



# Más allá de la góndola: Asignación óptima y pronóstico de la participación de mercado de Cool Drinks Company



Miembros del equipo



---

**Más allá de la góndola: Asignación óptima y pronóstico de la participación de  
mercado de Cool Drinks Company**

**Aragón Ana Paula - Assis Rosario - Espeche Miguez Mateo Benjamin - Fernandez Santiago -**

**Filgueira Delfina - Prado Leggio Zoe María - Rivera Galo Camila Paulina**

**[aaragon@face.unt.edu.ar](mailto:aaragon@face.unt.edu.ar) - [rosarioassis12@gmail.com](mailto:rosarioassis12@gmail.com) - [mateoespechemiguez@gmail.com](mailto:mateoespechemiguez@gmail.com) -**

**[santifern25@gmail.com](mailto:santifern25@gmail.com) - [delfinafilgueira3@gmail.com](mailto:delfinafilgueira3@gmail.com) - [zpradoleggio@gmail.com](mailto:zpradoleggio@gmail.com) -**

**[pauliriveragalo@gmail.com](mailto:pauliriveragalo@gmail.com)**



## ÍNDICE

<b>RESUMEN.....</b>	<b>4</b>
<b>INTRODUCCIÓN.....</b>	<b>5</b>
<b>SITUACIÓN PROBLEMÁTICA.....</b>	<b>5</b>
<b>PREGUNTAS DE INVESTIGACIÓN.....</b>	<b>6</b>
<b>MARCO METODOLÓGICO.....</b>	<b>7</b>
ENFOQUE Y DISEÑO DE INVESTIGACIÓN.....	7
TÉCNICAS DE RECOLECCIÓN DE DATOS.....	7
<b>HERRAMIENTAS A UTILIZAR (MODELOS).....</b>	<b>7</b>
<b>MARCO TEÓRICO.....</b>	<b>8</b>
<b>FUENTE Y CAPTURA DE LOS DATOS.....</b>	<b>13</b>
<b>APLICACIÓN.....</b>	<b>14</b>
ENTREVISTA A SUPERVISOR DE SUPERMERCADOS.....	14
PROGRAMACIÓN LINEAL POR METAS.....	15
PRONÓSTICO.....	20
<b>CONCLUSIONES.....</b>	<b>24</b>
<b>APÉNDICE.....</b>	<b>25</b>
<b>ANEXO.....</b>	<b>25</b>
Evaluación del modelo ARIMA como alternativa inicial.....	25
Comparación de Modelos de pronósticos:.....	28
<b>FUENTES BIBLIOGRÁFICAS.....</b>	<b>35</b>



---

## RESUMEN

El presente trabajo de investigación se enfoca en la aplicación de herramientas cuantitativas para mejorar la eficiencia operativa y fortalecer la toma de decisiones estratégicas en *Cool Drinks Company* (CDC), una empresa del sector de bebidas con destacada presencia en el canal de supermercados. En un contexto comercial cada vez más competitivo y dinámico, se vuelve imprescindible gestionar de forma óptima los recursos críticos, especialmente aquellos vinculados a la ejecución en el punto de venta y las acciones promocionales.

A través de un enfoque mixto —combinando técnicas cualitativas y cuantitativas— se desarrollan dos modelos analíticos: un modelo de Programación Lineal por Metas (PLM) orientado a optimizar la asignación semanal de horas de los repositores entre tiendas estratégicas; y un modelo de pronóstico basado en series de tiempo, que permite anticipar la evolución del indicador de participación de mercado (Share of Market, SOM) por cadena, y ajustar en consecuencia la planificación promocional.

La investigación se apoya en entrevistas semiestructuradas con personal clave de CDC, así como en bases de datos primarias y secundarias provistas por la organización y por consultoras especializadas. Esta triangulación metodológica permite abordar el fenómeno desde una perspectiva integral, fortaleciendo la validez de los resultados obtenidos.

Los modelos implementados evidencian el valor de una toma de decisiones apoyada en datos y orientada a resultados. Su correcta aplicación ofrece a la empresa la posibilidad de mejorar su ejecución en tiendas de alto potencial, anticiparse a escenarios adversos y asignar sus recursos de forma estratégica, contribuyendo a un posicionamiento más sólido y sostenible en el mercado.

**Palabras Clave:** Programación por metas - pronósticos - Share of Market - repositores - tiendas



---

## INTRODUCCIÓN

La empresa objeto de estudio de este trabajo, *Cool Drinks Company (CDC)* es una de las principales empresas de bebidas del país, con una fuerte presencia en el canal de supermercados, y un portafolio de marcas reconocidas a nivel nacional e internacional. La compañía ha incorporado procesos de gestión modernos, orientados a la eficiencia operativa, la planificación estratégica y la innovación comercial.

En este escenario, la toma de decisiones basada en datos se convierte en una herramienta esencial para CDC. La empresa trabaja constantemente con grandes volúmenes de información comercial y operativa, y emplea herramientas analíticas que permiten transformar esos datos en decisiones concretas. Esta lógica se extiende a múltiples áreas de gestión: desde la ejecución en el punto de venta hasta la planificación de acciones promocionales, la asignación de recursos humanos, y la mejora del desempeño de marca.

El presente trabajo se desarrolla dentro del marco del cursado de la materia “Análisis Cuantitativo de Negocios”, perteneciente a la carrera de Licenciatura en Administración de la Facultad de Ciencias Económicas. A través de la aplicación de modelos cuantitativos —Programación Lineal por Metas y Modelos de Pronóstico— se busca contribuir a una gestión más eficiente de recursos críticos como el tiempo de reposición en tiendas y la inversión en dinámicas comerciales. Estas herramientas permiten, por un lado, optimizar la asignación semanal de horas entre repositorios según criterios estratégicos y operativos; y por otro, anticipar posibles variaciones en indicadores clave como la participación de mercado (Share of Market), facilitando decisiones más proactivas.

El caso de CDC ilustra cómo una empresa de consumo masivo puede integrar la analítica avanzada como parte de su cultura de mejora continua. Apostar por modelos que reduzcan la incertidumbre y apoyen la planificación operativa refuerza su capacidad para adaptarse a un entorno dinámico, mantener ventajas competitivas y lograr una mayor efectividad en la ejecución comercial.

## SITUACIÓN PROBLEMÁTICA

La empresa *Cool Drinks Company (CDC)* ha experimentado una caída en su participación de mercado (Share-of-Market, SOM) dentro de las cadenas de supermercados. El SOM se calcula a partir del análisis de tickets de compra, identificando el peso relativo de las marcas de bebidas de la empresa respecto a las del resto de los competidores dentro de una misma transacción.

En ese sentido, dentro de los **factores clave que explican esta caída**, se identifican los siguientes:



1. Desempeño de los repositorios: Cada punto de venta cuenta con un repositor asignado por la empresa (no por el supermercado), cuya función es asegurar la reposición, orden y visibilidad de los productos en góndola, así como implementar acciones de marca (promociones, exhibiciones, etc.). Existe evidencia interna que señala una **relación directa y positiva entre el desempeño del repositor y el SOM**, en tanto que una mejor ejecución en punto de venta se traduce en mayor participación de las marcas de la empresa.

Sin embargo, el sistema actual de asignación de horas de reposición **no cubre adecuadamente todas las tiendas**, especialmente los **mayoristas** y las tiendas **WAR** (de alto potencial de crecimiento). Esto genera puntos de venta con baja rotación de stock, productos mal exhibidos o vencidos, y **oportunidades de venta desaprovechadas**, contribuyendo al debilitamiento de la posición competitiva de la marca.

2. Asignación de dinámicas comerciales: Las **dinámicas** son descuentos o promociones por marca que se negocian con las cadenas de supermercados y se trasladan al consumidor final, actuando como **disparadores del consumo**. Son una herramienta crítica para mejorar la competitividad frente a otras marcas, especialmente en contextos inflacionarios o de alta sensibilidad al precio.

Actualmente, no existe una **estrategia optimizada de asignación de dinámicas por cadena**, lo que lleva a una distribución desbalanceada. Algunas cadenas pueden tener baja actividad promocional o no contar con descuentos en los productos más relevantes, reduciendo su poder de atracción para el consumidor. Esto contribuye a que, aún con buena presencia en góndola, el consumidor opte por marcas más agresivas comercialmente.

## **PREGUNTAS DE INVESTIGACIÓN**

- ¿Cómo se puede optimizar la asignación semanal de horas de reposición de los repositorios en las tiendas de CDC en Tucumán para maximizar el SOM en los puntos de venta clave, asegurando una cobertura mínima en mayoristas y tiendas WAR?
- ¿Cómo se puede anticipar la variación del SOM semanal por cadena de supermercados para asignar dinámicas comerciales efectivas?

## **OBJETIVO GENERAL**

Aplicar herramientas cuantitativas para optimizar el Share of Market (SOM) de una empresa comercializadora de bebidas de Tucumán que permitan mejorar su desempeño en los segmentos de supermercados a través de una asignación más eficiente de recursos críticos.

## **OBJETIVOS ESPECÍFICOS**



1. Optimizar la asignación semanal de horas de reposición de los repositores en las tiendas de CDC en Tucumán, para maximizar el SOM en los puntos de venta clave, garantizando cobertura mínima en mayoristas y tiendas WAR.
2. Pronosticar la variación del SOM semanal por cadena de supermercados, para anticipar caídas en la participación y asignar dinámicas comerciales de manera más efectiva, focalizando recursos promocionales en las cadenas con mayor riesgo de pérdida de mercado.

## MARCO METODOLÓGICO

### ENFOQUE Y DISEÑO DE INVESTIGACIÓN

El enfoque es mixto, es decir, se combinan herramientas tanto cuantitativas como cualitativas con el fin de obtener una comprensión más completa del fenómeno estudiado, favoreciendo una visión holística del fenómeno. El problema de investigación involucra tanto la medición de variables específicas como la necesidad de interpretar dichas mediciones.

Por otra parte, el diseño de investigación es “No experimental - transversal” observando las variables tal como se dan en la realidad, **sin manipularlas**, y recolectando datos **en un único momento en el tiempo**. Su aplicación se justifica por la necesidad de describir o analizar relaciones entre variables existentes, como también la de detectar tendencias a partir de una fotografía de la situación actual.

### TÉCNICAS DE RECOLECCIÓN DE DATOS

Para la presente investigación, se utilizarán técnicas de recolección de datos acordes al enfoque mixto adoptado. En este sentido, se emplearán entrevistas semiestructuradas a empleados de CDC, con el fin de profundizar en percepciones, experiencias y significados que no podrían captarse mediante instrumentos rígidos. Complementariamente, se utilizarán bases de datos internas primarias, como ser “**Grilla de repositores**” o “**Maestro de clientes**”, y además, bases de datos secundarias, siendo la principal el “**Estudio de Share de mercado**” (fuente: Scientia). Esta combinación de técnicas permitirá abordar el problema desde una perspectiva integral, fortaleciendo la validez de los resultados y favoreciendo una interpretación más completa del contexto analizado.

### HERRAMIENTAS A UTILIZAR (MODELOS)

Las herramientas a utilizar son:

#### Modelo de Programación Lineal por Metas (PLM)



Se utilizará un modelo de PLM para optimizar la asignación semanal de horas de reposición de los repositorios en las tiendas de Tucumán, con el objetivo de maximizar el SOM en los puntos de venta clave.

El modelo incorporará restricciones de cobertura mínima en mayoristas y tiendas WAR, priorizando el uso eficiente del tiempo total disponible de reposición. Así como también garantizar una distribución equitativa de la carga entre repositorios.

### **Modelo de pronóstico del SOM**

Se desarrollará un modelo de series de tiempo, con el fin de predecir la evolución del SOM por cadena de supermercado, a partir de datos históricos semanales. Para ello se contrastará distintos modelos para encontrar aquel que mejor se ajuste al lote de datos disponible, analizando tendencias, ¿el SOM de la cadena crece o decrece en el tiempo? y estacionalidad, ¿hay semanas donde el SOM sube o baja frecuentemente?

Este modelo permitirá anticipar caídas en la participación y asignar dinámicas comerciales de manera más efectiva, focalizando recursos promocionales en las cadenas con mayor riesgo de pérdida de mercado.

## **MARCO TEÓRICO**

### **Análisis Cuantitativo**

El análisis cuantitativo es un enfoque metodológico que se basa en la recolección y análisis de datos numéricos para tomar decisiones informadas y resolver problemas complejos en diversos campos, incluyendo la administración y la economía. Según Levin y Rubin (2012), el análisis cuantitativo utiliza técnicas estadísticas y matemáticas para analizar patrones y tendencias en los datos, lo que permite a las organizaciones optimizar sus operaciones y estrategias. En el contexto de la administración de negocios, el análisis cuantitativo es esencial para la toma de decisiones basada en datos. Render, Stair, y Hanna (2015) destacan que este enfoque permite a las empresas mejorar la eficiencia operativa, reducir costos y maximizar la rentabilidad.

### **Modelos**

En el segundo paso se definieron a los modelos como representaciones (casi siempre matemáticas) de una situación. Sin embargo, existen otros tipos de modelos.

Render, Stair, Hanna (2013), clasifican a los modelos en:

- **Modelos físicos:** Son modelos tangibles de fácil comprensión, pero su modificación y manipulación es difícil y su alcance es de baja utilización. Algunos ejemplos de estos modelos son modelos de aeroplanos, modelos de casas, modelo de una ciudad.
- **Modelos análogos:** Son modelos intangibles de comprensión más difícil al igual que su modificación y manipulación. Su alcance de utilización es más amplio. Por ejemplo: mapa de carreteras, velocímetros, gráfica de rebanada de pastel.



- **Modelos simbólicos:** Los modelos simbólicos son modelos intangibles y su comprensión es la más difícil, al igual que los modelos análogos, su modificación y manipulación es difícil y su alcance es el más amplio. Algunos modelos de estos tipos son: modelos de simulación, modelos algebraicos, modelo de hoja de cálculo electrónica.

#### **Modelos determinísticos y probabilísticos:**

Además, los modelos simbólicos pueden clasificarse en modelos determinísticos y probabilísticos.

Los **modelos determinísticos** son aquellos donde se supone que todos los datos pertinentes se conocen con certeza. Es decir, en ellos se supone que cuando el modelo sea analizado se tendrá disponible toda la información necesaria para tomar las decisiones correspondientes. Por otro lado, en los **modelos probabilísticos o estocásticos**, algunos elementos no se conocen con certeza, es decir, en este tipo de modelos se presupone que algunas variables importantes, llamadas variables aleatorias, no tendrán valores conocidos antes que se tomen las decisiones correspondientes, y ese desconocimiento debe ser incorporado al modelo. Los modelos probabilísticos se destacan por incorporar incertidumbre a través de probabilidades de dichas variables aleatorias.

#### **Programación por metas**

Render (2013) plantea que la programación por metas puede manejar problemas de decisión que implican diversas metas, un concepto antiguo de cuatro décadas, que comenzó con el trabajo de Charnes y Cooper en 1961, fue perfeccionado y ampliado por Lee e Ignizio en las décadas de 1970 y 1980 (véase la bibliografía)

En situaciones comunes de toma de decisiones, las metas establecidas por la gerencia se pueden lograr tan solo a expensas de otras. Es necesario, establecer una jerarquía de importancia entre ellas, de modo que las de menor prioridad se enfrenten únicamente después de que se satisfagan las de mayor prioridad. Como no siempre es posible alcanzar todas las metas al grado en que desea quien toma las decisiones, la programación por metas intenta alcanzar un nivel satisfactorio de múltiples objetivos, lo cual, desde luego, difiere de la programación lineal, que trata de encontrar el mejor resultado posible con un solo objetivo. El ganador del premio Nobel de Economía, Herbert A. Simon, de la CarnegieMellon University, afirma que posiblemente los gerentes modernos no sean capaces de optimizar, sino que en cambio quizá tengan que “satisfacer” o “acercarse tanto como sea posible” al logro de sus metas. Es el caso con modelos tales como la programación por metas.

¿Específicamente cómo difiere la programación por metas de la programación lineal? La función objetivo es la diferencia principal. En vez de intentar maximizar o minimizar directamente la función objetivo, la programación por metas trata de minimizar las desviaciones entre las metas establecidas y las que en realidad se pueden lograr dentro de las restricciones dadas. En el método simplex de programación lineal, tales desviaciones reciben el nombre de variables de holgura y excedentes. Ya que el coeficiente de cada una de estas en la función objetivo es cero, las variables de holgura y las excedentes no afectan la solución óptima. En la programación por metas, las variables de desviación en general son las únicas variables en la función objetivo, y el objetivo es minimizar el total de esas variables de desviación. Cuando se formula el modelo de programación por metas, el algoritmo



computacional es casi el mismo que el de un problema de minimización resuelto por el método simplex.

#### **Conceptos Clave**

1. **Variables de Desviación:** Estas variables se utilizan para medir cuánto una solución se desvía de las metas establecidas. Existen dos tipos:
  - Desviación por debajo del objetivo (d-): Mide cuánto falta para alcanzar la meta.
  - Desviación por encima del objetivo (d+): Mide cuánto se excede la meta.
2. **Función Objetivo en Programación por Metas:** En lugar de maximizar o minimizar una única función, se busca minimizar la suma ponderada de las desviaciones de las metas. Esto puede implicar:
  - Minimizar solo las desviaciones por debajo del objetivo (d-).
  - Minimizar solo las desviaciones por encima del objetivo (d+).
  - Minimizar ambas desviaciones (d- y d+), dependiendo de la importancia que la organización asigne a cada tipo de desviación.
3. **Prioridades de las Metas:** En la programación por metas, las metas pueden tener diferentes niveles de prioridad. Las metas de mayor prioridad se consideran más importantes que las de menor prioridad. Si las metas tienen diferente prioridad, se les asignan ponderaciones diferentes en la función objetivo.

#### **Pronóstico**

Render, B. (2012) expresa: “Los gerentes tratan siempre de reducir la incertidumbre e intentan hacer mejores estimaciones de lo que sucederá en el futuro. Lograr esto es el objetivo principal de la elaboración de los pronósticos. Existen muchas formas de pronosticar el futuro. En muchas empresas (sobre todo las pequeñas), el proceso completo es subjetivo e incluye los métodos improvisados, la intuición y los años de experiencia. También existen muchos modelos de pronósticos cuantitativos, como promedios móviles, suavizamiento exponencial, proyecciones de tendencias y análisis de regresión por mínimos cuadrados.”

El autor en su libro considera tres tipos de modelos de pronósticos, en esta investigación aplicamos series de tiempo, el cual definió como: “Los modelos de series de tiempo intentan predecir el futuro usando datos históricos. Estos modelos suponen que lo que ocurra en el futuro es una función de lo que haya sucedido en el pasado.”

Además, Render, B. (2012) explica lo siguiente: “Cuando se analizan varios modelos de pronósticos diferentes para saber qué tan bien funciona un modelo o para comparar un modelo con otros, los valores pronosticados se comparan con los valores reales u observados. El error del pronóstico (o desviación) se define como:

*Error de pronóstico = valor real - valor pronosticado*

Una medida de exactitud es la **desviación media absoluta** (DMA), que se calcula tomando la suma de los valores absolutos de los errores de pronósticos individuales y, luego, dividiendo entre el número de errores (n):



$$DMA = \frac{\sum |\text{error del pronóstico}|}{n}$$

Un **promedio móvil ponderado** permite asignar diferentes pesos a las observaciones previas. Como el método de promedio móvil ponderado suele asignar mayor peso a las observaciones más recientes, este pronóstico es más sensible ante los cambios que ocurran en el patrón de los datos.

Un promedio móvil ponderado se expresa como

$$F_{t+1} = \frac{\sum (\text{peso del periodo } i)(\text{valor real de periodo } i)}{\sum (\text{pesos})}$$

Matemáticamente, esto es

$$F_{t+1} = \frac{w_1 Y_t + w_2 Y_{t-1} + \dots + w_n Y_{t-n+1}}{w_1 + w_2 + \dots + w_n}$$

donde

$$w_i = \text{peso para la } i\text{-ésima observación}$$

El **suavizamiento exponencial** es un método de pronósticos de uso sencillo y se maneja con eficiencia en la computadora. Aunque es un tipo de técnica de promedio móvil, necesita llevar un registro de los datos pasados.

La fórmula básica para el suavizamiento exponencial es:

Nuevo pronóstico = pronóstico del último periodo +  $\alpha$  (demanda real del último periodo – pronóstico del último periodo)

donde  $\alpha$  es un peso (o constante de suavizamiento) que tiene un valor entre 0 y 1, inclusive. La constante de suavizamiento, se puede modificar para dar más peso a los datos recientes con un valor alto o a los datos pasados cuando es bajo.

El **suavizamiento exponencial con ajuste de tendencia** establece que si hay una tendencia presente en los datos, debería usarse un modelo de pronóstico que la incorpore de manera explícita en el pronóstico. La idea es desarrollar un pronóstico de suavizamiento exponencial y, luego, ajustarlo por la tendencia. Se emplean dos constantes de suavizamiento en este modelo y ambos valores deben estar entre 0 y 1.

El nivel del pronóstico se ajusta multiplicando primero la constante de suavizamiento, por el error del pronóstico más reciente y sumarlo al pronóstico anterior. La tendencia se ajusta multiplicando la segunda constante de suavizamiento, por el error más reciente o la cantidad en exceso de la tendencia. Un valor más alto da más peso a las observaciones recientes y, con ello, responde con mayor rapidez a los cambios en los patrones.

En resumen,



Paso 1. Calcular el pronóstico suavizado ( $F_{t+1}$ ) para el periodo  $t + 1$  usando la ecuación

Pronóstico suavizado = pronóstico previo incluyendo tendencia +  $\alpha$ (último error)

$$F_{t+1} = FIT_t + \alpha(Y_t - FIT_t)$$

Paso 2. Actualizar la tendencia ( $T_{t+1}$ ) con la ecuación

Tendencia suavizada = tendencia previa +  $\beta$ (error o exceso de tendencia)

$$T_{t+1} = T_t + \beta(F_{t+1} - FIT_t)$$

Paso 3. Calcular el pronóstico de suavizado exponencial ajustado por la tendencia ( $FIT_{t+1}$ ) usando la ecuación

Pronóstico con tendencia ( $FIT_{t+1}$ ) = pronóstico suavizado ( $F_{t+1}$ ) + tendencia suavizada ( $T_{t+1}$ )

$$FIT_{t+1} = F_{t+1} + T_{t+1}$$

donde

$T_t$  = tendencia suavizada para el periodo  $t$

$F_t$  = pronóstico suavizado para el periodo  $t$

$FIT_t$  = Pronóstico incluyendo tendencia para el periodo  $t$

$\alpha$  = constante de suavizado para el pronóstico

$\beta$  = constante de suavizado para la tendencia

El **modelo ARIMA**, cuyas siglas provienen de **AutoRegressive Integrated Moving Average**, es una técnica estadística ampliamente utilizada para el análisis y pronóstico de series temporales. Este modelo fue desarrollado originalmente por Box y Jenkins (1970), y combina tres componentes fundamentales que permiten capturar distintas estructuras presentes en los datos temporales: un término autorregresivo (AR), un componente de integración (I) y un término de media móvil (MA).

El **componente autorregresivo (AR)**, representado por el parámetro  $p$ , modela la relación lineal entre el valor actual de la serie y sus propios valores pasados. Por ejemplo, un AR(2) asume que el valor presente depende de los dos valores anteriores, formalizado como:

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \varepsilon_t,$$

donde  $\phi_1$  y  $\phi_2$  son coeficientes del modelo, y  $\varepsilon_t$  es el término de error aleatorio.

El **componente integrado (I)**, indicado por el parámetro  $d$ , se refiere al número de diferenciaciones necesarias para convertir una serie no estacionaria (es decir, con tendencia o cambios en la varianza) en una serie estacionaria. Por ejemplo, si  $d = 1$ , se utiliza la primera diferencia ( $Y_t - Y_{t-1}$ ) para eliminar tendencias sistemáticas en los datos. Esta transformación es clave para cumplir con uno de los supuestos básicos de los modelos ARIMA: la estacionariedad.

Por su parte, el **componente de media móvil (MA)**, representado por el parámetro  $q$ , incorpora los errores pasados en la estimación del valor actual. Un modelo MA(2), por ejemplo, puede representarse como:

$$Y_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2},$$

donde  $\theta_1$  y  $\theta_2$  son parámetros del modelo que ponderan los errores de períodos anteriores.

Los modelos ARIMA se emplean en situaciones donde los datos presentan patrones complejos, como tendencias o ciclos, y requieren una estructura flexible para modelarlos adecuadamente. Esta versatilidad los convierte en una herramienta central en el análisis económico, financiero, demográfico y en general en cualquier campo donde se trabaje con datos cronológicos. Como señalan Box, Jenkins, Reinsel y Ljung (2016), "el modelo ARIMA proporciona una estructura sistemática para modelar la dinámica de series temporales con el fin de generar pronósticos confiables".



## FUENTE Y CAPTURA DE LOS DATOS

Para el desarrollo de esta investigación se utilizaron tanto **fuentes primarias** como **fuentes secundarias** de información.

- **Fuentes primarias:** se contó con **datos internos** de la empresa Cool Drinks Company (CDC), tales como la **Grilla de Repositores** y el **Maestro de Clientes**. Toda esta información fue proporcionada por un empleado de la Oficina de Supermercados Noa de CDC, quien cuenta con acceso autorizado a los sistemas de la empresa y conocimiento directo de la problemática abordada, a quien además se realizó una **entrevista semiestructurada**.

*Tabla 1: Maestro de cliente.*

Código de tienda	Cadena	Año	Sub-región	Local	Cadena	Sub-región	Tipo	Superficie (m <sup>2</sup> )	Dirección	Provincia	Zona	Etiquetas
1046	INTROH	0571	NDA	MA	Cadena 1	Sub-región 1	Regional	33	Calle SM TUC 500	Tucumán	Gran Tucumán	Farmacéutico-Repuestos
1048	INTROH	0571	NDA	MA	Cadena 2	Sub-región 2	Alayorquina	34	Calle SM TUC 500	Tucumán	Zona Sur	Derivados
1049	INTROH	0571	NDA	MA	Cadena 3	Sub-región 3	Regional	32	Calle SM TUC 500	Tucumán	Gran Tucumán	Repuestos
1049	INTROH	0571	NDA	MA	Cadena 4	Sub-región 4	Regional	36	Calle SM TUC 500	Tucumán	Zona Sur	Repuestos
1049	INTROH	0571	NDA	MA	Cadena 5	Sub-región 5	Nacional	27	Calle SM TUC 500	Tucumán	Gran Tucumán	Farmacéutico-Repuestos
1050	INTROH	0571	NDA	MA	Cadena 6	Sub-región 6	Nacional	38	Calle SM TUC 500	Tucumán	Zona Sur	Repuestos
1051	INTROH	0571	NDA	MA	Cadena 7	Sub-región 7	Nacional	33	Calle SM TUC 500	Tucumán	Gran Tucumán	Repuestos
1052	INTROH	0571	NDA	MA	Cadena 8	Sub-región 8	Nacional	38	Calle SM TUC 507	Tucumán	Zona Sur	Repuestos
1053	INTROH	0571	NDA	MA	Cadena 9	Sub-región 9	Nacional	23	Calle SM TUC 508	Tucumán	Gran Tucumán	Repuestos
1054	INTROH	0571	NDA	MA	Cadena 10	Sub-región 10	Nacional	22	Calle SM TUC 509	Tucumán	Zona Sur	Farmacéutico-Repuestos
1054	INTROH	0571	NDA	MA	Cadena 11	Sub-región 11	Nacional	33	Calle SM TUC 510	Tucumán	Gran Tucumán	Repuestos
1054	INTROH	0571	NDA	MA	Cadena 12	Sub-región 12	Nacional	34	Calle SM TUC 511	Tucumán	Zona Sur	Repuestos
1057	INTROH	0571	NDA	MA	Cadena 13	Sub-región 13	Nacional	29	Calle SM TUC 512	Tucumán	Gran Tucumán	Repuestos

Fuente: Elaboración Propia

*Tabla 2: Grilla de repositores*

Tienda	Cadena	Dirección	¿Reposición?	FIS Semanales	Nombre Repo
Tienda 1	Cadena 1	Calle SM TUC 500	Si	12	Repositor 1
Tienda 2	Cadena 2	Calle SM TUC 501	Si	25	Repositor 2
Tienda 3	Cadena 3	Calle SM TUC 502	Si	10	Repositor 3
Tienda 4	Cadena 4	Calle SM TUC 503	Si	4	Repositor 4
Tienda 5	Cadena 5	Calle SM TUC 504	Si	10	Repositor 5
Tienda 6	Cadena 6	Calle SM TUC 505	Si	10	Repositor 6
Tienda 7	Cadena 1	Calle SM TUC 506	Si	15	Repositor 2
Tienda 8	Cadena 2	Calle SM TUC 507	Si	20	Repositor 2
Tienda 9	Cadena 3	Calle SM TUC 508	Si	20	Repositor 4
Tienda 10	Cadena 4	Calle SM TUC 509	Si	12	Repositor 3
Tienda 11	Cadena 5	Calle SM TUC 510	Si	14	Repositor 1
Tienda 12	Cadena 6	Calle SM TUC 511	Si	12	Repositor 3
Tienda 13	Cadena 1	Calle SM TUC 512	Si	10	Repositor 6

Fuente: Elaboración Propia



- **Fuentes secundarias:** se utilizó un informe elaborado por una consultoras externas, el **Estudio de Share de Mercado** (fuente: **Scentia**), el cual aporta una visión complementaria sobre el desempeño de las marcas en las cadenas de supermercados.

*Tabla 3: Informe SOM Semanal - Scentia*

MERCADO	SOM CADENA 1		SOM CADENA 2		SOM CADENA 3		SOM CADENA 4		SOM CADENA 5		SOM CADENA 6	
	15	16	15	16	15	16	15	16	15	16	15	16
CDC	44,6%	51,2%	38,3%	44,0%	62,0%	55,6%	57,2%	61,0%	64,0%	31,8%	37,0%	37,0%
Merce 1	13,6%	13,8%	13,7%	13,0%	15,0%	13,8%	15,0%	15,0%	15,0%	13,8%	15,0%	15,0%
Merce 2	12,5%	12,5%	12,5%	12,5%	12,5%	12,5%	12,5%	12,5%	12,5%	12,5%	12,5%	12,5%
Merce 3	12,5%	12,5%	12,5%	12,5%	12,5%	12,5%	12,5%	12,5%	12,5%	12,5%	12,5%	12,5%

Fuente: Elaboración Propia

*Tabla 4: Tiendas WAR SMK NOA - Definido por Scentia*

Tiendas WAR						
SubRegión	ID Tienda WAR	Cadena	Cuadrante Matriz	SOM Actual (H1 2024)	SOM Objetivo (L E H1 2025)	Comentarios (opcional)
NOA	12340	Cadena 1	C1	50,0	60,0	Optimizar los de reposición, crecer FS negociando espacios con tienda.
NOA	12340	Cadena 2	B2	60,0	60,0	Consolidar FS y ADHOC, mantener alto NDS; explorar posibilidad de EDF.
NOA	12347	Cadena 3	B2	60,0	60,0	Potenciar ADHOC y EDF; sostener FS y NDS actuales.
NOA	12348	Cadena 4	B1	60,0	60,0	Reforzar FS y EDF; sostener 100% NDS y priorizar ejecución en góndola.
NOA	12349	Cadena 5	B2	60,0	60,0	Mejorar EDF; reforzar FS con tienda y mantener ADHOC actuales.
NOA	12350	Cadena 6	B2	60,0	60,0	Aumentar FS y EDF; buscar mayor presencia en góndola y puntos fríos.

Fuente: Elaboración Propia

La **captura de los datos** se realizó mediante **entrevistas y entrega de archivos por parte del empleado mencionado**, lo que garantizó tanto el acceso a información actualizada como la interpretación contextual necesaria para el análisis cuantitativo posterior.

## APLICACIÓN

### ENTREVISTA A SUPERVISOR DE SUPERMERCADOS

En el marco del estudio sobre la gestión comercial en el canal supermercados de empresas de consumo masivo, se llevó a cabo una entrevista con un supervisor del área correspondiente de Cool Drinks Company (CDC). La entrevista permitió conocer en profundidad las principales funciones y dinámicas que estructuran el trabajo del canal moderno en la región.



El supervisor es el principal responsable de la gestión comercial con las distintas cadenas de supermercados. Entre sus tareas se destacan la toma de pedidos, la negociación de precios y condiciones, así como la asignación de reposidores a cada tienda. Los reposidores, empleados directos de CDC, cumplen un rol clave en el punto de venta. Son los encargados de asegurar una reposición adecuada de productos, controlar los vencimientos, mantener actualizados los precios en góndola, y ejecutar la correcta exhibición de los productos mediante la instalación de materiales visuales como racks, islas y otros elementos que mejoran la visibilidad de la marca.

Se establece una relación directa entre la cantidad de horas de reposición asignadas y el desempeño comercial en el punto de venta. A mayor presencia del repositor, mayor es la probabilidad de que los productos de CDC sean elegidos por el consumidor, lo que se traduce en un mayor share o participación de mercado. Este indicador, medido semanalmente, está desagregado por cadena y no por tienda, aunque cada tienda está asociada a una de ellas. Las principales variables que influyen en el share son el precio y la ejecución, entendida esta última como la calidad del trabajo realizado en el punto de venta.

Un concepto estratégico dentro de la gestión son las tiendas WAR. Estas se caracterizan por tener un alto volumen total de venta de bebidas, pero una baja participación de CDC. Se consideran puntos de alto potencial de crecimiento, razón por la cual deben recibir una asignación prioritaria de horas de reposición con el objetivo de mejorar su ejecución y aumentar el share.

Desde el punto de vista organizativo, las tiendas se dividen en dos zonas geográficas: Gran Tucumán (GT) y Zona Sur (SZ), y cada repositor trabaja exclusivamente dentro de una de estas zonas. Las cadenas de supermercados se agrupan en tres tipos: nacionales, regionales y mayoristas. Actualmente, las cadenas mayoristas no cuentan con horas de reposición asignadas, situación que se considera subóptima y que se busca revertir.

Uno de los principales desafíos actuales del área es la subutilización de horas de reposición, lo cual implica una pérdida de oportunidades. Existe una cantidad de horas ociosas que podrían destinarse a tiendas WAR o a cadenas mayoristas para optimizar la ejecución general.

En cuanto a la gestión de promociones y descuentos, estas se negocian individualmente con cada cadena y están sujetas a un presupuesto limitado de trade spend, concepto que hace referencia a los fondos asignados para ofrecer precios especiales a las cadenas con el objetivo de que estos beneficios se trasladen al consumidor final. Por esta razón, es fundamental contar con información actualizada del share por cadena, de modo de priorizar adecuadamente los destinos del gasto promocional.

## **PROGRAMACIÓN LINEAL POR METAS**

A partir de la definición del problema se procedió a la modelización del mismo. Para ello, en primer lugar, se empleó un modelo de Programación Lineal por metas, utilizando la herramienta Solver para su solución. Cabe destacar que el modelo presentado constituye una simplificación de la situación real, con el objetivo de facilitar su formulación y análisis.



El objetivo es determinar la asignación óptima de horas de reposición que cada repositor dedicará a las distintas tiendas, buscando satisfacer las metas establecidas por la empresa.

**Metas del modelo:**

- 1- Se desea cumplir con un mínimo de horas semanales de reposición totales igual a 264
- 2- Lograr que las horas de reposición semanales en cada una de las tiendas WAR sean al menos 18
- 3- Dedicar al menos 4 horas de reposición semanales a las tiendas mayoristas

Los datos recolectados para el modelo implican: Cantidad de repositores que trabajan en el Gran Tucumán y en Zona Sur, cantidad de tiendas ubicadas también en estas zonas, características de cada tienda (Si son mayoristas, cadenas nacionales o regionales y tiendas WAR), horas de trabajo semanales disponibles por cada trabajador, información acerca de política de horas de reposición necesarias por tienda.

*Tabla 5: Datos generales*

<b>Datos</b>	
Tiendas en Tucumán	22
Repositores	6
Hs semanales por repositor	44
Hs semanales totales	<b>264</b>
Tiendas WAR	4
Tiendas mayoristas	2

Fuente: Elaboración propia

*Tabla 6: Datos de repositores*

<b>Grilla repositores:</b>	<b>Ubicación</b>	<b>Hs capacidad</b>
Repositor 1	GT	44
Repositor 2	GT	44
Repositor 3	GT	44
Repositor 4	GT	44
Repositor 5	SZ	44
Repositor 6	SZ	44

Fuente: Elaboración propia

*Tabla 7: Datos de las tiendas*



Tiendas	Zona	Tipo	¿Se trata de una tienda WAR?
Tienda 1	GT	Cadena nacional	
Tienda 2	GT	Cadena nacional	Si
Tienda 3	GT	Cadena regional	
Tienda 4	GT	Mayorista	
Tienda 5	GT	Cadena nacional	
Tienda 6	GT	Cadena nacional	
Tienda 7	GT	Cadena nacional	
Tienda 8	GT	Cadena nacional	
Tienda 9	GT	Mayorista	
Tienda 10	GT	Cadena regional	
Tienda 11	GT	Cadena nacional	
Tienda 12	GT	Cadena nacional	Si
Tienda 13	GT	Cadena nacional	
Tienda 14	GT	Cadena nacional	
Tienda 15	GT	Cadena nacional	
Tienda 16	GT	Cadena regional	
Tienda 17	SZ	Cadena nacional	Si
Tienda 18	SZ	Cadena regional	
Tienda 19	SZ	Cadena nacional	Si
Tienda 20	SZ	Cadena nacional	
Tienda 21	SZ	Cadena nacional	
Tienda 22	SZ	Cadena nacional	

Fuente: Elaboración propia

**Supuestos de modelo:**

- 1- A mayor cantidad de horas de reposición, mayor será el share of market de la tienda.
- 2- Los reposidores solo pueden desempeñarse en la zona a la que pertenecen:
  - ❖ Reposidores 1 a 4: Gran Tucumán (Tiendas 1 a 16)
  - ❖ Reposidores 5 y 6: Zona Sur (Tiendas 17 a 22)

**Variables de Decisión:**

- $X_{ij}$ : Horas semanales que dedica el repositor  $i$  a la tienda  $j$ .  
 Donde  $i=1, \dots, 6$  y  $j=1, \dots, 22$
- $dk$ : Desviación negativa respecto a la meta  $k$



- $dk+$ : Desviación positiva respecto a la meta  $k$   
Con  $k=1, \dots, 7$

### **Función Objetivo**

Minimizar los desvíos  $= (0 \times d1+) + (1 \times d1-) + (0 \times d2+) + (1 \times d2-) + (0 \times d3+) + (1 \times d3-) + (0 \times d4+) + (1 \times d4-) + (0 \times d5+) + (1 \times d5-) + (0 \times d6+) + (1 \times d6-) + (0 \times d7+) + (1 \times d7-)$

### **Restricciones:**

#### 1. Capacidad:

La restricción de capacidad semanales de horas normales de repositores se calculó teniendo en cuenta que los mismos trabajan 5 días a la semana 8 horas y los sábados 4 horas, lo que arroja un total de 44 horas semanales que dispone el repositor a la semana

$$\sum x1j \leq 44 \text{ horas}$$

$$\sum x2j \leq 44 \text{ horas}$$

$$\sum x3j \leq 44 \text{ horas}$$

$$\sum x4j \leq 44 \text{ horas}$$

$$\sum x5j \leq 44 \text{ horas}$$

$$\sum x6j \leq 44 \text{ horas}$$

$$j = 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16 \text{ para } x1j, x2j, x3j, x4j$$

$$j = 17, 18, 19, 20, 21, 22 \text{ para } x5j, x6j$$

#### 1. Política:

La empresa Cool Drinks Company mantiene vigente una política acerca de las horas semanales que se deben dedicar a las tiendas de cadenas nacionales y regionales, estableciendo que las horas de reposición en las mismas deben ser mayor o igual a 10.

$$\sum Xij \geq 10 \text{ horas}$$

Para  $i = 1, 2, 3, 4$  y  $j = 1, 2, 3, 5, 6, 7, 8, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22$

#### 2. No negatividad:

$$Xij \geq 0 \quad \forall i, j$$

$$dk-, dk+ \geq 0 \quad \forall k = 1, \dots, 7$$



**XVII Muestra Académica de Trabajos de Investigación  
 de la Licenciatura en Administración**

**Metas**

- 1- Se desea cumplir con un mínimo de horas semanales de reposición totales igual a 264

$$\sum X_{ij} - (d1+) + (d1-) = 264 \text{ horas semanales}$$

- 2- Lograr que las horas de reposición semanales en cada una de las tiendas WAR sean al menos 18

$$X_{12} + X_{22} + X_{32} + X_{42} - (d2+) + (d2-) = 18 \text{ horas}$$

$$X_{112} + X_{212} + X_{312} + X_{412} - (d3+) + (d3-) = 18 \text{ horas}$$

$$X_{517} + X_{617} - (d4+) + (d4-) = 18 \text{ horas}$$

$$X_{519} + X_{619} - (d5+) + (d5-) = 18 \text{ horas}$$

- 3- Dedicar al menos 4 horas de reposición semanales a las tiendas mayoristas

$$X_{12} + X_{22} + X_{32} + X_{42} - (d6+) + (d6-) = 4 \text{ horas}$$

$$X_{19} + X_{29} + X_{39} + X_{49} - (d7+) + (d7-) = 4 \text{ horas}$$

**Resultados del modelo:**

1. Cumplimiento de las metas

La solución óptima del modelo arrojó un valor de función objetivo igual a cero (FO = 0). Esto implica que no se produjeron desviaciones negativas respecto de las metas establecidas: todas las metas fueron alcanzadas en su totalidad.

1. Distribución de Horas

La asignación de las 264 horas disponibles fue equilibrada entre los seis repositores, respetando el máximo de 44 horas por persona.

*Tabla 8: Distribución de horas*

TIENDA/ REPOSITOR	T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12	T13	T14	T15	T16	T17	T18	T19	T20	T21	T22	Total horas por repositor	
Repositor 1	-	-	-	-	-	-	-	-	4	-	-	18	-	2	10	10	-	-	-	-	-	-	-	44
Repositor 2	-	-	-	-	-	-	-	6	-	10	10	-	10	8	-	-	-	-	-	-	-	-	-	44
Repositor 3	-	6	10	4	10	10	-	4	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	44
Repositor 4	10	12	-	-	-	-	22	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	44
Repositor 5	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	6	18	10	0	10	-	44
Repositor 6	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	18	4	-	-	22	-	-	44
Total horas por tienda	10	18	10	4	10	10	22	10	4	10	10	18	10	10	10	10	18	10	18	10	22	10	-	264



Fuente: Elaboración propia

El modelo desarrollado permitió una asignación óptima de las 264 horas semanales disponibles entre los seis repositores y las 22 tiendas distribuidas en el Gran Tucumán y la Zona Sur, respetando tanto las restricciones operativas como las metas definidas por la empresa. Se consideraron aspectos clave como la cobertura mínima en tiendas WAR y mayoristas, la segmentación geográfica de los trabajadores, y los requisitos establecidos para cadenas nacionales y regionales.

Los resultados obtenidos reflejan un desempeño altamente satisfactorio: **se cumplieron todas las metas propuestas sin generar desviaciones negativas**, lo cual indica que el esquema de asignación diseñado es plenamente viable desde el punto de vista operativo. Además, el uso completo de las 264 horas disponibles evidencia una utilización eficiente de los recursos, sin ociosidad ni sobrecarga.

### PRONÓSTICO

En primer lugar se lleva a cabo una etapa de análisis preliminar donde se analiza la evolución histórica del Share of Market (SOM) semanal de la empresa en las cadenas de supermercados durante el último año y medio.

El objetivo es identificar patrones, tendencias, estacionalidades y posibles puntos de quiebre o anomalías en la participación de mercado, que permitan comprender mejor los factores que explican su comportamiento y anticipar riesgos futuros. Así como también entender qué tipo de modelo se ajusta mejor a la serie de datos.

En primer lugar, se contrasta la evolución del SOM en las 6 cadenas de supermercado analizadas:

*Gráfico N 1: Gráficos de línea recta de las cadenas*





Fuente: Elaboración propia

#### **Análisis visual de gráficos:**

Al observar la evolución de la serie correspondiente a las 6 cadenas o marcas, a lo largo de 72 semanas, se puede señalar que **no se evidencia una tendencia definida**. Los valores de la serie fluctúan alrededor de un nivel promedio relativamente constante, sin mostrar un comportamiento claramente creciente ni decreciente.

En cuanto a la **estacionalidad**, el análisis gráfico no permite identificar patrones que se repitan de manera regular en intervalos fijos de tiempo. No se distinguen ciclos marcados o repeticiones evidentes cada cierto número de semanas que indiquen la existencia de estacionalidad fuerte. Por lo tanto, se concluye que, en caso de existir estacionalidad, esta sería **débil o no significativa visualmente**.

Respecto al componente **aleatorio o irregular**, la serie presenta fluctuaciones semana a semana que no siguen una estructura aparente. Estas variaciones parecen responder a factores externos o impredecibles, lo que indica la **presencia de ruido o variabilidad aleatoria**.

Por esto, el análisis comenzará aplicando modelos simples que se adecuen a la naturaleza estable y no estacional de la serie. En primer lugar, se utilizará el **suavizamiento exponencial simple**, dado que permite capturar el nivel promedio de la serie atenuando la variabilidad aleatoria observada. También se incluirá un modelo de **promedio móvil simple**, con una ventana de 3 o 4 semanas, como alternativa de comparación para evaluar la precisión de los



pronósticos. En caso de que, al explorar los datos en profundidad, se detecten indicios de estacionalidad leve, se podrá incorporar un modelo de **descomposición multiplicativa** con un ciclo corto, como el de 4 semanas, para verificar si mejora la capacidad predictiva del modelo.

Cabe destacar que el análisis se basa en **72 observaciones semanales para cada una de las seis cadenas analizadas**, y que estas presentan un **comportamiento muy similar entre sí a lo largo del tiempo**. Esta situación plantea un interrogante respecto a si realmente se asemeja el comportamiento entre las mismas o bien, si se debe a la forma de tratamiento de los datos. Además, al trabajar con datos semanales, es posible que **se pierda la oportunidad de detectar patrones más finos o ciclos de corta duración**, ya que la periodicidad elegida suaviza las fluctuaciones intra-semanales y puede limitar la sensibilidad de los modelos para captar estacionalidades menores o comportamientos diferenciados.

#### **Aplicación de modelos de pronóstico:**

Dado que la variable bajo análisis —el Share of Market (SOM) semanal por cadena— se comporta como una serie temporal univariada, inicialmente se optó por aplicar un modelo ARIMA (AutoRegressive Integrated Moving Average). Esta metodología es ampliamente utilizada en pronósticos de series temporales debido a su capacidad para modelar componentes autorregresivos, de tendencia e inercia estocástica. En este caso, el enfoque ARIMA se consideró adecuado para capturar la dinámica semanal del SOM, permitiendo anticipar posibles caídas en la participación de mercado.

Se procedió entonces a estimar modelos ARIMA(5,1,0) para cada una de las seis cadenas, evaluando tanto las métricas de ajuste como el comportamiento de los residuos. Si bien los modelos presentaron buenos resultados en términos estadísticos —cumpliendo con los supuestos de normalidad (Jarque-Bera), independencia (Ljung-Box) y homocedasticidad (ARCH)—, se identificaron limitaciones relevantes en el desempeño predictivo. Se observaron correlaciones negativas entre los valores reales y los pronosticados, indicando que el modelo no lograba captar correctamente la dirección de los movimientos del SOM. Esta falta de consistencia en el ajuste y la interpretación llevó a reconsiderar la estrategia de modelado.

Frente a estas limitaciones, se optó por evaluar modelos de suavizamiento exponencial con y sin tendencia, y de promedios móviles simples. Este enfoque resultó más adecuado para la dinámica observada, mostrando menor error medio absoluto (MAD) y mejor coherencia entre los pronósticos y la evolución real de la serie. A continuación se exponen los resultados obtenidos para cada cadena.

- **Cadena 1:**

*Tabla 9: Comparación de modelos para Cadena 1*



**XVII Muestra Académica de Trabajos de Investigación  
 de la Licenciatura en Administración**

CADENA 1				
MODELOS	MAD	MSE	MAPE	Forecast
PMS con N=3	4,983	39,415	7,21%	68,70
PMS con N=16	3,865	26,801	5,59%	71,09
SES con alfa=0,2	4,429	32,289	6,41%	69,55
SES con alfa=0,05	4,104	29,398	6,00%	71,29
HOLT con alfa=0,2 y beta=0,1	4,473	32,82	6,47%	69,33

Fuente: Elaboración propia.

Se evaluaron tres modelos de pronóstico: promedio móvil simple ( $n=3$  y  $n=16$ ), suavizamiento exponencial simple (SES con  $\alpha=0.2$  y  $\alpha=0.05$ ) y suavizamiento exponencial con tendencia (modelo de Holt con  $\alpha=0.2$  y  $\beta=0.1$ ). El modelo de promedio móvil simple con  $n=16$  resultó ser el que mejor se ajusta a la serie histórica, ya que minimiza el error medio absoluto (MAD) con un valor de 3.865, y un error porcentual medio absoluto (MAPE) de 5.53%. El modelo pronostica para la semana 21 del año 2025 una participación de mercado (SOM) de 71.09%.

- **Cadena 2:**

*Tabla 10: Comparación de modelos para Cadena 2*

CADENA 2				
MODELOS	MAD	MSE	MAPE	Forecast
PMS con N=5	4,222	25,617	6,04%	68,02
PMS con N=14	3,85	20,753	5,52%	69,53
SES con alfa=0,3	4,465	28,707	6,44%	66,86
SES con alfa=0,07	4,184	25,732	6,09%	70,14

Fuente: Elaboración propia.

Se evaluaron tres modelos de pronóstico: promedio móvil simple ( $n=5$  y  $n=14$ ), y suavizamiento exponencial simple (SES con  $\alpha=0.3$  y  $\alpha=0.07$ ). El modelo de promedio móvil simple con  $n=14$  resultó ser el que mejor se ajusta a la serie histórica, ya que minimiza el error medio absoluto (MAD) con un valor de 3.98, y un error porcentual medio absoluto (MAPE) de 5.52%. El modelo pronostica para la semana 21 del año 2025 una participación de mercado (SOM) de 69.53%.

- **Cadena 3:**

*Tabla 11: Comparación de modelos para Cadena 3*



**XVII Muestra Académica de Trabajos de Investigación  
 de la Licenciatura en Administración**

CADENA 3				
MODELOS	MAD	MSE	MAPE	Forecast
PMS con N=16	4,804	32,387	6,95%	70,64
PMS con N=4	4,784	37,698	6,90%	71,50
SES con alfa=0,5	4,74	34,884	6,83%	71,54
SES con alfa=0,8	5,14	40,476	7,39%	71,57
HOLT con alfa=0,2 y beta=0,1	4,504	31,402	6,51%	70,96

Fuente: Elaboración propia.

Se evaluaron tres modelos de pronóstico: promedio móvil simple (n=4), suavizamiento exponencial simple (alfa=0,5) y suavizamiento exponencial con tendencia (modelo de Holt). El modelo de Holt, con parámetros alfa=0,2 y beta=0,1, resultó ser el que mejor se ajusta a la serie histórica, ya que minimiza el error medio absoluto (MAD), obteniéndose un valor de 4,50%, y un error porcentual medio absoluto (MAPE) de 6,51%. El modelo pronostica para el próximo periodo una participación de mercado (SOM) de 70,96%.

- **Cadena 4:**

*Tabla 12: Comparación de modelos para Cadena 4*

CADENA 4				
MODELOS	MAD	MSE	MAPE	Forecast
PMS con N=4	4,298	25,584	6,11%	69,835
SES con alfa=0,5	4,453	29,468	6,32%	68,363
HOLT con alfa=0,2 y beta=0,1	4,166	23,922	5,92%	69,914

Fuente: Elaboración propia.

Se siguió un análisis similar con los mismos modelos y parámetros (Holt con alfa=0,2 y beta=0,1). El mejor ajuste también corresponde al modelo de Holt, con un MAD de 4,78% y un MAPE del 5,92%, proyectando para el siguiente periodo una participación de mercado del 69,91%. El modelo busca capturar tanto el nivel como la tendencia subyacente de la serie, ofreciendo pronósticos más robustos frente a cambios suaves en el mercado.

- **Cadena 5:**

*Tabla 13: Comparación de modelos para Cadena 5*



**XVII Muestra Académica de Trabajos de Investigación  
 de la Licenciatura en Administración**

CADENA 5				
MODELOS	MAD	MSE	MAPE	Forecast
PMS con N=5	4,17	25,45	5,91%	70,64
PMS con N=9	4,01	23,71	5,70%	71,50
SES con alfa=0,25	4,06	24,43	5,76%	71,54
SES con alfa=0,01	3,96	21,80	5,60%	71,57
HOLT con alfa=0,25 y beta=0,1	4,15	25,76	5,89%	70,96

Fuente: Elaboración propia.

Para la Cadena 5, el modelo que ofrece el mejor desempeño es el Suavizamiento Exponencial Simple (SES) con  $\alpha = 0,01$ , ya que presenta los menores errores (MAD: 3,96; MSE: 21,80; MAPE: 5,60%) en comparación con el Promedio Móvil Simple (PMS) con N=5 y N=9, el SES con  $\alpha = 0,25$  y el modelo de Holt con  $\alpha = 0,25$  y  $\beta = 0,1$ ; por lo tanto, se considera el más adecuado para el pronóstico, estimando un valor para el próximo período de 71,38%.

- **Cadena 6:**

*Tabla 14: Comparación de modelos para Cadena 6*

CADENA 6				
MODELOS	MAD	MSE	MAPE	Forecast
PMS con N=3	5,09	37,60	7,43%	72,00
PMS con N=12	4,47	28,01	6,40%	74,87
SES con alfa=0,2	4,56	30,83	6,64%	73,48
SES con alfa=0,14	4,59	31,14	6,68%	73,57
HOLT con alfa=0,20 y beta=0,15	4,81	33,95	6,98%	74,84

Fuente: Elaboración propia.

El modelo que presenta el mejor desempeño es el Promedio Móvil Simple (PMS) con N=12, ya que muestra los errores más bajos en comparación con el resto de los modelos evaluados (MAD: 4,47; MSE: 28,01; MAPE: 6,40%). Frente al PMS con N=3, los modelos de Suavizamiento Exponencial Simple (SES) con  $\alpha=0,2$  y  $\alpha=0,14$ , y el modelo de Holt con  $\alpha=0,2$  y  $\beta=0,15$ , el PMS con N=12 resulta el más adecuado para realizar el pronóstico, estimando un valor para el próximo período de 74,87%.

**Conclusiones a partir de los pronósticos realizados:**

**1. CDC presenta una participación de mercado estable con una ligera tendencia**

- Las cadenas analizadas evidencian una participación de mercado relativamente estable, con una **tendencia suave hacia niveles cercanos al 70%**. Esto indica que su posición competitiva se encuentra consolidada. Sin embargo, se han observado variaciones de hasta un 10% tanto a la baja como al alza.
- En consecuencia, es fundamental anticipar y prevenir posibles caídas para implementar dinámicas que contrarresten dichos efectos. De igual forma,



cuando se detecten tendencias al alza, será oportuno potenciar las dinámicas para aprovechar el crecimiento y maximizar la participación de mercado.

- Las dinámicas más frecuentes deben emplearse de manera estratégica, orientadas a mantener o incrementar la participación en períodos específicos de baja estacionalidad o ante la presencia de competencia agresiva.

## **2. Consideraciones para la asignación de dinámicas**

- Es imprescindible monitorear de forma continua la tendencia de la participación de mercado. En caso de observar una tendencia decreciente, se deberá aumentar la intensidad o frecuencia de los descuentos para recuperar cuota.
- Al mismo tiempo, es importante evaluar la elasticidad de la demanda respecto a los descuentos, ya que, si las ventas responden favorablemente, estas dinámicas serán una herramienta eficaz; en caso contrario, podrían resultar innecesarias o incluso contraproducentes.
- Es clave integrar estos pronósticos con análisis competitivos y del entorno del mercado, incorporando nuevas variables que permitan tomar decisiones más fundamentadas.

## **CONCLUSIONES**

Finalizado el trabajo, tras haber aplicado programación lineal por metas, se ha diseñado una asignación óptima de las horas semanales de los reposidores de Cool Drinks Company, logrando cumplir de manera integral todas las metas establecidas, mientras se respetan las restricciones de capacidad y las políticas organizacionales. Esta solución asegura una utilización del 100% de las horas de reposición semanales disponibles, asigna al menos 18 horas a las tiendas WAR, de manera que se pueda aprovechar el potencial de crecimiento en las mismas, y dedica un mínimo de 4 horas a las tiendas mayoristas. También cumple con el requisito de 10 horas semanales para tiendas de cadenas nacionales y regionales.

La asignación estratégica, fundamentada en el supuesto de que más horas de reposición incrementan el *share of market* (SOM), maximiza la eficiencia al considerar las zonas de los reposidores —Gran Tucumán y Zona Sur— y las necesidades específicas de cada tienda. Así, esta propuesta no solo optimiza el uso de las 44 horas semanales disponibles por repositor, sino que también impulsa el SOM de manera sostenible y rentable, reflejando una gestión efectiva y alineada con los objetivos empresariales.

Por otro lado, se aplicaron herramientas cuantitativas que permiten optimizar el *Share of Market* (SOM) de una empresa CDC, mejorando su desempeño en el canal supermercados a través de una asignación más eficiente de recursos promocionales. En particular, mediante la implementación de modelos de pronóstico como el suavizamiento exponencial con tendencia (modelo de Holt) y el promedio móvil simple, se busca pronosticar variaciones semanales en la participación de mercado por cadena, lo que permite identificar con antelación caídas potenciales en el SOM y focalizar acciones correctivas. Este abordaje cuantitativo, facilita una gestión más estratégica y proactiva de las dinámicas comerciales.



La capacidad de pronosticar comportamientos futuros en el mercado se convierte en un activo clave para la toma de decisiones en entornos altamente competitivos. En este contexto, la asignación de descuentos debe ser dinámica y sustentada en evidencia cuantitativa sobre el comportamiento histórico y esperado del mercado, con el fin de maximizar la rentabilidad y la participación, evitando a su vez políticas promocionales excesivas que conduzcan a guerras de precios insostenibles. La integración de estos modelos predictivos en la gestión comercial contribuye a una mejor utilización de los recursos críticos de la empresa, permitiendo reaccionar con agilidad frente a cambios en la dinámica competitiva y consolidar una posición sólida en los puntos de venta estratégicos.

## **APÉNDICE**

### Entrevista a Supervisor de supermercados (SPV) de Cool Drinks Company:

1. ¿Cuál es tu rol dentro de Cool Drinks Company, específicamente en el canal de supermercados?
2. ¿Qué tareas realiza un repositor de CDC en el punto de venta?
3. ¿Qué relación hay entre el trabajo del repositor y el desempeño de CDC en el supermercado?
4. ¿Cómo miden ese share y qué variables lo afectan?
5. ¿Qué son las tiendas "WAR" y qué importancia tienen?
6. ¿Cómo se organiza geográficamente el trabajo de los repositores?
7. ¿Qué tipos de cadenas manejan y cómo impacta eso en la gestión?
8. Mencionaste problemas con la distribución de horas de reposición, ¿cómo afecta eso al desempeño?
9. ¿Cómo se definen las acciones promocionales o descuentos que hace CDC?
10. ¿Podrías explicar qué es el trade spend?

## **ANEXO**

### **Evaluación del modelo ARIMA como alternativa inicial**

Con el objetivo de identificar el modelo más adecuado para pronosticar el SOM, se evaluó inicialmente la aplicación de un modelo ARIMA(5,1,0) para cada cadena. A continuación, se presentan los resultados del desempeño predictivo del modelo en cada caso:

*Tabla 6: Indicadores principales modelo ARIMA*



**XVII Muestra Académica de Trabajos de Investigación  
 de la Licenciatura en Administración**

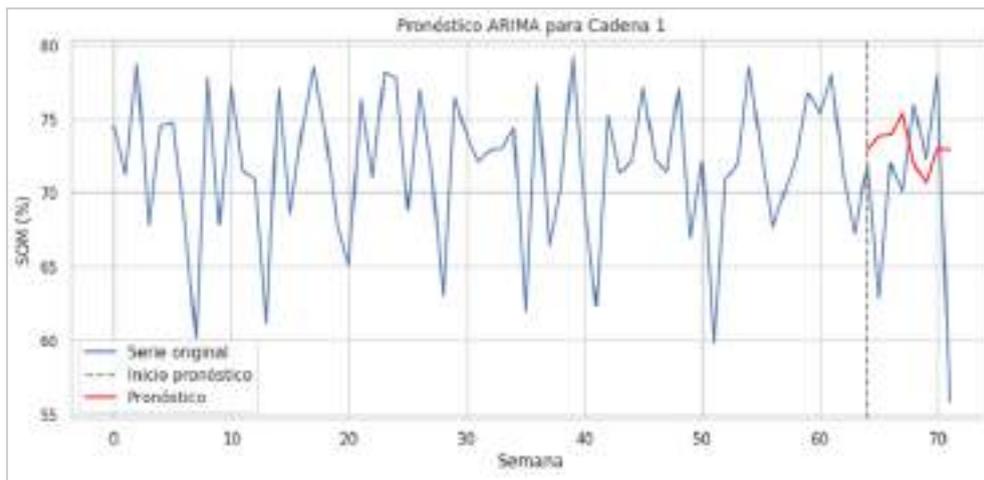
Cadena	MAE	RMSE	MAD	Correlación	Jarque-Bera p-valor	Ljung-Box p-valor	ARCH p-valor
Cadena 1	5.867	7.815	5.867	-0.203	0.658651	0.294221	0.604580
Cadena 2	5.727	6.339	5.727	-0.266	0.596177	0.399500	0.727696
Cadena 3	3.250	3.724	3.250	-0.222	0.833960	0.362254	0.238484
Cadena 4	2.929	3.678	2.929	0.019	0.822994	0.020421	0.997409
Cadena 5	3.432	3.936	3.432	0.583	0.699279	0.555077	0.848393
Cadena 6	3.576	4.638	3.576	0.218	0.666647	0.753603	0.417667

Fuente: Elaboración propia

A pesar de que los tests aplicados (Jarque-Bera, Ljung-Box y ARCH) mostraron p-valores mayores a 0.05 en todos los casos, lo que indica que los residuos del modelo cumplen los supuestos de normalidad, independencia y homocedasticidad. Sin embargo, estos resultados no fueron suficientes para validar su aplicación práctica, ya que el modelo presentó inconsistencias en la dirección del pronóstico y baja correlación con los valores reales. En particular, **las cadenas 1, 2 y 3 mostraron correlaciones negativas**, lo que indica que el modelo ARIMA no capturó correctamente la dirección de los movimientos del SOM.

A continuación, se adjuntan las salidas de python al aplicar el modelo ARIMA para determinar los pronósticos del SOM en CDC:

Gráfico 1: Pronóstico de SOM con ARIMA



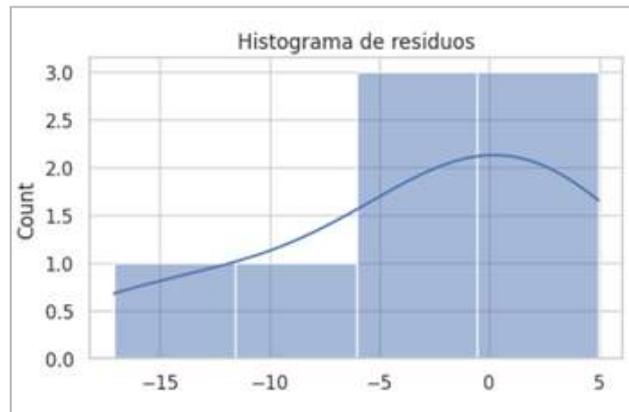
Fuente: Elaboración propia con Python

Muestra la serie histórica completa del Share of Market (SOM) de la Cadena 1, donde la línea azul representa los valores reales semanales, la línea punteada gris indica el punto de corte entre el período de entrenamiento y el de pronóstico, y la línea roja muestra los valores pronosticados por el modelo ARIMA(5,1,0) para las semanas restantes.



Se observa que el modelo tiende a suavizar la serie y no capta completamente las fluctuaciones abruptas, lo que explica su desempeño limitado.

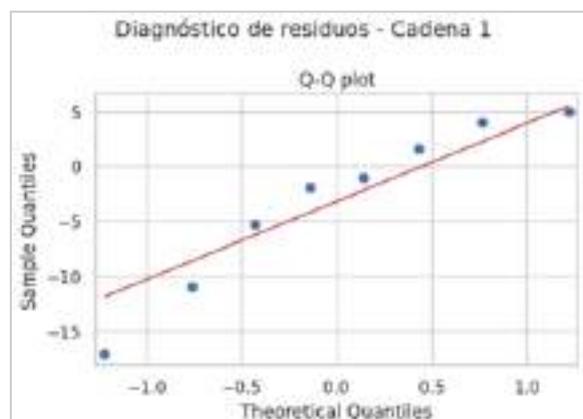
Gráfico 2: *Histograma de residuos*



Fuente: Elaboración propia con Python

Representa la distribución de los errores (residuos) entre los valores reales y los pronosticados. Muestra una asimetría leve y algunos valores atípicos (outliers), aunque sin violar gravemente la normalidad.

Gráfico 3: *Q-Q Plot (Quantile-Quantile)*



Fuente: Elaboración propia con Python

Compara los residuos con una distribución normal teórica. Si los puntos se alinearan sobre la línea roja, indicaría normalidad perfecta. Aquí se aprecia cierta desviación, aunque dentro de rangos aceptables.

Gráfico 4: *Residuos en el tiempo*



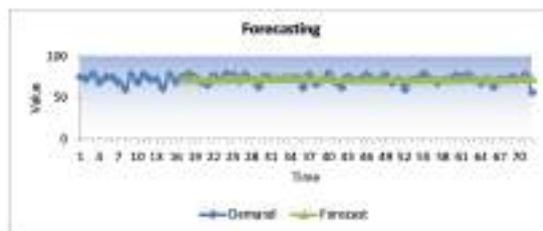
Fuente: Elaboración propia con Python

Muestra la evolución temporal de los residuos. Sirve para verificar si hay patrones persistentes no capturados por el modelo. En este caso, los residuos fluctúan alrededor de cero sin tendencia clara, lo que indica independencia, aunque con algunos picos extremos.

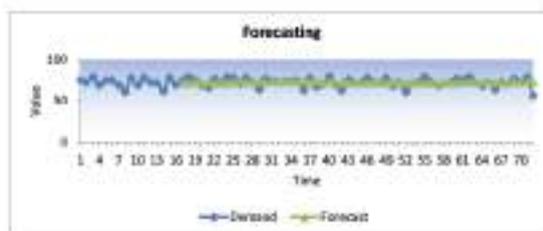
**Comparación de Modelos de pronósticos:**

**CADENA 1**

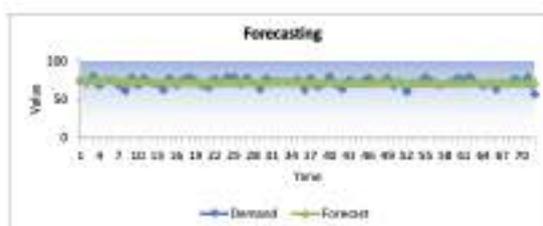
PMS con N=8	
Measure	Value
Error Measures	
Bias (Mean Error)	-0.277
<b>MAD (Mean Absolute Deviation)</b>	<b>4.983</b>
MSE (Mean Squared Error)	39.415
Standard Error (denominator=2+67)	8.371
MAPE (Mean Absolute Percent Error)	7.21%
Forecast	
next period	68.703



PMS con N=16	
Measure	Value
Error Measures	
Bias (Mean Error)	-0.045
<b>MAD (Mean Absolute Deviation)</b>	<b>3.663</b>
MSE (Mean Squared Error)	26.801
Standard Error (denominator=2+64)	5.272
MAPE (Mean Absolute Percent Error)	5.59%
Forecast	
next period	71.09

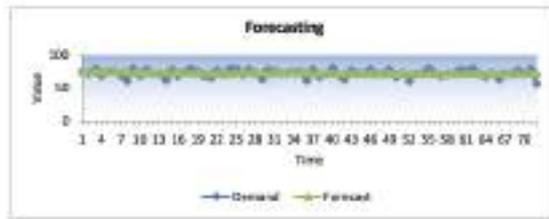


MS con alpha=0.2	
Measure	Value
Error Measures	
Bias (Mean Error)	-0.249
<b>MAD (Mean Absolute Deviation)</b>	<b>4.425</b>
MSE (Mean Squared Error)	52.289
Standard Error (denominator=2+69)	7.265
MAPE (Mean Absolute Percent Error)	6.41%
Forecast	
next period	68.551

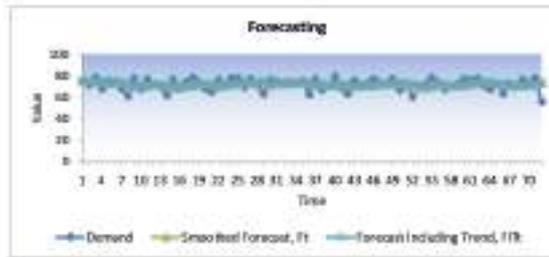




SES con $\alpha=0,95$	
Measure	Value
Error Measure	
Bias (Mean Error)	-0,905
<b>MAD (Mean Absolute Deviation)</b>	<b>4,194</b>
MSE (Mean Squared Error)	29,398
Standard Error (denom=2+89)	5,5
MAPE (Mean Absolute Percent Error)	6,00%
Forecast	
next period	71,286



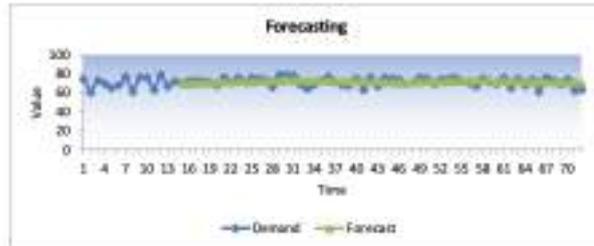
SES con $\alpha=0,1$ y $\beta=0,1$	
Measure	Value
Error Measure	
Bias (Mean Error)	-0,31
<b>MAD (Mean Absolute Deviation)</b>	<b>4,473</b>
MSE (Mean Squared Error)	32,82
Standard Error (denom=2+89)	5,813
MAPE (Mean Absolute Percent Error)	6,47%
Forecast	
next period	89,31



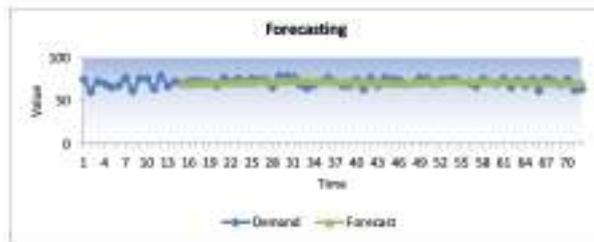
**CADENA 2**



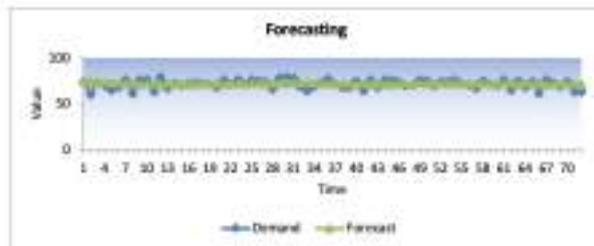
FMS con $\alpha=0.5$	
Measure	Value
Error Measures	
Bias (Mean Error)	-0,052
<b>MAD (Mean Absolute Deviation)</b>	<b>4,222</b>
MSE (Mean Squared Error)	25,617
Standard Error (denominator=65)	5,139
MAPE (Mean Absolute Percent Error)	6,04%
Forecast	
next period	66,016



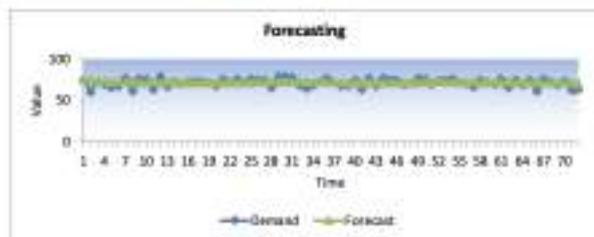
FMS con $\alpha=0.4$	
Measure	Value
Error Measures	
Bias (Mean Error)	-0,223
<b>MAD (Mean Absolute Deviation)</b>	<b>3,85</b>
MSE (Mean Squared Error)	20,753
Standard Error (denominator=66)	4,636
MAPE (Mean Absolute Percent Error)	5,52%
Forecast	
next period	66,53



SES con $\alpha=0.3$	
Measure	Value
Error Measures	
Bias (Mean Error)	-0,343
<b>MAD (Mean Absolute Deviation)</b>	<b>4,455</b>
MSE (Mean Squared Error)	28,707
Standard Error (denominator=65)	5,435
MAPE (Mean Absolute Percent Error)	6,44%
Forecast	
next period	66,863



SES con $\alpha=0.07$	
Measure	Value
Error Measures	
Bias (Mean Error)	-0,809
<b>MAD (Mean Absolute Deviation)</b>	<b>4,184</b>
MSE (Mean Squared Error)	25,732
Standard Error (denominator=69)	5,146
MAPE (Mean Absolute Percent Error)	6,09%
Forecast	
next period	70,139

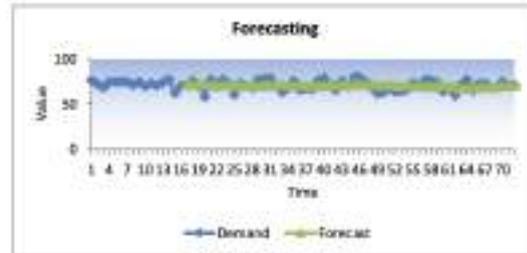


**CADENA 3**

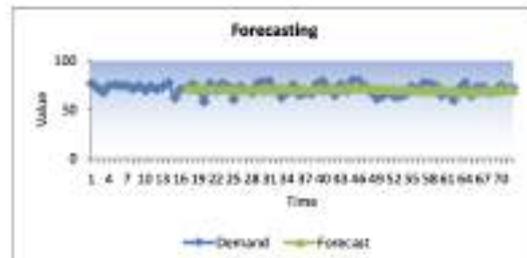


**XVII Muestra Académica de Trabajos de Investigación  
 de la Licenciatura en Administración**

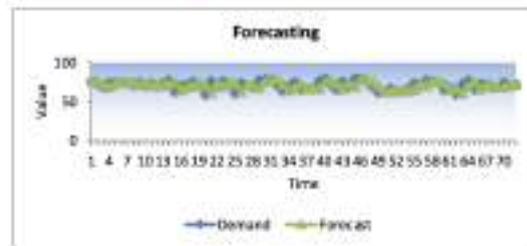
FMS con $n=36$	
Error Measures	
Bias (Mean Error)	0,161
<b>MAD (Mean Absolute Deviation)</b>	<b>4,80</b>
MSE (Mean Squared Error)	32,39
Standard Error (denom=n-2=54)	5,80
MAPE (Mean Absolute Percent Error)	5,949%
Forecast	
next period	70,616



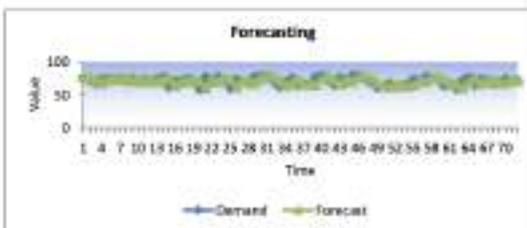
FMS con $n=64$	
Error Measures	
Bias (Mean Error)	-0,009
<b>MAD (Mean Absolute Deviation)</b>	<b>4,78</b>
MSE (Mean Squared Error)	37,70
Standard Error (denom=n-2=54)	6,23
MAPE (Mean Absolute Percent Error)	6,899%
Forecast	
next period	71,495



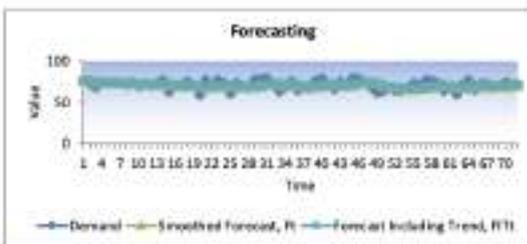
SES con $\alpha=0,5$	
Error Measures	
Bias (Mean Error)	-0,133
<b>MAD (Mean Absolute Deviation)</b>	<b>4,74</b>
MSE (Mean Squared Error)	34,88
Standard Error (denom=n-2=54)	5,99
MAPE (Mean Absolute Percent Error)	5,825%
Forecast	
next period	71,541



SES con $\alpha=0,8$	
Error Measures	
Bias (Mean Error)	0,083
<b>MAD (Mean Absolute Deviation)</b>	<b>5,14</b>
MSE (Mean Squared Error)	40,48
Standard Error (denom=n-2=54)	6,45
MAPE (Mean Absolute Percent Error)	7,387%
Forecast	
next period	71,567



SES con tendencia con $\alpha=0,2$ y $\beta=0,1$	
Error Measures	
Bias (Mean Error)	0,291
<b>MAD (Mean Absolute Deviation)</b>	<b>4,50</b>
MSE (Mean Squared Error)	31,40
Standard Error (denom=n-2=54)	5,68
MAPE (Mean Absolute Percent Error)	6,506%
Forecast	
next period	70,963

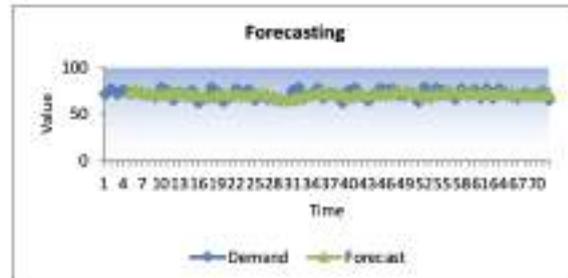


**CADENA 4**

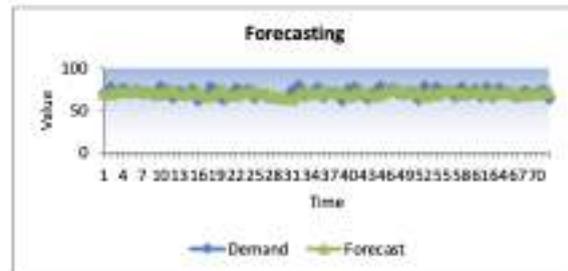


**XVII Muestra Académica de Trabajos de Investigación  
 de la Licenciatura en Administración**

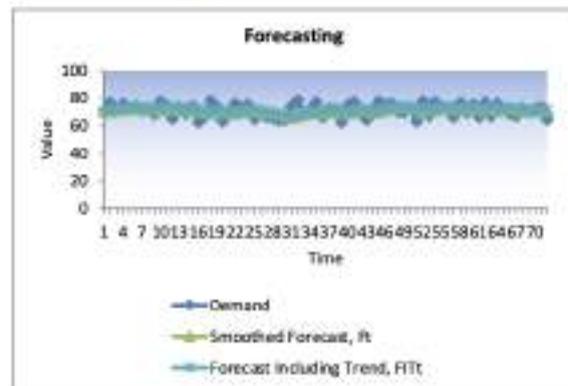
PMS con n=4	
<u>Error Measures</u>	
Bias (Mean Error)	-0,18
<b>MAD (Mean Absolute Deviation)</b>	<b>4,30</b>
MSE (Mean Squared Error)	25,58
Standard Error (denom=n-2=54)	5,13
MAPE (Mean Absolute Percent Error)	6,110%
<u>Forecast</u>	
next period	<b>69,835</b>



SES con a=0,5	
<u>Error Measures</u>	
Bias (Mean Error)	-0,057
<b>MAD (Mean Absolute Deviation)</b>	<b>4,65</b>
MSE (Mean Squared Error)	29,47
Standard Error (denom=n-2=54)	5,51
MAPE (Mean Absolute Percent Error)	6,322%
<u>Forecast</u>	
next period	<b>68,363</b>



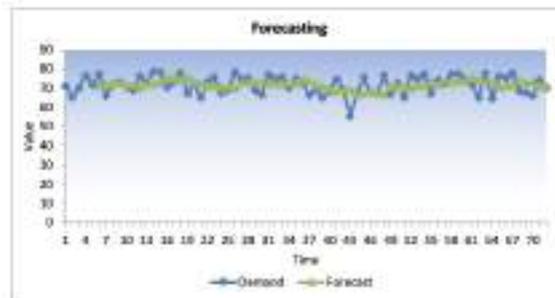
SES con tendencia con a=0,2 y beta=0,1	
<u>Error Measures</u>	
Bias (Mean Error)	-0,037
<b>MAD (Mean Absolute Deviation)</b>	<b>4,17</b>
MSE (Mean Squared Error)	23,92
Standard Error (denom=n-2=54)	4,95
MAPE (Mean Absolute Percent Error)	5,924%
<u>Forecast</u>	
next period	<b>69,914</b>



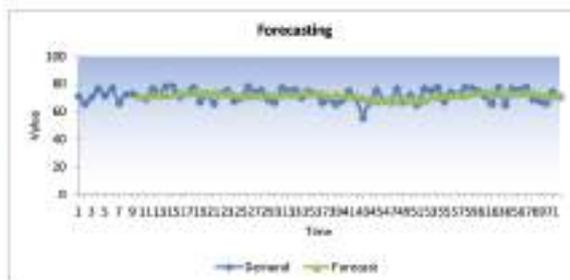
**CADENA 5**



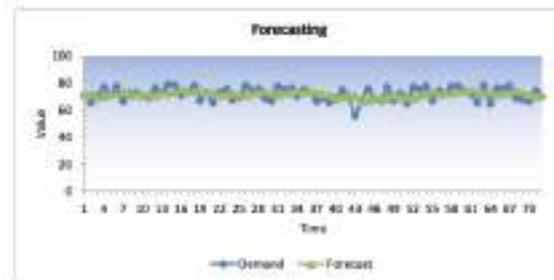
PMS con N=5	
Measure	Value
Error Measure	
Bias (Mean Error)	-0,079781343
<b>MAD (Mean Absolute Deviation)</b>	<b>4,286856718</b>
MSE (Mean Squared Error)	25,45248549
Standard Error (degrees=2=47)	5,033074093
MAPE (Mean Absolute Percent Error)	5,913%
Forecast	
next period	69,262



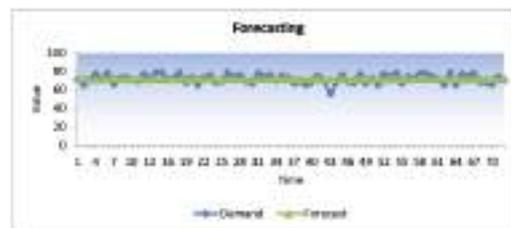
PMS con N=6	
Measure	Value
Error Measure	
Bias (Mean Error)	-0,081798947
<b>MAD (Mean Absolute Deviation)</b>	<b>4,32287479</b>
MSE (Mean Squared Error)	22,71246181
Standard Error (degrees=2=54)	4,348833454
MAPE (Mean Absolute Percent Error)	5,70%
Forecast	
next period	71,18888889



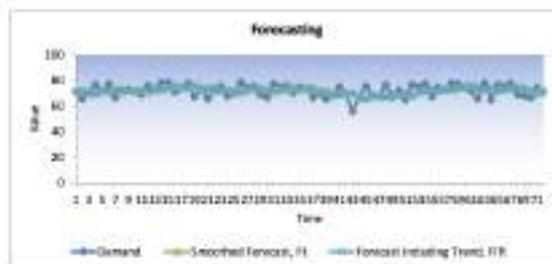
SES con alpha=0,25	
Measure	Value
Error Measure	
Bias (Mean Error)	-0,079144687
<b>MAD (Mean Absolute Deviation)</b>	<b>4,260478695</b>
MSE (Mean Squared Error)	24,44281905
Standard Error (degrees=2=63)	5,13301773
MAPE (Mean Absolute Percent Error)	5,76%
Forecast	
next period	70,88339565



SES con alpha=0,01	
Measure	Value
Error Measure	
Bias (Mean Error)	0,061964731
<b>MAD (Mean Absolute Deviation)</b>	<b>3,957181185</b>
MSE (Mean Squared Error)	21,80188465
Standard Error (degrees=2=69)	4,759280654
MAPE (Mean Absolute Percent Error)	5,60%
Forecast	
next period	71,3794628

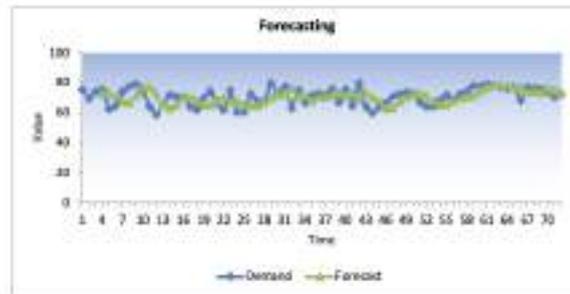


SES con alpha=0,25 y beta=0,1	
Measure	Value
Error Measure	
Bias (Mean Error)	-0,079094703
<b>MAD (Mean Absolute Deviation)</b>	<b>4,145646797</b>
MSE (Mean Squared Error)	25,76004364
Standard Error (degrees=2=69)	5,147430950
MAPE (Mean Absolute Percent Error)	5,89%
Forecast	
next period	70,78154413

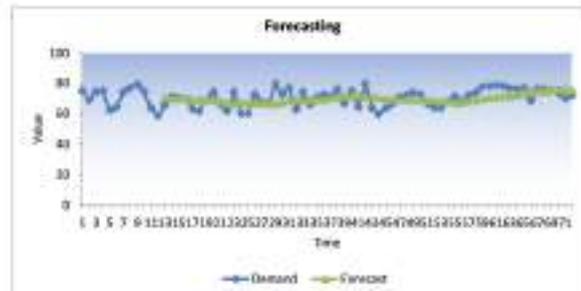




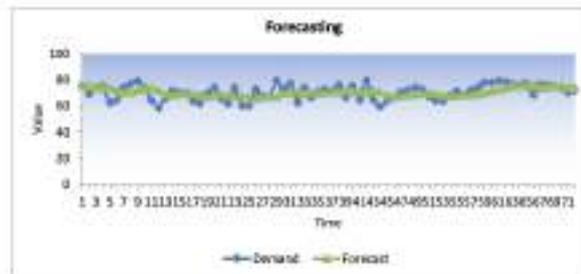
FMS con N=8	
Measure	Value
Error Mean Error	-0,03271988
Bias (Mean Error)	-0,03271988
<b>MAD (Mean Absolute Deviation)</b>	<b>5,085802174</b>
MSE (Mean Squared Error)	17,59866329
Standard Error (descomin=2=67)	6,222620948
MAPE (Mean Absolute Percent Error)	7,43%
Forecast	
next period	72,08333333



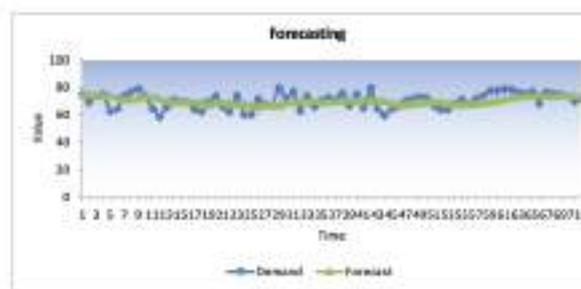
FMS con N=12	
Measure	Value
Error Mean Error	0,468732222
Bias (Mean Error)	0,468732222
<b>MAD (Mean Absolute Deviation)</b>	<b>4,403666667</b>
MSE (Mean Squared Error)	18,06631405
Standard Error (descomin=2=54)	5,382568998
MAPE (Mean Absolute Percent Error)	6,80%
Forecast	
next period	74,86916667



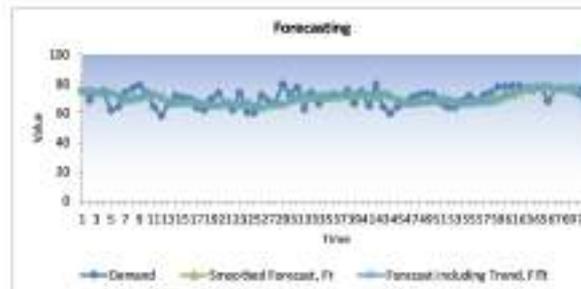
SES con alpha=0,2	
Measure	Value
Error Mean Error	-0,10660283
Bias (Mean Error)	-0,10660283
<b>MAD (Mean Absolute Deviation)</b>	<b>4,55558755</b>
MSE (Mean Squared Error)	10,82839152
Standard Error (descomin=2=63)	5,831174693
MAPE (Mean Absolute Percent Error)	6,64%
Forecast	
next period	73,88480889



SES con alpha=0,34	
Measure	Value
Error Mean Error	-0,14730589
Bias (Mean Error)	-0,14730589
<b>MAD (Mean Absolute Deviation)</b>	<b>4,386837718</b>
MSE (Mean Squared Error)	11,24128544
Standard Error (descomin=2=63)	5,458596664
MAPE (Mean Absolute Percent Error)	6,88%
Forecast	
next period	75,88616667



SES con alpha=0,2 y beta=0,15	
Measure	Value
Error Mean Error	-0,03771325
Bias (Mean Error)	-0,03771325
<b>MAD (Mean Absolute Deviation)</b>	<b>4,814282683</b>
MSE (Mean Squared Error)	13,35462969
Standard Error (descomin=2=63)	5,908717587
MAPE (Mean Absolute Percent Error)	6,88%
Forecast	
next period	74,8369244





---

## FUENTES BIBLIOGRÁFICAS

- Hernández Sampieri, R., Fernández Collado, C., & Baptista Lucio, P (2018). Metodología de la investigación. Mac Graw Hill.
- Levin, R. I., & Rubin, D. S. (2012). Statistics for Management. Pearson Education.
- Render, B., Stair, R.M., & Hanna, M.E. (2013). Métodos cuantitativos para los negocios (12ª ed.). Pearson Educación.
- Rodríguez, J., & Gomez, M. (2020). Análisis cuantitativo de negocios: Métodos y aplicaciones. Revista de Administración de Empresas, 45(2), 73-89.
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2016). *Time series analysis: Forecasting and control* (5th ed.). Wiley.