



**Universidad
de Valparaíso**
CHILE

FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA INDUSTRIAL

**Desarrollo de un prototipo de Sistema Predictivo de Ventas de Pisco
Mistral en CPCh**

**Trabajo de Título para la asignatura Taller de Integración de
Ingeniería Industrial III**

Marcelo Alvarado

Prof. guía: Dr. Filadelfo de Mateo

Julio, 2025

índice

1. Introducción	3
2. Contenido y Desarrollo del Problema	4
3. Objetivos	5
3.1. Objetivo General.....	5
3.2. Objetivos Específicos.....	5
4. Marco Teórico / Estado del Arte.....	6
4.1. Inteligencia Comercial y Toma de Decisiones	6
4.2. Series de Tiempo y Forecasting	6
4.3. Segmentación de Clientes.....	7
4.4. Visualización de Datos y Herramientas de Apoyo.....	7
5. Propuesta Metodológica.....	8
5.1. Limpieza de datos y análisis exploratorio.....	8
5.2. Modelamiento de series de tiempo (forecasting)	8
5.3. Segmentación de clientes (clustering).....	8
5.4. Visualización e integración	9
6. Aplicación Metodológica.....	10
6.1 Filtrado de datos históricos.....	10
6.2 Construcción de variables de análisis por cliente	11
6.3 Modelamiento de demanda con Prophet	11
6.4 Segmentación de clientes con K-means	12
6.5 Integración de resultados en dashboard interactivo	13
7. Resultados	15
7.1 Proyección de ventas	15
7.2 Segmentación de clientes	16
7.3 Probabilidad de recompra	17
7.4 Visualización en dashboard interactivo	17
8. Conclusiones:	19
9. Anexos.....	21
10. Referencias	23

1. Introducción

Durante la práctica profesional en la Pisquera de Chile (CPCh), se identificó importantes brechas en el uso estratégico de la información comercial. El área de ventas actualmente presenta un enfoque reactivo frente al comportamiento de los clientes, lo que dificulta anticipar patrones de sus compras, ajustar metas o planificar estrategias de cobertura efectivas. A pesar de contar con una amplia base de datos históricos, no se explotan con herramientas analíticas que permitan segmentar clientes ni prever el comportamiento futuro de la demanda.

Esta necesidad de fortalecer la gestión comercial mediante el uso de herramientas analíticas también ha sido reconocida a nivel corporativo. Según la Memoria Integrada de CCU (2024), uno de los ejes estratégicos de la compañía es la mejora de márgenes y eficiencia comercial, impulsada a través de la adopción de tecnologías predictivas y sistemas de inteligencia comercial.

En particular, la marca Pisco Mistral -una de las líneas más relevantes del portafolio de CPCh- presenta una alta variabilidad estacional en sus ventas. En el canal Hogar, bajo la supervisión del jefe de ventas en la zona de Viña del Mar, se han identificado fluctuaciones mensuales de entre un 30% a 65% en volumen dependiendo del mes y año que se tome como referencia, Anexo 1. Esta inestabilidad impacta directamente en la eficiencia logística, el cumplimiento de metas, la fidelización de clientes y la utilización de recursos comerciales. Adicionalmente, se evidencia un número creciente de clientes inactivos o con baja recompra, lo que representa una oportunidad para la mejora del proceso de gestión comercial.

Frente a este escenario, en este proyecto se propone el desarrollo de un sistema analítico que integre modelos de forecasting y segmentación, con el fin de dotar al equipo comercial de CPCh con herramientas predictivas y visuales para anticipar el comportamiento de la demanda y actuar de manera proactiva sobre su cartera de clientes.

2. Contenido y Desarrollo del Problema

La gestión comercial de la Compañía Pisquera de Chile (CPCh), específicamente en la zona de Viña del Mar y en el canal denominado “Hogar” que indica que es el sector de sólo botillerías, no cuenta con herramientas que permitan anticipar la demanda ni comprender de manera segmentada el comportamiento de los clientes de este canal. Esta carencia limita la capacidad del equipo de ventas para priorizar acciones, detectar riesgos de inactividad y actuar a tiempo con campañas o visitas estratégicas.

En consecuencia, las decisiones comerciales se toman sobre la base en datos históricos sin un enfoque predictivo ni diferenciado, lo que deriva a una planificación reactiva. Esta situación afecta la eficiencia operativa, la asignación de recursos y el cumplimiento de metas mensuales.

Además, al no contar con una segmentación de clientes, se aplica la misma estrategia comercial a toda la cartera, sin considerar el nivel de fidelización, frecuencia de compra o potencial de crecimiento de cada cliente. Esto lleva a oportunidades perdidas tanto en cobertura como en eficiencia comercial, como se resume en la figura 1.

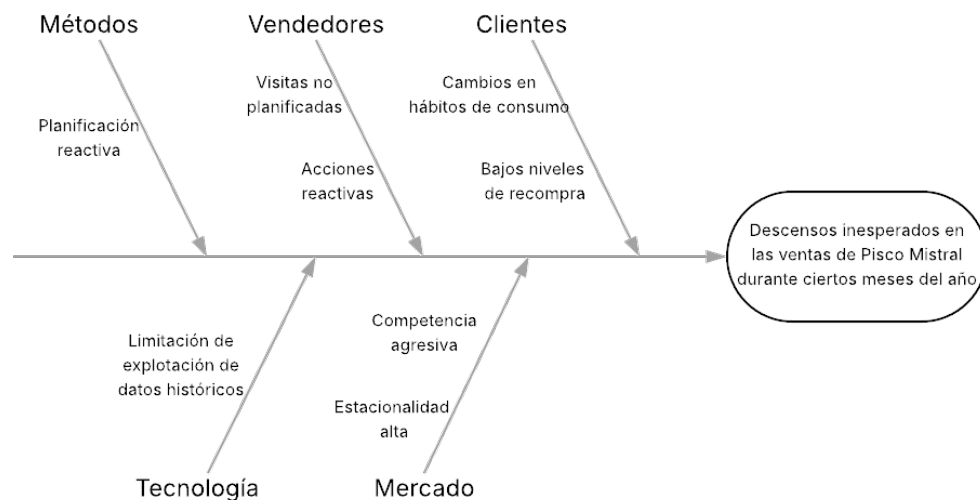


Figura 1. Diagrama de causa-efecto de la disminución de ventas de Pisco Mistral.

3. Objetivos

3.1. Objetivo General

- Desarrollar un prototipo de sistema analítico que permita segmentar clientes y predecir el volumen mensual de ventas de la marca Mistral, en el canal Hogar de Viña del Mar.

3.2. Objetivos Específicos

- Identificar patrones de variabilidad y estacionalidad en las ventas mensuales, así como factores que influyen en su comportamiento.
- Caracterizar los distintos tipos de clientes según su comportamiento de compra, nivel de actividad y frecuencia de adquisición.
- Diseñar un prototipo funcional que integre visualmente los resultados del análisis de demanda y segmentación de clientes para apoyar la toma de decisiones comerciales.

4. Marco Teórico / Estado del Arte

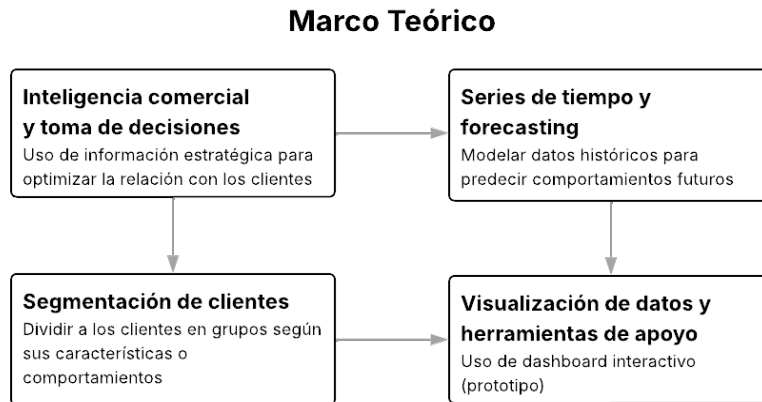


Figura 2. Ejes conceptuales del marco teórico

4.1. Inteligencia Comercial y Toma de Decisiones

La inteligencia comercial consiste en el uso de información estratégica para apoyar decisiones en áreas como ventas, marketing, distribución y fidelización de clientes. En contextos de alta competencia y cambios de comportamiento del consumidor, las herramientas analíticas permiten anticiparse a patrones y optimizar la relación con los clientes.

Kotler & Keller (2016) destacan que una gestión basada en inteligencia comercial mejora la asignación de recursos y eleva la efectividad de las acciones comerciales. A nivel organizacional, Davenport y Harris (2007) argumentan que las empresas que compiten basadas en análisis obtienen ventajas sostenibles.

4.2. Series de Tiempo y Forecasting

Las series de tiempo permiten analizar y modelar datos históricos con el fin de identificar patrones, estacionalidades o tendencias que ayuden a estimar valores futuros. En entornos comerciales, se utilizan para proyectar demanda, definir metas o planificar abastecimiento (Hyndman & Athanasopoulos, 2018).

Estas técnicas han sido aplicadas ampliamente en la planificación de ventas, logística y distribución (Box et al., 2015), destacándose por su utilidad en variables sensibles al tiempo.

4.3. Segmentación de Clientes

La segmentación es un enfoque ampliamente utilizado en marketing y gestión comercial para clasificar a los clientes según patrones de comportamiento, características demográficas o historial de compra.

Su objetivo es identificar grupos homogéneos dentro de una base diversa de clientes, lo cual permite comprender mejor sus necesidades y planificar estrategias diferenciadas.

Desde el punto de vista analítico, la segmentación puede abordarse mediante enfoques estadísticos, visuales o computacionales. Algunos modelos se centran en variables como la frecuencia de compra, el volumen adquirido o la inactividad. Estas técnicas permiten explorar el comportamiento del cliente sin necesidad de etiquetas previas, facilitando un análisis más profundo de su vínculo con la organización (Han et al., 2011; Ngai et al., 2009).

4.4. Visualización de Datos y Herramientas de Apoyo

La visualización de datos permite transformar grandes volúmenes de información en representaciones gráficas que facilitan su interpretación. Herramientas como dashboards interactivos han cobrado relevancia por su utilidad en la toma de decisiones comerciales (Few, 2009).

Shmueli, Patel y Bruce (2017) señalan que la visualización no solo mejora la comunicación de hallazgos, sino que también fortalece la interacción entre analistas y usuarios del negocio.

5. Propuesta Metodológica

La metodología del proyecto se basa en un enfoque cuantitativo, aplicado y exploratorio, con el objetivo de desarrollar un prototipo de sistema analítico que permita anticipar el comportamiento de ventas y segmentar a los clientes de la marca Mistral, en el canal Hogar de la zona de Viña del Mar.

El diseño metodológico se estructura en cuatro etapas:

5.1. Limpieza de datos y análisis exploratorio

Se trabajó sobre bases internas previamente consolidadas, aplicando un proceso de depuración para filtrar exclusivamente los registros asociados a productos de la marca Pisco Mistral, canal Hogar, y correspondientes a la zona gestionada por el jefe de ventas en Viña del Mar.

Posteriormente, se desarrolló un análisis exploratorio para identificar patrones relevantes como tendencias, estacionalidad, picos de venta y caídas mensuales. Asimismo, se examinó el comportamiento de clientes activos e inactivos, su distribución geográfica y su participación en el volumen total de ventas.

5.2. Modelamiento de series de tiempo (forecasting)

Se aplica el modelo Prophet para estimar el volumen mensual de ventas en HL. Este modelo fue elegido por su capacidad de incorporar estacionalidad, feriados y su robustez ante datos faltantes.

5.3. Segmentación de clientes (clustering)

Se implementa el algoritmo K-means, considerando variables como volumen de compra, frecuencia de pedidos, recencia e inactividad. El objetivo es identificar grupos de clientes con comportamientos similares para facilitar la gestión comercial diferenciada.

A continuación, se describen las reglas utilizadas para la interpretación de cada grupo segmentado:

Tabla 1. Reglas de segmentación K-means y su interpretación

Segmentos	Reglas aplicadas	Interpretación
0	Volumen \geq 20 HI	Cientes de alto volumen
1	Frecuencia \geq 15 y Volumen $<$ 20 HI	Cientes frecuentes, poco volumen
2	Frecuencia $<$ 15 y Volumen $<$ 20 HI	Cientes dispersos o esporádicos

5.4. Visualización e integración

Los resultados obtenidos se integran en un tablero interactivo en Tableau, que permitirá al jefe de zona filtrar por comuna, producto y segmento de cliente. Esto facilitará una gestión más proactiva y focalizada.

Esta metodología es factible y coherente con los datos disponibles, y ha sido diseñada para entregar valor práctico y replicable al área comercial de CPCh.

6. Aplicación Metodológica

Para el desarrollo de esta propuesta, se siguió una metodología estructurada y secuencial, que permitió transformar datos históricos de ventas en herramientas prácticas de análisis comercial y toma de decisiones. La combinación de enfoques exploratorios, modelamiento estadístico y segmentación de clientes, junto con herramientas de visualización interactiva, permitió entregar resultados tangibles y accionables. A continuación, se detalla cada etapa implementada:

6.1 Filtrado de datos históricos

El primer paso consistió en la recolección y consolidación de los registros de ventas proporcionados por CPCh, abarcando un período de tres años (2023, 2024 y 2025). Se trabajó exclusivamente con datos correspondientes al canal Hogar de la zona Viña del Mar, bajo la supervisión del jefe de ventas de dicha área. Esta delimitación territorial y comercial fue fundamental para acotar el análisis a una unidad estratégica específica, asegurando la alineación con los objetivos de gestión local.

El proceso de filtrado incluyó:

- **Depuración de registros incompletos**, con especial atención a fechas, unidades vendidas y productos sin codificación correcta.
- **Eliminación de productos fuera del alcance del estudio**, como líneas no pertenecientes a la marca Pisco Mistral.
- **Revisión de coherencia temporal**, ajustando períodos mal etiquetados o duplicados.

Posteriormente, se estableció una estructura jerárquica de los datos para permitir su uso eficiente en las herramientas de análisis. Esta estructura incluyó campos como cliente ID, fecha, volumen en hectolitros, producto, comuna y ejecutivo responsable. El enfoque en una marca específica permitió mantener la homogeneidad del análisis y evitar sesgos provocados por mezclas de categorías de productos con comportamientos disímiles.

Este proceso no solo aseguró la calidad de los datos, sino que sentó las bases para una exploración robusta y confiable, especialmente considerando que las decisiones posteriores —

como la modelación de demanda o la segmentación— dependen en gran medida de la integridad de los datos de entrada.

6.2 Construcción de variables de análisis por cliente

Una vez filtrada la base de datos, se procedió a la generación de variables clave que permitieran caracterizar cuantitativamente el comportamiento de cada cliente durante el período 2023–2025. Estas variables fueron seleccionadas con el objetivo de capturar tanto el valor como la dinámica de la relación comercial a lo largo del tiempo, sirviendo como insumo directo para los modelos de segmentación aplicados posteriormente.

Las principales variables construidas fueron:

- **Volumen total acumulado:** Representa la suma total del volumen de compra (en hectolitros) registrado por cada cliente en el período de análisis. Esta variable permite identificar a los clientes de mayor peso comercial dentro del canal.
- **Frecuencia de compra:** Corresponde al número de meses en los cuales el cliente realizó al menos una transacción. Esta métrica permite evaluar la regularidad de compra y distinguir entre clientes recurrentes y esporádicos.
- **Recencia:** Se define como el número de meses transcurridos desde la última compra registrada de cada cliente hasta el final del período. Este indicador es clave para identificar clientes activos versus aquellos que han dejado de comprar recientemente.

Estas tres variables, derivadas directamente de las transacciones históricas, fueron normalizadas para asegurar una adecuada interpretación conjunta y utilizadas como base para la posterior segmentación mediante el algoritmo K-means. La construcción de estas variables permitió transformar los datos transaccionales en información de valor para el análisis comercial, facilitando una mejor comprensión del comportamiento de los clientes del canal Hogar en Viña del Mar.

6.3 Modelamiento de demanda con Prophet

Con el objetivo de estimar la evolución futura de la demanda mensual, se aplicó el modelo Prophet, desarrollado por el equipo de investigación de Meta (Facebook). Esta herramienta se

caracteriza por su estructura aditiva, que permite modelar tendencias no lineales junto a componentes estacionales y efectos de días festivos. Fue desarrollada por el equipo de Facebook, ha sido ampliamente adoptada por su facilidad de implementación y su capacidad para generar pronósticos confiables incluso en presencia de datos faltantes o cambios abruptos. Estas características lo hacen especialmente adecuado para entornos comerciales con alta variabilidad temporal.

Se entrenó el modelo utilizando los datos mensuales agregados de ventas históricas (en hectolitros) desde enero de 2023 hasta junio de 2025. Prophet permitió descomponer la serie en sus tres componentes clave:

- **Tendencia:** Representa el crecimiento sostenido de las ventas a lo largo del tiempo.
- **Estacionalidad anual:** Captura la variación cíclica de ventas mes a mes.
- **Ruido / anomalías:** Permite detectar caídas puntuales, como la observada en febrero de 2025.

Uno de los beneficios del modelo es que permite integrar feriados o eventos especiales como input externo, lo que posibilita realizar ajustes más realistas en la proyección. En este caso, se analizaron posibles efectos por eventos comerciales como Fiestas Patrias o Navidad.

El resultado fue una proyección visual clara y confiable de la demanda mensual para el resto del 2025, con bandas de incertidumbre incluidas. Este insumo es crítico para los equipos de planificación logística, ya que permite anticipar inventarios, reforzar periodos de alta demanda o prever caídas abruptas con anticipación suficiente. Para más detalle, ver Anexo 2.

6.4 Segmentación de clientes con K-means

Con el objetivo de identificar patrones comunes dentro de la cartera de clientes, se aplicó una técnica de segmentación no supervisada mediante el algoritmo K-means. Esta metodología permitió clasificar a los clientes en grupos con características de comportamiento similares, utilizando como base las variables previamente construidas: volumen total de compra, frecuencia de compra y recencia.

La elección del algoritmo K-means respondió a su capacidad para generar agrupaciones homogéneas de manera eficiente, siendo especialmente útil cuando se dispone de un conjunto reducido de variables cuantitativas claramente definidas. Para ello, se procedió a normalizar las tres variables utilizadas, asegurando que cada una tuviera igual peso en el proceso de agrupamiento y evitando sesgos derivados de diferencias de escala.

Tras la aplicación del algoritmo, se identificaron tres segmentos de clientes con comportamientos claramente diferenciados:

- **Segmento 0:** Clientes con volumen de compra alto, considerados estratégicos por su impacto en la demanda total.
- **Segmento 1:** Clientes con frecuencia de compra elevada pero con volúmenes moderados, potencialmente fidelizados y regulares.
- **Segmento 2:** Clientes con baja frecuencia y volumen, cuya actividad comercial es más esporádica o inactiva.

La interpretación de estos segmentos se apoya en reglas simples basadas en los rangos observados para cada variable, lo que permite facilitar la lectura e implementación de estrategias diferenciadas. Esta segmentación, detallada en el Anexo 3, permite priorizar acciones comerciales según el perfil de cada grupo: reforzar relaciones con los clientes clave, estimular a los de comportamiento regular y diseñar acciones de recuperación o reactivación para los menos activos.

Además, la segmentación obtenida fue integrada en el dashboard interactivo, lo que habilita su uso práctico por parte del equipo comercial, permitiendo filtrar y visualizar dinámicamente las ventas proyectadas, el comportamiento de compra y el potencial de cada segmento en el tiempo.

6.5 Integración de resultados en dashboard interactivo

Con el fin de consolidar los análisis anteriores y hacerlos operativos para el equipo comercial, se diseñó un dashboard interactivo en Tableau, herramienta que permite integrar visualizaciones dinámicas y aplicar filtros personalizados en tiempo real.

El tablero fue diseñado con un enfoque modular, considerando los siguientes componentes principales:

- **Proyección de ventas mensuales** (modelo Prophet), con opción de ver series históricas y pronóstico futuro.
- **Segmentación de clientes por grupo**, con posibilidad de filtrar por comuna, cliente o ejecutivo.
- **Clasificación de probabilidad de recompra**, mediante colores para facilitar su lectura.
- **Matriz de gestión comercial**, que cruza frecuencia y recencia, indicando qué clientes requieren acción prioritaria.

El dashboard fue pensado como una herramienta de apoyo a la planificación táctica, no solo como un resumen visual. Permite, por ejemplo:

- Que el jefe de zona filtre su cartera y vea cuáles de sus clientes tienen alta probabilidad de recompra pero están en baja actividad.
- Detectar segmentos con bajo rendimiento por zona o comuna.
- Programar visitas o campañas según la estacionalidad futura proyectada.

Además, su diseño visual permite democratizar el acceso a los datos, facilitando la comprensión de hallazgos incluso para perfiles no técnicos.

Este tablero, incluido en el Anexo 4, se convierte así en el puente final entre el análisis y la acción, constituyendo un pilar clave de esta propuesta metodológica.

7. Resultados

La implementación de la propuesta analítica permitió obtener resultados significativos orientados a mejorar la eficiencia comercial y la toma de decisiones en el canal Hogar de la marca Pisco Mistral, específicamente en la zona de Viña del Mar.

Estos resultados se desprenden de la aplicación secuencial de modelos predictivos, técnicas de segmentación no supervisada y herramientas visuales de análisis, las cuales fueron integradas en un dashboard interactivo para facilitar su lectura e interpretación por parte del equipo comercial.

A continuación se detallan los hallazgos más relevantes obtenidos a lo largo del desarrollo del proyecto:

7.1 Proyección de ventas

Uno de los principales entregables del análisis corresponde a la proyección de ventas mensuales para los años 2024 y 2025, generada mediante la implementación del modelo Prophet. Este modelo, desarrollado por Meta, es una técnica de forecasting basada en series de tiempo que permite capturar automáticamente patrones estacionales, tendencias y efectos de calendario, incluso en escenarios con cierto nivel de irregularidad o ruido en los datos.

En el caso de Pisco Mistral, se utilizó una serie de ventas históricas mensuales para el canal Hogar desde 2023 hasta mediados de 2025. La modelación arrojó una tendencia general creciente, lo cual sugiere un comportamiento positivo en términos de demanda futura. Este hallazgo es relevante no solo desde el punto de vista estratégico, sino también operativo, ya que permite anticipar necesidades logísticas, coordinar inventarios y alinear acciones comerciales a meses de alta demanda.

Adicionalmente, la proyección permitió identificar meses críticos con comportamiento atípico, como caídas abruptas o alzas inesperadas. Este tipo de análisis ayuda a detectar períodos que requieren atención especial, ya sea para reforzar acciones de marketing, revisar condiciones comerciales o evaluar factores externos que puedan haber afectado el comportamiento de compra. De forma complementaria, se detectaron patrones estacionales moderados, lo que permite planificar campañas de forma más precisa durante el año calendario.

La ventaja de utilizar Prophet radica en su capacidad para realizar ajustes automáticos ante datos faltantes o atípicos, lo que otorga mayor robustez a las proyecciones y minimiza la intervención manual. Esto entrega a los tomadores de decisiones un marco de anticipación confiable y fácilmente actualizable, capaz de proyectar nuevos escenarios conforme se integren datos recientes.

7.2 Segmentación de clientes

El segundo bloque de resultados relevantes proviene del modelo de segmentación no supervisada, aplicado con la técnica K-means. Esta metodología permitió agrupar a los clientes en tres segmentos diferenciados basados en variables de comportamiento clave: volumen total de compra, frecuencia (cantidad de meses con compras registradas) y recencia (meses transcurridos desde la última compra).

Los segmentos obtenidos fueron los siguientes:

- Segmento 0 – Clientes de alto volumen: Usuarios con compras superiores a 20 hectolitros anuales. Representan un grupo estratégico por su impacto directo en los ingresos totales, pero cuya frecuencia de compra puede ser irregular.
- Segmento 1 – Clientes frecuentes con bajo volumen: Clientes con 15 o más meses de compra registrados, pero con un volumen acumulado menor a 20 HL. Este grupo evidencia una relación comercial activa y sostenida, aunque con menor intensidad.
- Segmento 2 – Clientes esporádicos: Compradores con baja frecuencia (<15 meses) y bajo volumen (<20 HL), lo que sugiere relaciones menos consistentes o transaccionales.

Esta segmentación permitió visualizar con claridad los distintos perfiles comerciales presentes en la base de clientes, facilitando la identificación de oportunidades y riesgos. Por ejemplo, los clientes del segmento 2 pueden ser objeto de campañas de activación o recuperación, mientras que los del segmento 0 requieren estrategias de fidelización y monitoreo proactivo.

Además, este enfoque permite asignar recursos comerciales de manera más eficiente, evitando estrategias genéricas para toda la cartera y focalizando esfuerzos donde existe mayor

retorno potencial. En conjunto, el modelo entrega una base sólida para personalizar campañas, priorizar visitas de vendedores y diseñar promociones diferenciadas.

7.3 Probabilidad de recompra

Otro eje central del análisis fue la categorización de los clientes según su propensión a realizar una nueva compra, es decir, su probabilidad de recompra. Para este fin, se utilizaron nuevamente las variables de comportamiento (frecuencia, recencia y volumen), y se definieron tres niveles de probabilidad: alta, media y baja.

- Alta: Clientes que han mantenido una frecuencia elevada de compra y que realizaron su última compra en un periodo reciente.
- Media: Clientes con cierta recurrencia, pero con mayor dispersión en sus compras o con una última compra más lejana.
- Baja: Clientes inactivos durante varios meses, con compras esporádicas o históricas, cuyo comportamiento no indica intención clara de continuar.

Esta clasificación representa un insumo crítico para la gestión de cartera, ya que permite identificar tempranamente posibles casos de abandono y diseñar estrategias de retención focalizadas. Asimismo, posibilita anticipar quiebres en la continuidad comercial y derivar alertas a los equipos de ventas para tomar medidas proactivas.

Al analizar la distribución de los clientes según esta tipología, se evidenció que una parte importante de la base se concentra en la categoría media, lo cual sugiere una oportunidad significativa para reforzar el vínculo comercial con acciones de fidelización y seguimiento personalizado.

7.4 Visualización en dashboard interactivo

Todos los resultados obtenidos fueron consolidados en un dashboard dinámico construido en Tableau, con el objetivo de facilitar la interpretación, exploración y uso práctico de la información por parte del equipo comercial. Esta herramienta fue diseñada no solo como un

resumen visual de los análisis, sino como un instrumento táctico de gestión, accesible y personalizable.

El tablero incluye distintas secciones interactivas, entre ellas:

- Proyección de ventas por segmento, con evolución mensual y comparativa histórica.
- Distribución de clientes por segmentación de comportamiento, clasificados según el modelo K-means.
- Gráfico de probabilidad de recompra, con filtro por categoría.
- Matriz de gestión de clientes, basada en las dimensiones de frecuencia y recencia, que permite detectar rápidamente clientes activos, inactivos, frecuentes u ocasionales.

El valor del dashboard radica en su capacidad para cruzar filtros de forma intuitiva, permitiendo, por ejemplo, revisar los clientes de un segmento específico con alta probabilidad de recompra, o analizar cómo se comportan los clientes frecuentes durante ciertos períodos del año.

Este tablero, que puede visualizarse en tiempo real, se convierte en una herramienta operativa clave para la planificación de campañas, el seguimiento de objetivos y la priorización de actividades comerciales. Su flexibilidad y capacidad de actualización lo hacen fácilmente escalable a otras zonas, canales o marcas dentro de la organización.

En conjunto, los resultados obtenidos permiten construir una visión completa, accionable y actualizada del comportamiento comercial en el canal Hogar para Pisco Mistral en la zona de Viña del Mar. La combinación de herramientas predictivas, análisis segmentado y visualización integrada fortalece la capacidad analítica de la organización, mejorando la toma de decisiones y la gestión estratégica de la cartera de clientes.

Además, este enfoque es perfectamente escalable y replicable en otras zonas de cobertura comercial, abriendo la posibilidad de institucionalizar prácticas analíticas que eleven el estándar de planificación y ejecución en CPCh. La evidencia generada constituye una base robusta para futuras iniciativas de inteligencia comercial y representa un paso significativo hacia una gestión más proactiva, focalizada y basada en datos.

8. Conclusiones:

El análisis desarrollado evidencia de manera concluyente que la aplicación de herramientas analíticas al comportamiento comercial constituye una fuente significativa de valor estratégico y operativo. A través de la integración de modelos predictivos, técnicas de segmentación y plataformas de visualización, fue posible transformar información histórica dispersa en una base estructurada para la toma de decisiones comerciales informadas, focalizadas y escalables.

En primer lugar, la proyección de ventas realizada mediante el modelo Prophet permitió anticipar el comportamiento del canal Hogar para la marca Pisco Mistral durante los años 2024 y 2025. Este modelo, al incorporar automáticamente tendencias, efectos de calendario y variabilidad mensual, ofreció una estimación robusta y comprensible de la evolución esperada de la demanda. Los resultados obtenidos reflejan una tendencia creciente, pero también revelan puntos críticos donde se presentan caídas o repuntes específicos, lo que entrega un insumo directo para la planificación comercial proactiva y la optimización de inventarios, cobertura o campañas.

En segundo lugar, la segmentación de clientes a través del algoritmo K-means demostró ser una herramienta eficaz para caracterizar perfiles diferenciados dentro de la cartera actual. La clasificación en tres grupos homogéneos, según volumen, frecuencia y recencia, permitió identificar a los clientes más estratégicos, así como aquellos que requieren atención prioritaria o planes de retención específicos. Esta segmentación es un paso clave para pasar de una gestión homogénea a una lógica de personalización comercial, mucho más eficiente en el uso de recursos y en la generación de valor.

Complementariamente, el modelo de probabilidad de recompra añadió una dimensión anticipativa al análisis. Al establecer niveles de propensión (alta, media y baja), se habilita un enfoque preventivo para reducir la pérdida de clientes y fomentar relaciones más sostenibles. Esta clasificación aporta una capa crítica para la gestión del ciclo de vida del cliente, y permite acciones comerciales más ajustadas al nivel de compromiso actual de cada segmento.

La visualización integrada en Tableau representa otro de los aportes fundamentales del trabajo. A través de un dashboard interactivo y dinámico, se sintetizan los principales hallazgos en una herramienta accesible para el equipo comercial, permitiendo filtrar por zona, producto, cliente

o período. Esta interfaz no solo mejora la comprensión de los datos, sino que facilita la acción inmediata y la lectura táctica en el día a día. La incorporación de elementos visuales como matrices de recencia-frecuencia o gráficos de evolución de ventas ofrece un soporte operativo concreto para la ejecución de decisiones.

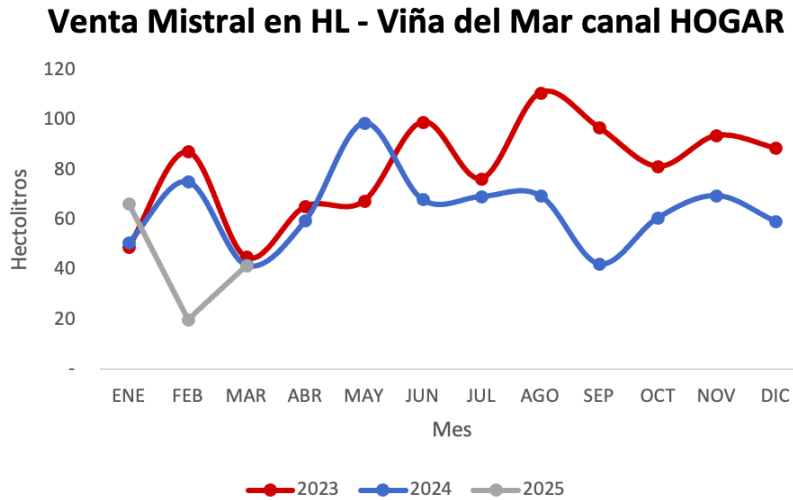
Finalmente, se concluye que la propuesta metodológica no solo cumple con los objetivos planteados inicialmente, sino que entrega una base sólida para la expansión futura. Su diseño modular, basado en datos accesibles y técnicas replicables, la vuelve perfectamente escalable a otras zonas geográficas, canales de venta u otras marcas de la compañía. Además, abre posibilidades para integrar automatización de reportes, sistemas de alertas o incluso modelos más sofisticados de predicción o clasificación.

En conjunto, este trabajo valida que la inteligencia comercial aplicada —basada en ciencia de datos y visualización estratégica— puede constituirse en un factor diferenciador clave para enfrentar entornos dinámicos y competitivos como el actual.

9. Anexos

Anexo 1:


Venta en hectolitros de producto marca Mistral por el jefe de venta en el sector de Viña del Mar en canal HOGAR.



Elaboración propia en base a datos CPCh.

Anexo 2:

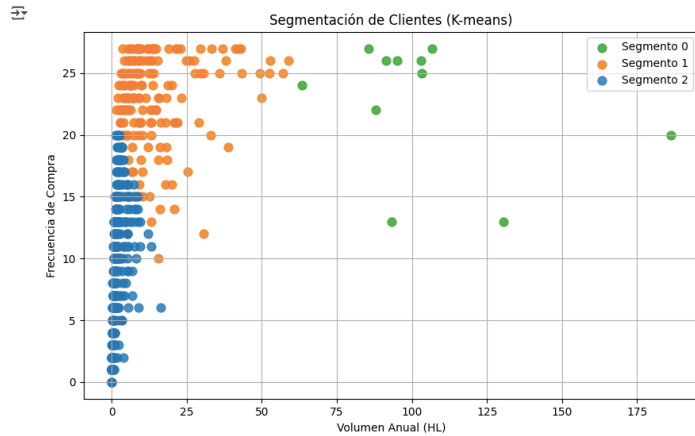
Modelo de series de tiempo (Prophet) para estimar la demanda mensual proyectada de pisco Mistral



Elaboración propia en base a datos CPCh.

Anexo 3:

Segmentación de Clientes (K-means) para agrupación según comportamiento.

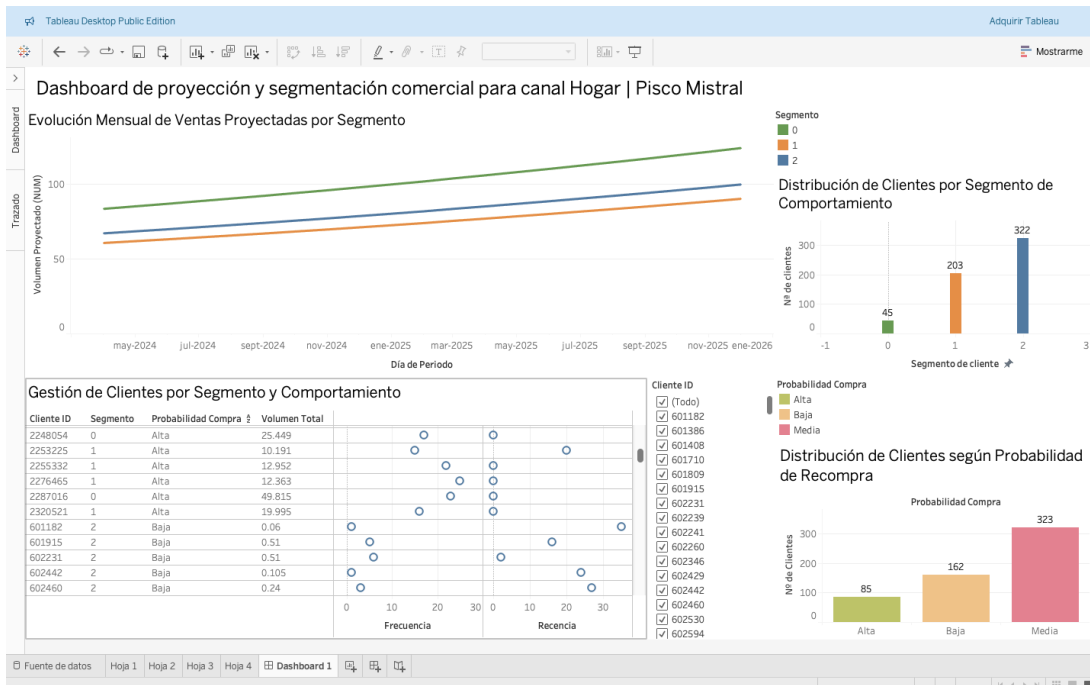


Segmentos	Reglas aplicadas	Interpretación
0	Volumen \geq 20 HL	Clientes de alto volumen
1	Frecuencia \geq 15 y Volumen < 20 HL	Clientes frecuentes, poco volumen
2	Frecuencia < 15 y Volumen < 20 HL	Clientes dispersos o esporádicos

Elaboración propia en base a datos CPCh.

Anexo 4:

Prototipo de dashboard interactivo en Tableau. Se visualiza la proyección de ventas, segmentación de clientes y herramientas de gestión por comportamiento.



Elaboración propia en base a datos CPCh en plataforma Tableau.

10. Referencias

- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time Series Analysis: Forecasting and Control*. Wiley.
- Compañía Cervecerías Unidas (CCU). (2024). *Memoria Integrada CCU 2024*.
<https://www.ccu.cl/memoria2024>
- Davenport, T. H., & Harris, J. G. (2007). *Competing on Analytics: The New Science of Winning*. Harvard Business Review Press.
- Few, S. (2009). *Now You See It: Simple Visualization Techniques for Quantitative Analysis*. Analytics Press.
- Han, J., Kamber, M., & Pei, J. (2011). *Data Mining: Concepts and Techniques (3rd ed.)*. Morgan Kaufmann.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice (2nd ed.)*. OTexts.
- Kotler, P., & Keller, K. L. (2016). *Dirección de Marketing (15ª ed.)*. Pearson Educación.
- Kuhn, M., & Johnson, K. (2013). *Applied Predictive Modeling*. Springer.
- Längkvist, M., Karlsson, L., & Loutfi, A. (2014). A review of unsupervised feature learning and deep learning for time-series modelling. *Pattern Recognition Letters*, 42, 11–24.
<https://doi.org/10.1016/j.patrec.2014.01.008>
- Lundberg, S. M., & Lee, S.-I. (2017). A Unified Approach to Interpreting Model Predictions. *Advances in Neural Information Processing Systems*, 30.
https://proceedings.neurips.cc/paper_files/paper/2017/file/8a20a8621978632d76c43dfd28b67767-Paper.pdf
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). The M4 Competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, 34(3), 802–808.
<https://doi.org/10.1016/j.ijforecast.2018.06.001>
- Ngai, E. W. T., Xiu, L., & Chau, D. C. K. (2009). Application of data mining techniques in customer relationship management: A literature review and classification. *Expert Systems with Applications*, 36(2), 2592–2602. <https://doi.org/10.1016/j.eswa.2008.02.021>
- Pedregosa, F., Varoquaux, G., Gramfort, A., et al. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.

Provost, F., & Fawcett, T. (2013). *Data Science for Business: What You Need to Know About Data Mining and Data-Analytic Thinking*. O'Reilly Media.

Roberts, S., Osborne, M., & Ebdon, M. (2013). Gaussian Processes for Time-Series Modelling. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 371(1984). <https://doi.org/10.1098/rsta.2012.0022>

Shmueli, G., Patel, N. R., & Bruce, P. C. (2017). *Data Mining for Business Analytics: Concepts, Techniques, and Applications in R*. Wiley.

Tan, P.-N., Steinbach, M., & Kumar, V. (2018). *Introduction to Data Mining* (2nd ed.). Pearson.

Taylor, S. J., & Letham, B. (2018). *Forecasting at Scale*. *The American Statistician*, 72(1), 37–45. <https://doi.org/10.1080/00031305.2017.1380080>