial se basan en una descripción de la tendencia y la estacionalidad de los datos, los modelos ARIMA tienen como objetivo describir las autocorrelaciones en los datos. ( Athanasopoulos & Hyndman, 2nd edition, May 2018)

Se utiliza cuando las series de tiempo tienen un comportamiento volátil y se necesitan modelos más sofisticados.

El término AR refiere a modelos autorregresivos y pronostica la variable de interés utilizando una combinación lineal de los valores pasados de esa variable. Es una regresión de la variable contra sí misma.

Los modelos autorregresivos son notablemente flexibles para manejar una amplia gama de patrones de series de tiempo diferentes.

Un modelo autorregresivo de orden p tiene la siguiente ecuación:

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t,$$

El término MA (medias móviles) además de usar los valores anteriores de la variable a pronosticar en una regresión también incluye los errores de pronósticos anteriores en un modelo similar a la regresión.

Un modelo de medias móviles de orden q tiene la siguiente ecuación:

$$y_t = c + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q},$$

### **Demanda no observada**

Como se explica anteriormente, demanda no es igual a venta y, en casos de quiebre de stock, muchas veces se pierde de vista cuánto es la demanda no observada.

En un interesante trabajo de investigación realizado por Aditya, Nils y Tong acerca de la demanda no observada, los autores plantean tener en cuenta tres tipos de observaciones. La primera, respectiva a las ventas con una variable binaria de quiebres, la segunda, con el tiempo de ocurrencia de ventas y quiebres y, la tercera y última, la demanda completa, utilizada como *benchmark* también en algunas ocasiones.

En el trabajo se demuestra cómo el simple hecho de observar los casos de quiebre de stock versus la demanda completa genera la ejecución de mejores lotes óptimos de compra. A su vez, el uso del tiempo de ocurrencia permite reducir un 76,1 % de pérdida en los resultados esperados de acuerdo con su extenso estudio numérico el cual no es el foco de este estudio.

En la misma investigación logran demostrar que para una distribución Poisson y normal de la demanda con media desconocida el método utilizado es manejable y atractivo. La información contenida en el momento en que se realizan las ventas captura el tiempo de desabastecimiento como único *output*, donde los autores utilizan puntos de control realizando observaciones únicamente en momentos predeterminados en un período que integra su convergencia con los modelos de observaciones de eventos de tiempo y quiebres de stock. (Aditya, Nils, & Tong , Febrero 2015)

Para este caso puntual del objeto de análisis de este trabajo, se pudo determinar que para los artículos seleccionados aleatoriamente dentro de un criterio ABC, los mismos nunca quedan en niveles menores de stock promedio de una unidad por sucursal. Dado este dato, se asumió como demanda observable la venta efectiva. Para reforzar este punto, los niveles de stock promedio son mayores a dos veces la venta diaria.

## CAPÍTULO III: INVESTIGACIÓN EMPÍRICA

### Situación actual – Presentación Empresa JJ

La investigación se centrará en la empresa denominada por cuestiones de confidencialidad (a partir de ahora) JJ, ubicada en el sector *retail*, la cual comercializa productos que incluyen desde medicamentos hasta cosmética y cuidado personal. La empresa cuenta con 100 tiendas de venta minoristas, un centro de distribución y un *e-commerce*.

Para este trabajo, se tomó en cuenta una selección de artículos “A” utilizando la metodología ABC. La misma consiste en dividir en tres el inventario aplicando el principio de Pareto según el cual el 80 % de la venta se concentra en el 20 % de los artículos de inventario en este caso. Sobre los artículos seleccionados, se analizó el impacto que tiene en la organización contar con un modelo para planificar la demanda, si el mismo brinda información de calidad y si su costo es menor a los beneficios obtenidos.

JJ no cuenta con una política de inventarios definida y si bien desea tener días de stock acordes al sector, no existe una directriz establecida formalmente.

Hoy en día, se encuentra en plena etapa de decisión sobre la instalación de un planificador de demanda. Hasta el momento, se utiliza una fórmula de pedido automático desarrollado en el ERP para abastecer a las tiendas bajo la responsabilidad de logística y distribución, mientras que el departamento comercial se encarga del centro de distribución cruzando con información de ventas y niveles de stock.

Esto trae como problemas una falta de sinergia entre ambos sectores distando de ser óptimos los niveles de stock, lo cual lleva generalmente a *sobrestockear* por temor a quiebres.

### Análisis cuantitativo de aplicación de modelos

Para el caso de la empresa JJ, se trabajó con la simplificación del stock total dado que se asumió no tener limitaciones ni impedimentos para la movilidad de la mercadería entre tiendas cercanas y costos bajos o casi nulos de movilidad de producto entre las mismas.

A su vez, resulta necesario definir una jerarquía dentro del problema. Por lo tanto, primero se deberá predecir la demanda a nivel agregado para luego analizar cómo se distribuye la

misma entre cada una de las sucursales (100 puntos de venta). Predecir la demanda a nivel de sucursal tiene a su vez la dificultad que cada una tiene distintos comportamientos como puede ser, por ejemplo, un evento deportivo *random* o la instalación de una feria temporal que traccione mayor cantidad de personas. En este caso, se enfocará la investigación en predecir la demanda de los tres artículos más importantes (de acuerdo con la facturación) todas juntas en lugar de hacerlo con tres modelos separados. El comportamiento de estos tres SKU es representativo del total de artículos "A". Estos últimos se componen de 2.800 SKU de un total de 14.000 SKU activos tomando todos los artículos (ABC). La muestra representa un 2 % de las ventas totales.

En este punto se detallará el análisis realizado para determinar la conveniencia o no de aplicar un modelo de pronóstico descrito en los capítulos anteriores.

Se realizará un pronóstico de forma manual teniendo en cuenta los datos de la serie de tiempo actual que se presentan a continuación:

Mes	2017	2018	2019	2020
Enero	8.525	7.898	7.311	??
Febrero	8.189	7.312	6.665	??
Marzo	8.769	8.095	7.219	
Abril	8.710	7.899	6.955	
Mayo	8.311	7.856	??	
Junio	8.167	7.701	??	
Julio	8.418	7.749	??	
Agosto	7.981	7.720	??	
Setiembre	7.980	7.428	??	
Octubre	8.304	7.513	??	
Noviembre	7.706	7.389	??	
Diciembre	8.397	7.670	??	
<b>Total Anual</b>	<b>99.457</b>	<b>92.230</b>		
<b>Total Ene-Abril</b>	<b>34.193</b>	<b>31.204</b>	<b>28.150</b>	

Tabla 1: Serie temporal de ventas mensuales de JJ para el análisis

Como se puede observar en la Tabla 1, los campos con los "??" son el objetivo a pronosticar utilizando los datos que se encuentran en la serie anterior para luego validarlos con las ventas observadas en esos meses y estudiar qué tan bien se ajustan los modelos estadísticos y manuales.

Existen infinitas formas de pronosticar las ventas de forma manual. Podría tomarse por ejemplo la intuición o asumirse un comportamiento similar al del año anterior, entre otros. Para el siguiente *forecast*, el primer supuesto elegido consistió en asumir que el valor del

mes a pronosticar será igual al del mismo mes del año anterior agregándole cierta variación definida intuitivamente.

A continuación, en la Tabla 2 se encuentra el análisis de las variaciones reales (en amarillo) y las supuestas en este escenario (gris):

Mes	Var 18/17	Var 19/18	Var 19/18
Enero	-7,4%	-7,4%	-5,6%
Febrero	-10,7%	-8,8%	-6,6%
Marzo	-7,7%	-10,8%	
Abril	-9,3%	-12,0%	
Mayo	-5,5%	-4,1%	
Junio	-5,7%	-4,3%	
Julio	-7,9%	-6,0%	
Agosto	-3,3%	-2,5%	
Setiembre	-6,9%	-5,2%	
Octubre	-9,5%	-7,1%	
Noviembre	-4,1%	-3,1%	
Diciembre	-8,7%	-6,5%	
<b>Total Anual</b>	<b>-7,3%</b>	<b>-5,4%</b>	
<b>Total Ene-Abril</b>	<b>-8,7%</b>	<b>-9,8%</b>	

*Tabla 2: Variaciones porcentuales de ventas*

Tomando en cuenta esta supuesta variación, se le aplicó a las ventas de cada mes del año anterior, el porcentaje de variación de la Tabla 2 y se lo comparó con las ventas reales observadas. Como segundo punto se agregó un nuevo supuesto con el que se trabajará en todo el análisis que es el costo de quiebre de stock y el costo de mantener excesos. Para ello, se tomó como costo de quiebre el margen perdido por no realizar la venta, mientras que el costo de mantener inventario se definió como el costo de adquisición del mismo.

<b>Costo Quiebre</b>	350
<b>Costo Exceso</b>	250

Los siguientes fueron los resultados obtenidos de este primer experimento teniendo en cuenta que las diferencias entre el pronóstico y la realidad se multiplicaron por los respectivos costos:

Mes	Pronóstico	Ventas Reles	Diferencia	Costo
May-19	7.533	6.877	-656	229.751
Jun-19	7.371	6.632	-739	258.805
Jul-19	7.287	6.723	-564	197.444
Ago-19	7.531	6.875	-656	229.478
set-19	7.043	6.471	-572	200.073
Oct-19	6.976	6.644	-332	116.291
Nov-19	7.161	6.217	-944	330.411
Dic-19	7.172	6.566	-606	212.085
Ene-20	6.903	6.346	-557	195.115
Feb-20	6.223	5.745	-478	167.191
<b>Total</b>	<b>71.201</b>	<b>65.096</b>	<b>-6.105</b>	<b>2.136.643</b>

*Tabla 3: Resultados obtenidos mediante pronóstico manual*

Este resultado representa un costo de error en el pronóstico de \$ 2.136.643 de pérdida.

Ahora bien, si se buscara simplificar mucho más aún la predicción manual, se podría suponer que el resto de los meses por delante tendrían el mismo comportamiento que el acumulado de los cuatro primeros meses de 2019, es decir, una disminución del 9,8 %. En la Tabla 4 a continuación se observan los resultados obtenidos.

Mes	Pronóstico	Ventas Reles	Diferencia	Costo
May-19	7.087	6.877	-210	73.541
Jun-19	6.947	6.632	-315	110.351
Jul-19	6.991	6.723	-268	93.656
Ago-19	6.964	6.875	-89	31.300
set-19	6.701	6.471	-230	80.502
Oct-19	6.778	6.644	-134	46.791
Nov-19	6.666	6.217	-449	157.088
Dic-19	6.919	6.566	-353	123.662
Ene-20	6.595	6.346	-249	87.310
Feb-20	6.013	5.745	-268	93.689
<b>Total</b>	<b>67.661</b>	<b>65.096</b>	<b>-2.565</b>	<b>897.890</b>

*Tabla 4: Resultados obtenidos mediante segundo pronóstico manual*

En este caso, el costo del error en la predicción disminuye sensiblemente respecto al caso anterior, pero de todos modos, no existe un fundamento sólido para esto más que supuestos intuitivos de acuerdo con los datos existentes.

En el siguiente apartado se realizará la misma predicción, pero con alguno de los modelos predictivos vistos anteriormente. Para ello, se utilizará el software *grtl* el cual es gratuito y permite realizar predicciones utilizando distintos modelos de modo tal de poder elegir aquel que se ajuste mejor a los datos en cuanto a la performance predictiva *out of sample*.

La siguiente imagen muestra los resultados obtenidos luego de aplicar varios modelos estadísticos y seleccionar aquel que mejor explique el comportamiento de la variable o variables a estimar, que en este caso fue el ARIMA estacional de orden AR(1) MA(2). Como se observa en la Tabla 5, tiene un  $R^2$  ajustado de 0,99372 y menor criterio de Schwarz comparado a los otros modelos utilizados lo cual lo hace sólido. (Elliott & Timmermann, 2016)

Modelo 65: ARMAX, usando las observaciones 2017:01-2019:04 (T = 28)  
 Estimado usando AS 197 (MV exacta)  
 Variable dependiente: Unidades  
 Desviaciones típicas basadas en el Hessiano

	coeficiente	Desv. típica	z	valor p	
const	7903,97	19,1710	412,3	0,0000	***
Phi_1	-0,737272	0,145401	-5,071	3,97e-07	***
Theta_1	-1,49321	0,730643	-2,044	0,0410	**
Theta_2	0,999993	0,731254	1,368	0,1715	
dm1	806,031	36,4243	22,13	1,66e-108	***
dm2	331,002	37,8704	8,740	2,32e-018	***
dm3	1063,55	40,1229	26,51	7,97e-155	***
dm4	947,122	41,7572	22,68	6,80e-114	***
dm5	857,824	40,9746	20,94	2,54e-097	***
dm6	769,987	42,2742	18,21	3,99e-074	***
dm7	981,150	43,6214	22,49	4,93e-112	***
dm8	809,813	45,0287	17,98	2,58e-072	***
dm9	724,976	46,4794	15,60	7,54e-055	***
dm10	991,138	47,9630	20,66	7,21e-095	***
dm11	691,801	49,4983	13,98	2,18e-044	***
dm12	1239,46	51,0476	24,28	3,15e-130	***
Fecha	-61,6628	2,02280	-30,48	4,27e-204	***
Media de la vble. dep.	7851,321	D.T. de la vble. dep.	515,8392		
Media de innovaciones	-4,172538	D.T. innovaciones	27,15346		
R-cuadrado	0,997209	R-cuadrado corregido	0,993720		
Log-verosimilitud	-159,5334	Criterio de Akaike	355,0667		
Criterio de Schwarz	379,0464	Crit. de Hannan-Quinn	362,3975		

	Real	Imaginaria	Módulo	Frecuencia
AR (estacional)				
Raíz 1	-1,3564	0,0000	1,3564	0,5000
MA (estacional)				
Raíz 1	0,7466	-0,6653	1,0000	-0,1158
Raíz 2	0,7466	0,6653	1,0000	0,1158

Tabla 5: Resultados obtenidos con *grtl* para el modelo AR(1)MA(2)

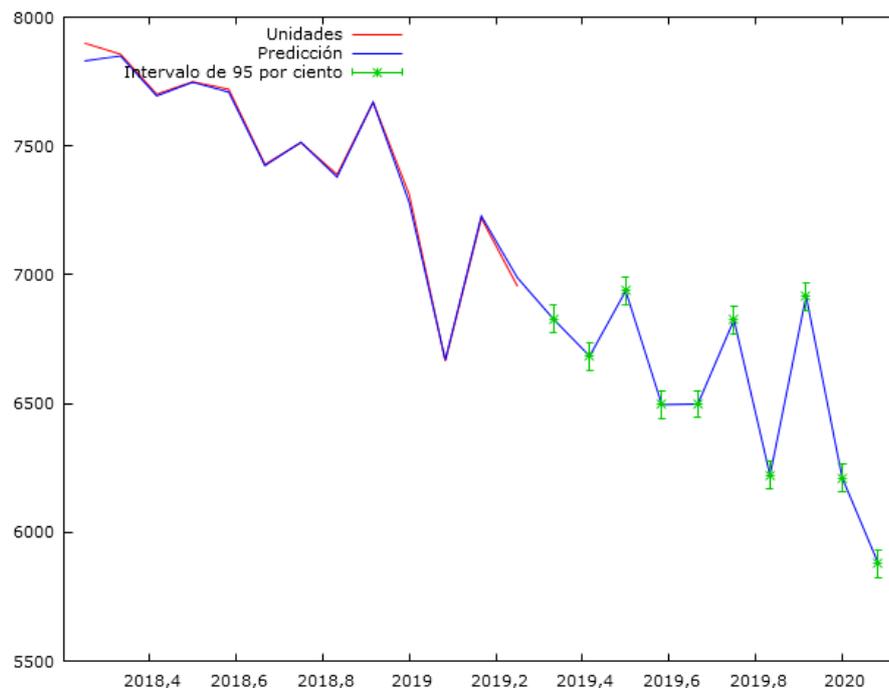
Al ejecutar este modelo se obtuvieron los siguientes resultados realizados con un intervalo de confianza al 95 % que se puede apreciar en la Tabla 6:

Mes	Pronóstico	Ventas Reales	Diferencia	Costo
May-19	6.828	6.877	49	12.307
Jun-19	6.684	6.632	-52	18.165
Jul-19	6.937	6.723	-214	74.991
Ago-19	6.496	6.875	379	94.872
set-19	6.498	6.471	-27	9.415
Oct-19	6.825	6.644	-181	63.241
Nov-19	6.221	6.217	-4	1.456
Dic-19	6.917	6.566	-351	122.829
Ene-20	6.211	6.346	135	33.635
Feb-20	5.879	5.745	-134	46.974
<b>Total</b>		<b>65.096</b>	<b>-400</b>	<b>477.886</b>

Tabla 6: Resultados obtenidos mediante utilización de modelo AR(1)MA(2)

Como se puede observar, el costo del error en este pronóstico (\$ 477.886) es sensiblemente inferior a los anteriores, aproximadamente unas 4,5 y 1,8 veces menor respectivamente.

Este programa permite a su vez graficar el pronóstico realizado para poder tener una referencia visual del comportamiento.



Gráfica 4: Representación gráfica del pronóstico realizado con gntl

Para exigir aún más al modelo, se realizaron los siguientes supuestos en forma separada para los resultados obtenidos en el intervalo de confianza del modelo ARIMA expuesto

anteriormente: (i) el pronóstico es la cota inferior del intervalo, (ii) el pronóstico es la cota superior del intervalo y (iii) el pronóstico es la cota superior o inferior del intervalo de forma que el costo del error es el máximo del intervalo. En la Tabla 7 se encuentran los diferentes valores del intervalo de confianza y los resultados obtenidos al aplicar los supuestos.

Mes	IC al 95%							
	Real	cota inf	cota sup	Dif inf	Dif sup	Costo inf	Costo sup	Max costo
May-19	7.124	6.775	6.881	349	243	87.363	60.753	87.363
Jun-19	6.823	6.631	6.737	192	86	48.080	21.470	48.080
Jul-19	6.897	6.884	6.990	13	-93	3.237	32.718	32.718
Ago-19	7.054	6.442	6.549	612	505	152.928	126.318	152.928
set-19	6.628	6.445	6.551	183	77	45.830	19.220	45.830
Oct-19	6.805	6.771	6.878	34	-73	8.382	25.518	25.518
Nov-19	6.350	6.168	6.274	182	76	45.515	18.905	45.515
Dic-19	6.712	6.864	6.970	-152	-258	53.102	90.356	90.356
Ene-20	6.552	6.158	6.265	394	287	98.440	71.830	98.440
Feb-20	6.022	5.826	5.932	196	90	49.003	22.392	49.003
<b>Total</b>	<b>66.967</b>	<b>64.964</b>	<b>66.028</b>	<b>2.003</b>	<b>939</b>	<b>591.880</b>	<b>489.480</b>	<b>675.750</b>

Tabla 7: Resultados al exigir el modelo con IC al 95%

Como se puede observar en la Tabla 7, si el resultado del pronóstico fuera siempre la cota inferior, el costo del error sería de \$ 591.880, mientras que si fuera la cota superior se situaría en los \$ 489.480. En ambos casos, la pérdida es inferior a los pronósticos intuitivos con una probabilidad del 95 %. Sin embargo, si se exige más aún el modelo y se elige aquel pronóstico con el mayor costo de error por mes de acuerdo con las cotas, se podrá apreciar que el costo del error asciende a \$ 675.750, lo cual continúa representando un 25 % menos que la mejor estimación intuitiva realizada anteriormente.

Estas diferencias considerables demostradas en este apartado resultan del análisis de los tres artículos seleccionados. Extrapolando los resultados a la totalidad de artículos los resultados serán más importantes y contundentes aún.

Dados los resultados expuestos anteriormente, se puede concluir que contar con un modelo estadístico para la predicción de demanda acerca a mejores resultados y le quita cierto grado de subjetividad al armado del mismo. Esto sin tener en cuenta el tiempo que lleva hacer la predicción para cada artículo.

---

## CAPÍTULO IV: SOLUCIONES PARA PRONOSTICAR DEMANDA

### Gestionando inventarios con hojas de cálculo

Cuando se trata de gestión y control de stock, las hojas de cálculo son la herramienta preferida de la mayoría de los planificadores. Sin embargo, tratar de administrar el inventario de esta manera puede resultar complejo y poco práctico.

MS Excel del paquete Microsoft Office, en cualquiera de sus versiones, es sin dudas el programa predeterminado para realizar análisis de todo tipo y muchas empresas dependen demasiado de esta herramienta. Si bien las hojas de cálculo son fáciles de usar, en muchas situaciones comerciales, simplemente carecen de la potencia de procesamiento así como de la estructura estándar o la solidez requerida.

Esto se puede observar en la gestión de la cadena de suministro, donde casi todas las decisiones deben estar respaldadas por un análisis efectivo potencialmente de miles de líneas de datos.

Para construir una hoja de cálculo que sea capaz de administrar volúmenes tan grandes de datos, una empresa tendría que dedicar muchas horas de desarrollo y refinar una hoja de cálculo. De todas formas, en ese caso, la hoja de cálculo final sin dudas sería lenta y engorrosa, sin mencionar la posibilidad de que el archivo se dañe.

Estas planillas se convierten en hojas creadas totalmente a medida. Esto trae como consecuencia que las empresas se vuelvan dependientes de quien creó el documento. A su vez, son administradas también por una sola persona para gestionar inventarios. Esto, por un lado, es una ventaja ya que evita múltiples manipulaciones de la misma que pueden contribuir a errores. Sin embargo, desde otro punto de vista, supone un riesgo elevado cuando esa persona a cargo cambia de rol o abandona la empresa. Esto puede aún potenciarse más por la dificultad para entender las fórmulas de quien reemplaza al responsable de llevar estas planillas, muchas veces de alta complejidad.

Los errores de fórmula y tipeo están a la orden del día y cuanto mayor la cantidad de líneas de información, más aumenta este margen de error. Un caso muy conocido es el de JP Morgan que atribuyó una equivocación por errores cometidos en MS Excel por un costo de 6 mil millones de dólares. (Expansión, 2013)

Cuando una empresa recién está comenzando, las hojas de cálculo son probablemente suficientes. Sin embargo, a medida que crece la demanda y la organización se expande, la complejidad de la operación se incrementará. Aquí es cuando las hojas de cálculo dejan de ser estables y generalmente tienen un impacto directo en el crecimiento, ya que posiblemente no lograrán apoyar a la empresa de la mejor manera en ese camino.

Otra desventaja es que si bien es posible desarrollar un sistema de control de cambios, el tiempo que se requiere para gestionar e implementarlo es muy alto.

### **Soluciones efectivas**

Independientemente de los cambios del personal, para que un software de gestión de stock sea efectivo, debe respaldar la continuidad de los datos. En consecuencia, los procedimientos de previsión, planificación de la demanda, asignación y reposición, no solo deben ser sólidos, sino también estandarizados.

La solución utilizada debe permitir a los equipos de planificación trabajar de forma proactiva. Si las empresas logran automatizar los procesos de gestión de inventario, los equipos de la cadena de suministro pueden centrar su atención en los problemas más críticos. El software de gestión de stock debe hacer el trabajo más complejo para que los equipos de la cadena de suministro puedan enfocar su tiempo y atención donde es realmente importante o necesario.

Un software de control de stock debe proporcionar conocimientos en los que se pueda confiar. Mediante la utilización de modelos de pronóstico probados y estructuras de datos adecuadas, una solución de control de stock efectiva minimizará el riesgo de errores y asegurará que el análisis sea consistente. Como resultado se obtendrán conocimientos sólidos sobre los cuales basar las decisiones de la cadena de suministro con confianza.

Para la mayoría de las empresas, el crecimiento genera una mayor demanda. Por lo tanto, los equipos de planificación deben administrar redes más grandes de distribución con más clientes y más productos. Sin embargo, todos estos resultados se reflejan en un aumento exponencial de datos. Si se administraran solo con hojas de cálculo, la cantidad de líneas de datos y las fórmulas necesarias para mantener todo bajo control sería inmanejable.

Un software de control de stock eficaz no solo debe respaldar el crecimiento sino también aprovechar activamente la complejidad para proporcionar a las empresas ideas valiosas y una mayor visión.

## Principales *vendors* de soluciones

En esta sección se analizarán algunos *vendors* (desarrolladores de soluciones) de los productos enlatados antes mencionados. La mayoría de estos buscan optimizar los niveles de stock a las compañías, minimizando el ingreso de datos manuales por los usuarios. Básicamente, lo que ofrecen es gestionar de forma eficiente el stock, contando con cantidades suficientes de productos en los puntos de venta con la mínima inversión de capital. En el último tiempo, estos se han enfocado en mejorar los modelos mediante algoritmos de *machine learning*, así como también la interfase con el usuario y la visualización de los datos.

A pesar de la enorme expectativa acerca de las tecnologías como *machine learning* e inteligencia artificial, existen límites en cuanto a las capacidades y el valor que se puede obtener del uso de los mismos. De todos modos, el potencial que han desarrollado hoy en día supera estas limitaciones y pone el foco de esperanza en continuar agregando valor. A su vez, los *vendors* han incorporado mejoras sumando algoritmos para reconocimiento de patrones que permitan distinguir valores anómalos y atípicos, analizando al mismo tiempo las políticas y supuestos establecidos por el planificador.

Un punto al cual los *vendors* le prestan suficiente importancia es al uso del software buscando facilitar las mejores herramientas que sean útiles a la hora de entender los resultados y tomar decisiones. La gran mayoría permiten generar paneles amigables e informes que pueden personalizarse por los usuarios y no hojas de cálculo con números que hacen más atractivos los resultados o informaciones.

Mirando a futuro, se busca una mejor conexión con los datos de los puntos de venta para que las soluciones sean más receptivas y permitan a los clientes operar en tiempo real. Incluso cuando el *lead time* sea de períodos más largos, este le permitirá tener una mejor idea de la predicción y mejorar el pronóstico de demanda reduciendo los riesgos de compradores.

Si bien aún se está lejos de que el software administre completamente en lugar de los humanos los objetivos de inventario y nivel de servicio, algunos clientes de estos *vendors* han logrado disminuir sensiblemente las cargas de trabajo permitiendo optimizar ese tiempo para análisis y planificación.

La configuración y flexibilidad de la herramienta de planificación debe ser estándar especialmente si el proveedor ofrece una implementación en la nube siguiendo las mejores prácticas de la industria. Actualmente, los proveedores que han podido hacer el cambio a

la nube están mejor posicionados para aprovechar las capacidades analíticas que generan valor para las soluciones de optimización de inventarios en los próximos años.

De acuerdo con el estudio realizado por Nucleus Research en “Inventory optimization technology value matrix 2019” donde año a año analizan las funcionalidades de los principales proveedores, se puede observar a continuación, en la Imagen 1, donde se muestra cómo se compone el mercado de los principales *vendors* de acuerdo con el uso por parte de los usuarios y la funcionalidad.



Imagen 1: Representación de los vendors (Nucleus Research, 2019)

Se describen a continuación las principales características de alguno de los *vendors* para tener una noción a la hora de elegir con qué software quedarse.

Aquí vale aclarar que la decisión siempre debe ir en línea con el tamaño de la empresa y/o facturación, ya que los costos de dichas implementaciones son elevados y las mismas deben justificar su inversión. Asimismo, las pequeñas o medianas empresas quizás deban buscar con algún sistema de planificación de *open source* o diseñar algo propio y más a medida que estos enlatados, donde generalmente existe mayor rigidez de lo que propone.

### E<sub>2</sub>Open:

Es la empresa líder de acuerdo con IO Matrix ya que ofrece una optimización de inventario a través de toda la cadena de suministro basado en la nube que incluye planificación de ventas y operaciones, planificación y respuesta de suministros, planificación y percepción de demanda, gestión de proveedores y canales en múltiples niveles.

La solución se ubica entre la planificación de la demanda y la planificación de suministros extrayendo datos del ERP, de la solución de gestión de canal y del planificador de demanda ayudando a la empresa a establecer un inventario óptimo y niveles de existencias de seguridad que se incorporan al módulo de planificación y respuesta de suministro, así como a los proveedores.

La propuesta de valor de este software se basa en su rol central como componente integrado del sistema de planificación para ofrecer un análisis de ciclo cerrado de los niveles de stock mediante el monitoreo o control de la concreción de los objetivos de inventario, recolectando información como plazos de entrega, interdependencia de las ubicaciones de los SKU y violaciones a las políticas definidas. La herramienta muestra el inventario en ubicaciones orientadas al cliente y entre depósitos con el pronóstico de demanda utilizando la demanda observada a través de la cadena, eliminando la necesidad de agrupar el riesgo y dando como resultado planes de suministro más precisos que permiten a los clientes reducir los niveles de retención de inventarios.

Este proveedor ha realizado varias adquisiciones en el último tiempo como *Orchestra* para la recopilación de datos del punto de venta, *Zyme* para la gestión de datos de canal, *Terra Technology* para la detección de la demanda y *Steelwedge* para la planificación de operaciones y ventas, lo que le han permitido posicionarse como líder. (Nucleus Research, 2019)

### SAP:

Este software es un experto de acuerdo con esta clasificación ya que ofrece la optimización de inventario como parte de una solución integrada de planificación estratégica que cubre cinco módulos: operación y ventas (S&OP), inventarios, analítico de demanda, torre de control, planificación y respuesta de suministros. Este software está disponible en la nube en la plataforma HANA y centrado en la gestión integral de la cadena de suministro. Los clientes obtienen mayores beneficios cuando adquieren más que solo el módulo de optimización de inventario ya que pueden alimentarse con datos de pronóstico de demanda observada.

---

Actualmente está buscando desarrollar soluciones adicionales de aprendizaje automático (ML) que permitan ofrecer un mayor valor a los clientes. (Nucleus Research, 2019)

#### SlimStock:

Es un proveedor *core* que ofrece su producto Slim4 que incluye perfiles de demanda, planificación de demanda, S&OP, planificación de reabastecimiento y planificación MEIO. Dentro de las industrias principales con las que trabaja se encuentra la automotriz, *retail* minorista y mayorista, repuestos, industriales, consumo masivo, construcción y atención médica entre otros.

Este software no está albergado en la nube, sino que requiere instalar licencias de escritorio y conectarse a servidores remotos o tener uno propio para alojarlo. Sin embargo, en los últimos años se viene invirtiendo en la actualización de la interfaz y en ofrecer mayor SaaS (Soporte lógico y datos alojados en servidores de empresas tecnológicas). (Nucleus Research, 2019)

### **Análisis de implementación en caso estudio**

Para mejorar el proceso de pronóstico, la empresa JJ evalúa propuestas de distintos *vendors*. Se procedió en función de las pautas recomendadas en el apartado anterior, “Soluciones efectivas”.

La empresa actualmente cuenta con un ERP que tiene desarrollado un módulo con una fórmula de pedido automático para la preparación de los pedidos a las distintas sucursales y de la misma forma determinar los niveles de compra.

Ante la evolución y el tamaño de dicha organización, la empresa JJ salió al mercado buscando dar un salto en calidad y potenciales ahorros en eficiencia con software enlatado.

Se realizaron reuniones y negociaciones con diferentes empresas, algunas de las cuales se encuentran en la Imagen 1. No se revelarán los nombres, pero sí al cuadrante al que pertenecen con el fin de mantener la confidencialidad de la información.

Para la realización del criterio de selección se tomaron cinco criterios a los que les dio una ponderación relativa para influir en la elección final. Los criterios seleccionados fueron:

- Propuesta
- Experiencia
- Reputación
- Sensaciones

- Precio

### **Propuesta:**

En el análisis de la propuesta se tomaron los siguientes temas aplicando la respectiva ponderación previamente definida:

Cap.	Sec.	Tema	distribución	Peso	Otro A	Core A	Líder A	Líder B	Otro B
2.1		Configuración del Cronograma de Abastecimiento		4%	7	10	10	10	4
2.2		Sistema de revisión y generación		4%	4	10	10	10	4
2.3		Gestión por incidencias		7%	4	10	10	10	4
2.4		Pronóstico avanzado de demanda	40%						4
	2.4.0	Método de pronóstico de demanda base	25%	10%	5	7	10	10	4
	2.4.1	Promociones	25%	10%	4	2	10	10	4
	2.4.2	Nuevos	15%	6%	7	8	10	10	4
	2.4.3	Estacionales	15%	6%	10	10	10	7	4
	2.4.4	Sustitutos	5%	2%	4	10	10	10	4
	2.4.5	Intermitentes	5%	2%	4	10	10	10	4
	2.4.6	No sugerir cuando está discontinuado	5%	2%	4	8	10	10	4
	2.4.7	Quiebres de stock	5%	2%	10	10	10	10	4
2.5		Cálculo avanzado del stock de seguridad		20%	5	5	10	10	4
2.6		Gestión del stock mínimo y mínimo de exhibición		2%	5	10	10	10	4
2.7		Gestión de Exclusiones		2%	10	10	10	10	4
2.8		Gestión del stock sobrante		3%	4	4	8	10	4
2.9		KPI's		8%	5	7	7	10	4
2.10		Revisión final de cantidades sugeridas		3%	5	8	8	9	4
2.11		Redondeos de bulto y bonificaciones		3%	3	7	7	10	4
2.12		Category Management Incorporado		2%	0	0	0	0	4
2.13		Elementos de Inteligencia Artificial / Redes neuronales / Machine Learning		2%	0	0	0	10	4
		<b>Total</b>		<b>100%</b>	<b>5,1</b>	<b>6,8</b>	<b>9,2</b>	<b>9,6</b>	<b>4,0</b>

Tabla 8: Ponderación aplicado a la propuesta de acuerdo a cada tema.

### **Experiencia:**

Para este punto se buscó información sobre los distintos clientes que implementaron la solución. La forma de ponderar este criterio fue analizando la experiencia que tenía el proveedor en cuatro categorías ponderando en importancia de menor a mayor de acuerdo con la siguiente lista:

- Mismo sector de actividad (*retail*) a nivel mundial.
- Mismo sector de actividad a nivel regional (LATAM).
- Mismo tipo de empresas dentro del sector a nivel mundial.
- Mismo tipo de empresas a nivel regional (LATAM).

A continuación, se presenta el análisis realizado por la empresa respecto a este punto.

Empresa	Producto	Antigüedad (años)	Implementaciones				Las más relevantes	Puntaje
			5%	10%	25%	60%		
			Misma sector - Diferente tipo empresa	Misma sector - Diferente tipo empresa LATAM	Mismo tipo empresa	Mismo tipo empresa LATAM		
Otro A	Otros A RP	18	0	7	0	0	RIBEIRO (Argentina) UNISUPER (Argentina) SUPER SELECTOS (El Salvador) MEGA SANTA MARÍA (Ecuador) LA COLONIA (Honduras) MOTOCICLO (Uruguay) ETMAN (Argentina)	1,6
Core A	Core4	20	10	1	6	0	• Mediq (Holanda y Polonia) • Fagron (Holanda y Brasil)+H5 • ZacoFarva (España) • Accord Healthcare (España) • Byram Healthcare (Estados Unidos) • Grupo Rev (Panamá)	4,7
Lider A	Lider99	21	10	3	2	2	1) Corporación GPF (Ecuador): Fibeca + SanaSana Fibeca: 94 PDV, 16.000 SKU SanaSana: 500 PDV, 25.000 SKU	5,6
Lider B	RAS WRA TOP	31	10	10		5		10,0
Otro B		0	0	0	0	0		0,0

Tabla 9: Ponderación aplicada a la experiencia del vendor

### Reputación:

En este criterio se tomaron como referencia los informes y estudios realizados por Nucleus y Gartner para analizar la reputación de las distintas soluciones y se obtuvo el siguiente el puntaje:

Proveedor	Nucleus	Gartner	Puntaje
Otro A	-	-	0
Core A	Core	Challenger	7
Lider A	Líder	Líder	10
Lider B	Líder	Líder	10
Otro B	-	-	0

Tabla 10: Reputación de acuerdo a los principales analistas

### Sensaciones:

En este punto, quizás el más subjetivo de todos, pero no menos importante es donde se ponderó la percepción de los principales dueños del proyecto e implementación en la compañía. Dichas personas ocupan puestos clave y tienen una visión global de la empresa que les permite poder entender cuáles son los que a su criterio se ajustan de mejor manera

o cumplen más eficientemente con las necesidades actuales. Participaron en esta valoración los directores Comercial, TI, Logística y distribución y el jefe de *supply chain*.

PD	Director LyD	Director Com	Director IT	Jefe Supply chain	Promedio
Cygnus	4	8	6	4	5,5
SlimStock	7	10	8	7	8,0
Tools Group	7	4	8	9	7,0
jda	9	5	5	9	7,0
Forecastia	4	6	5	4	4,8
Opus	4	0	4	3	2,8

Tabla 11: Valoración interna de la propuesta

### **Precio:**

Este criterio es uno de los más sensibles y con mayor impacto en las decisiones ya que se trata de importantes erogaciones. Muchos proveedores presentan sus propuestas incluyendo diferentes agregados lo que hace difícil comparar. Por este motivo, se buscó uniformizar las solicitudes para poder hacer comparables las ofertas en una propuesta inicial. El costo se descompone en la inversión inicial que normalmente es la más fuerte y luego costos de mantenimiento, desarrollo y accesorios.

Inversión Inicial (USD)		Mantenimiento (USD/año)		Modalidad SAAS (USD/año)	
Proveedor	Oferta Inicial	Proveedor	Total	Proveedor	Total
Otro A	108.410	Otro A	9.508	Otro A	No tiene
Core A	385.640	Core A	45.927	Core A	No tiene
Lider A	593.570	Lider A	44.000	Lider A	147.096
Lider B	995.000	Lider B	66.000	Lider B	250.000
Otro B	152.000	Otro B	199.200	Otro B	265.000

Tabla 12: Principales componentes del costo

Costo Total a 5 años				
Proveedor	Inversión	Mantenimiento (5 años)	TOTAL	Puntuación
Otro A	108.410	47.540	155.950	8,6
Core A	270.960	229.635	500.595	5,6
Lider A	345.000	220.000	565.000	5,1
Lider B	765.000	330.000	1.095.000	0,5
Otro B	152.000	996.000	1.148.000	0,0

Tabla 13: Análisis comparativo de soluciones

Luego de analizar los distintos criterios se analizó la importancia de cada uno en la elección de la nueva solución a implementar agregando a la comparación el módulo que podría desarrollar el ERP actual para satisfacer la solicitud.

Los resultados fueron los siguientes:

Criterio	Peso	Otro A	Core A	Lider A	Lider B	Otro B	Actual
1. Propuesta	40%	5,1	6,8	9,2	9,6	4,0	3,0
2. Experiencia	25%	1,6	4,7	5,6	10,0	0,0	1,6
3. Reputación	5%	0,0	7,0	10,0	10,0	0,0	0,0
4. Sensaciones	10%	5,5	8,0	7,0	7,0	4,8	2,8
5. Precio	20%	8,6	5,6	5,1	0,5	0,0	10,0
<b>Puntaje Final</b>	<b>100%</b>	<b>47</b>	<b>62</b>	<b>73</b>	<b>76</b>	<b>21</b>	<b>39</b>

Ranking	4	3	2	1	6	5
---------	---	---	---	---	---	---

Tabla 14: Resumen de criterios ponderados

### Pronosticar ante eventos inusuales

Todo lo expuesto anteriormente en este trabajo se basa en situaciones que suceden de forma habitual en la vida de las empresas en las que existen artículos sazonales que tienen una demanda estacional, otros con demandas cíclicas, pero todas ellas dentro de ciertos intervalos. En estas circunstancias los softwares para predicción se adaptan perfectamente entendiendo estos cambios naturales, pero es importante preguntarse ¿qué pasa cuando uno se enfrenta a situaciones atípicas?

En este último tiempo, la mayoría de los países se han enfrentado a una situación totalmente atípica de impacto no solo a nivel regional sino también mundial, el efecto COVID-19. Esto ha cambiado por completo los hábitos de consumo de las personas de forma radical. La clave desde el punto de vista de la planificación está en tomar rápidamente el timón por parte de los expertos en la materia y afectar estratégicamente los parámetros de las soluciones para tener una estrategia reactiva. Se puede influir en el pronóstico de distintas formas, algunas de las cuales se describirán brevemente para luego pasar a relatar cómo reacciona la empresa JJ ante esta situación.

- **Ajuste de pronóstico estructural:** consiste en modificar la demanda media para el cálculo del mismo.
- **Ajuste de pronóstico a nivel de mes:** cambio esperado en el pronóstico (aumento o disminución) para meses específicos.
- **Ajuste de pronóstico a nivel de semana:** igual al punto anterior para semanas puntuales.
- **Ajuste temporal del tiempo de entrega:** debido a la incertidumbre en la cadena de suministro, los plazos de entrega son temporalmente más largos. Poder influir en

---

este punto podría ayudar a prever mejor la cantidad a comprar para hacer frente a las mismas demandas o niveles superiores aún.

- **Creación de un stock de seguridad adicional:** para absorber picos adicionales ya que los sistemas pueden no reaccionar tan rápidamente y puede resultar una solución muy útil.

Los cambios en el consumo traen aparejado artículos con una demanda varias veces mayor a lo habitual de algunos productos y caídas estrepitosas en otros. Ante esto, en la empresa JJ se estableció como foco principal un listado de artículos críticos de consumo debido al coronavirus (“listado COVID-19”) como por ejemplo tapabocas, alcohol en gel y desinfectantes, entre otros, donde se priorizó siempre tener stock suficiente antes que quebrar para todos los productos referidos. Se determinó que contar con stock suficiente en épocas de crisis podría generar nuevos clientes satisfechos por la dificultad de adquirir estos productos en el mercado. Es fundamental aclarar que este listado es dinámico y se analiza día a día de acuerdo con el comportamiento del mercado.

Como primera medida, no se recurrió a la planificación, sino que se realizaron compras en las cantidades que se pudieran conseguir dada a la escasez para artículos de este “listado COVID-19”. Esto tiene un potencial efecto látigo en la cadena de suministro que podría generar *sobrestocks* altísimos una vez que esta situación se normalice.

La segunda medida se basó en poner la analítica a disposición de la situación para poder verificar lo que el software de planificación estaba solicitando y determinar cuáles deberían ser los niveles óptimos de compra para esta situación. Mientras tanto, se tomó como medida para abastecer a las tiendas la creación de un nuevo stock de seguridad de forma temporal para asegurar un correcto abastecimiento de estos artículos y que la mercadería estuviera en su mayor porcentaje en los locales comerciales.

Por último, una vez que los niveles de compra se lograron adaptar a la situación, se buscó adecuar el software modificando determinados parámetros como palancas. Se estableció un stock de presentación temporal (stock de seguridad adicional) para afectar la disponibilidad de stock en las tiendas, y a medida que empieza a quedar atrás el pico de mayor demanda, se comienza a disminuir este parámetro hasta eliminarlo definitivamente una vez esté normalizada la situación. Mientras tanto, a nivel de compras se modificó la previsión base para el cálculo de los pronósticos afectando el *lead time* de entrega del proveedor y la demanda diaria tomando como representativa los últimos 60 días.

Esta batería de medidas se comenzó a aplicar los días previos a la llegada del coronavirus al país, dada su inminente aparición. Como todo es dinámico, más aún en el *retail*, las

acciones más profundas se terminaron de implementar durante los primeros 10 días de la pandemia a nivel local.

Todas estas medidas sirven para poder hacer frente a las altas demandas, pero ¿qué pasa con aquellos artículos que las personas dejaron de consumir? La tendencia es dejarlos de lado sin tener en cuenta que estos productos generalmente son la mayoría en los locales comerciales. Mantener los mismos niveles de stock y compras resultará en futuros *sobrestock* con lo que esto implica de acuerdo con lo expuesto anteriormente. Una opción podría ser disminuir los stocks de seguridad temporalmente y reducir el *lead time* cargado en el sistema como forma de disminuir los pedidos a realizar.

Resulta muy difícil entrenar un modelo para funcionar correctamente ante situaciones muy distintas a los datos utilizados para dicho entrenamiento. Los planificadores, aun los de primer nivel, reaccionan tarde ante estos fenómenos ya que ningún modelo predictivo puede anticiparse, por lo cual es clave la injerencia del planificador humano experto para hacerse cargo del volante y transitar la travesía.

Una rápida respuesta de cara al consumidor puede tener un efecto multiplicador en la captación de nuevos clientes y consolidación de actuales en tiempos de crisis. A su vez, permitirá contar con mejores datos en tiempo real para pronosticar de mejor manera.

## Conclusiones

El pronóstico de la demanda resulta de vital importancia a la hora de tomar decisiones en las empresas que no solo tienen afectación en las áreas comerciales o de *supply chain*, sino también en los resultados financieros de la compañía.

La mejor opción para pronosticar la demanda en *retail* es la utilización de modelos estadísticos de series de tiempo, que como se ha demostrado en este trabajo mejora considerablemente los resultados y no tiene en cuenta posibles sesgos utilizados a la hora de pronosticar de forma manual. Sin embargo, esta intuición o idea que tienen los expertos nunca debe ser descartada, sino que siempre es buena complementarla a los resultados obtenidos del modelo. Ante situaciones excepcionales es este juicio del experto el que puede salvar de grandes errores a las empresas y el que a su vez puede agregar valor para afectar distintos parámetros que permitan corregir la predicción. Se analizó anteriormente que, en situaciones totalmente anómalas como, por ejemplo, el efecto COVID-19, resulta fundamental la proactividad para hacerse cargo del problema y analizar la mejor opción para corregir los pronósticos.

Por último y a la hora de elegir un software para pronosticar la demanda es importante tener en consideración el tamaño de la empresa, el objetivo perseguido y analizar cuánto ahorro debe generar un software enlatado versus un desarrollo a medida, si se desea ir por ese camino, o la utilización de softwares de código abierto que siempre es una opción disponible sobre todo para empresas pequeñas y medianas.

Sea cual fuera el software a utilizar resulta clave asegurar la continuidad de los datos, la solidez y estandarización de los mismos. Debe ser confiable y contribuir en la minimización de errores para que el análisis sea consistente y se puedan tomar las mejores decisiones con confianza. Es deseable a su vez que pueda aportar una mayor visión y agregar valor a la compañía aprovechando la complejidad con la que está construido.

## Bibliografía

- Athanasopoulos, G., & Hyndman, R. (2nd edition, May 2018). *Forecasting: Principles and Practice*. Monash University, Australia: Otext. Obtenido de <https://otexts.com/fpp2/>
- Academy, S. (s.f.). *Slimstock Academy*. Obtenido de <https://www.slimstock.com/cl/news/la-estacionalidad-en-las-compras-de-inventario/>
- Acosta Ríos, M. F., Díaz Pacheco, R. A., & Anaya Salazar, Á. P. (Jul de 2009). *Biblioteca Universidad de San Buenaventura*. Obtenido de <http://bibliotecadigital.usb.edu.co>: <http://hdl.handle.net/10819/5127>
- Aditya, J., Nils, R., & Tong, W. (Febrero 2015). *Demand Estimation and Ordering Under Censoring: Stock-Out Timing Is (Almost) All You Need*. Operation Research.
- Diebold, F. X. (Edition 2017). *Forecasting in Economics, Business, Finance and Beyond*. University of Pennsylvania: University of Pennsylvania.
- Elliott, G., & Timmermann, A. (2016). *Economic Forecasting*. United Kingdom: Princeton University.
- *Expansión*. (19 de Abril de 2013). Obtenido de Expansión: <https://expansion.mx/economia/2013/04/18/los-mayores-errores-financieros-en-excel>
- Kozyrkov, C. (4 de Abril de 2020). *Medium*. Obtenido de towards data science: <https://towardsdatascience.com/how-to-work-with-someone-elses-data-f33485d79ed4>
- Kozyrkov, C. (3 de Abril de 2020). *Medium*. Obtenido de toward data science: <https://towardsdatascience.com/how-to-work-with-someone-elses-data-6c45d467d7a2>
- Murillo Bustamante, Á. (2019). *Universidad Católica del Norte*. Obtenido de Universidad Católica del Norte: <https://slideplayer.es/slide/13782716/>
- Nucleus Research. (2019). *IO TECHNOLOGY VALUE MATRIX 2019*.
- SlimStock. (2018). *SlimStock Knowledge*. Obtenido de <https://www.slimstock.com/cl/news/5-principios-para-la-prevision-de-la-demanda/>
- *SlimStock Academy*. (s.f.). Obtenido de <https://www.slimstock.com/cl/news/los-queiebres-de-stock-en-retail/>