



UNIVERSIDAD DE CHILE  
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS  
DEPARTAMENTO DE INGENIERÍA INDUSTRIAL

SISTEMA DE APOYO PARA DOTACIÓN DE PERSONAL DE REPOSICIÓN DE  
SUPERMERCADO MEDIANTE HERRAMIENTAS DE APRENDIZAJE AUTOMÁTICO

TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN GESTIÓN DE OPERACIONES  
MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL INDUSTRIAL

SEBASTIÁN IGNACIO GALLARDO PINO

PROFESOR GUÍA:  
MARCELO OLIVARES ACUÑA

PROFESORA CO-GUÍA:  
ALEJANDRA PUENTE CHANDÍA

COMISIÓN:  
CHARLES THRAVES CORTÉS-MONROY

SANTIAGO DE CHILE  
2021

RESUMEN DE LA MEMORIA PARA OPTAR  
AL TÍTULO DE MAGÍSTER EN GESTIÓN DE OPERACIONES  
POR: SEBASTIÁN IGNACIO GALLARDO PINO  
FECHA: 2021  
PROF. GUÍA: MARCELO OLIVARES ACUÑA  
PROF. CO-GUÍA: ALEJANDRA PUENTE CHANDÍA

## SISTEMA DE APOYO PARA DOTACIÓN DE PERSONAL DE REPOSICIÓN DE SUPERMERCADO MEDIANTE HERRAMIENTAS DE APRENDIZAJE AUTOMÁTICO

Debido a la alta competencia en la industria del retail, las empresas de esta industria, constantemente buscan formas de mejorar su rendimiento, ya sea abaratando costos o aumentando sus ingresos. En [11] los autores declaran que “Después del costo de los bienes vendidos, el gasto de mano de obra en la tienda es el componente de costo más grande en la industria del retail. Como resultado, desarrollar y ejecutar planes laborales es una tarea clave para los retailers”. Si bien se realizan esfuerzos para mejorar el rendimiento, aún hay brechas que pueden ser optimizadas.

El objetivo de esta investigación es sentar un punto de inicio en la optimización de dotación y asignación eficiente de reponedores del retail supermercadista de la Región Metropolitana, mediante una estimación de tiempos diarios de reposición por local y pronósticos de quiebres de stock, utilizando datos transaccionales, mediciones de tiempo de trabajo y data sobre quiebres observados.

Para esto, se sigue una metodología de 3 etapas. En la primera etapa, y mediante el uso de los datos transaccionales, se postulan modelos de predicción de demanda agregada a nivel de categoría de productos, basados en series de tiempo, input necesario para poder realizar una correcta estimación de los tiempos de trabajo que requiere cada sala diariamente. En la segunda etapa, usando las estimaciones de demanda diaria y las mediciones de tiempo, se calibra una función mediante diferentes modelos lineales que permite ajustar el tiempo diario de trabajo en dos componentes: tiempo de trabajo fijo, que captura el efecto de actividades que no dependen de la cantidad de productos a reponer; y tiempo variable, que captura el efecto de aquellas que si dependen de la cantidad de productos a reponer. Finalmente, como tercera etapa y utilizando datos de quiebres observados, se plantean modelos de predicción de quiebres de stock, basados en *CART analysis*, que permiten clasificar mediante diversos criterios si un producto tiene o no disponibilidad para venta en sala. Con esto se busca optimizar la priorización de actividades de reposición dentro de la sala.

Como resultados, se obtiene que el modelo *Prophet* es el modelo que mejor ajusta la demanda, teniendo un error promedio fuera de muestra de un 24.7% versus un 33.8% y 29.8% que entregan los modelos *Exponential Smoothing* y *ARIMA*, respectivamente. Con respecto a la estimación de tiempos, se mostró que al aplicar la función de ajuste de tiempos a los pronósticos de demanda, el error promedio observado disminuye a un 16%. Esto se debe a que las categorías sobreestimadas se contrarrestan con las subestimadas. Finalmente, respecto a los quiebres de stock, no se logran resultados completamente satisfactorios, ya que, debido a la poca información disponible para clasificar, los modelos postulados logran estimar correctamente sólo un 50% a 60% de los quiebres de stock reales.

*Dedicado a Teresa.*

# Agradecimientos

En este espacio, me gustaría agradecer a muchas personas que han sido parte importante durante todo mi paso por la universidad.

A toda mi familia, porque han sido una fuente de inspiración y orgullo. Han estado en todo momento apoyándome y brindándome toda su comprensión y cariño. Gran parte de lo que he logrado es gracias a ellos. Estoy enormemente agradecido de lo mucho que me han entregado.

A mis amigos y amigas de la facultad, porque me acompañaron (y por sobretodo aguantaron) durante estos siete años. Caro, Karin, Wasta, Nat, Tomi, Dani, Fran, Cristian, Magda, Javi, Seba, Feñita, Simón, JP, Mati, Gabi, cada uno de ustedes forma parte de mi corazón y estoy muy feliz de haberlos conocido.

A mis amigos que no son de la facultad y que, aunque no veían mis quejas a diario, igualmente estaban conmigo en cada momento. Ariel, Roberto, Pablo, gracias por ser quienes son y por estar conmigo en las buenas y en las malas, por las risas, los consejos, las conversas.

A la profesora Alejandra Puente, por confiar en mí ofreciéndome el trabajo presentado en esta tesis, y además acompañarme en el transcurso de ella. A la profesora Zunilda Vergara, también por confiar en mí e incentivarme a perder el miedo a ser parte de equipos docentes. Gracias a esto pude reconocer lo mucho que me gusta enseñar. A Paula Cabrera, porque gracias a su ayuda logré conocerme más a mi mismo. A Linda Valdés, porque sinceramente sin su orientación, mi pasar por el MGO hubiese sido caótico. A tod@s l@s profes que me ayudaron a tener más confianza en mi mismo.

Finalmente, quiero agradecer al resto de compañeros y compañeras que no están mencionad@s pero que compartieron conmigo y me mostraron su cariño.

# Tabla de Contenido

<b>Introducción</b>	<b>1</b>
<b>1. Datos</b>	<b>3</b>
1.1. Obtención de los datos . . . . .	3
1.2. Datos . . . . .	3
1.3. Análisis exploratorio de los datos . . . . .	5
1.3.1. Análisis de ventas RM . . . . .	5
1.3.2. Análisis de ventas por locales . . . . .	9
1.3.3. Efecto 18 Octubre y Pandemia . . . . .	16
<b>2. Levantamiento de procesos</b>	<b>18</b>
<b>3. Estimación de demanda</b>	<b>21</b>
3.1. Formulación de modelos de estimación de demanda . . . . .	21
3.1.1. Modelo ARIMA . . . . .	21
3.1.2. Modelo Exponential Smoothing . . . . .	21
3.1.3. Modelo Prophet . . . . .	22
3.2. Resultados modelos y comparación . . . . .	23
3.3. Refinamiento modelo Prophet . . . . .	25
3.4. Rolling Forecast . . . . .	27
<b>4. Estimación de tiempos de reposición</b>	<b>31</b>
4.1. Tiempos de reposición . . . . .	31
4.2. Formulación de modelos de estimación de tiempos de reposición . . . . .	31
4.2.1. Calibración de la función . . . . .	32
4.3. Balance de tiempo fijo y tiempo variable . . . . .	38
<b>5. Detección de quiebres de stock</b>	<b>42</b>
5.1. Formulación de modelos de quiebres de stock . . . . .	42
5.1.1. Productos de alta y media rotación . . . . .	43
5.1.2. Productos de baja rotación . . . . .	45
5.2. Resultados . . . . .	46
5.2.1. Productos de alta y media rotación . . . . .	46
5.2.2. Productos de baja rotación . . . . .	47
<b>Conclusión</b>	<b>49</b>



# Índice de Tablas

3.1. MAPE fuera de muestra modelos estimación de demanda agregada para locales 1 y 2. . . . .	24
3.2. MAPE fuera de muestra modelos estimación de demanda agregada para locales 3 y 4. . . . .	24
3.3. MAPE fuera de muestra modelos estimación de demanda agregada para locales 5 y 6. . . . .	24
3.4. MAPE fuera de muestra modelo Prophet con inclusión de estacionalidad mensual, con horizonte de predicción de 8 días. . . . .	26
3.5. MAPE fuera de muestra modelo Prophet con inclusión de estacionalidad mensual y fechas especiales, con horizonte de predicción de 8 días. . . . .	26
3.6. MAPE fuera de muestra modelo Prophet con inclusión de estacionalidad mensual, con horizonte de predicción de 30 días. . . . .	26
3.7. MAPE fuera de muestra modelo Prophet con inclusión de estacionalidad mensual y fechas especiales, con horizonte de predicción de 30 días. . . . .	27
3.8. MAPE fuera de muestra rolling forecast modelo Prophet con inclusión de estacionalidad mensual y factores climáticos. . . . .	29
3.9. MAPE fuera de muestra rolling forecast modelo Prophet con inclusión de estacionalidad mensual, fechas especiales y factores climáticos. . . . .	29
4.1. Valores estimados para componente fija de tiempos de reposición, según segmento de local. . . . .	33
4.2. Resultados estimación modelo 1. . . . .	35
4.3. Resultados estimación modelo 2. . . . .	35
4.4. Resultados estimación modelo 3. . . . .	36
4.5. Resultados estimación modelo 4. . . . .	36
4.6. Resultados estimación modelo 5. . . . .	36
4.7. MAPE tiempo variable de reposición, categorías no refrigeradas. . . . .	37
4.8. MAPE tiempo variable de reposición, categorías refrigeradas. . . . .	37
4.9. Tiempos de reposición estimados por local. . . . .	38
4.10. Valores estimados por cluster para tiempo fijo. . . . .	39
4.11. Valores estimados por grupo de categoría para tiempo variable asociado a proceso de reposición. . . . .	39
4.12. Valores estimados por cluster para tiempo variable asociado a nuevos procesos relacionados con la demanda. . . . .	39
4.13. MAPE tiempo variable de reposición para nueva metodología, para categorías no refrigeradas y refrigeradas. . . . .	40

4.14. Tiempos de reposición estimados por local bajo nueva metodología. . . . .	40
5.1. Matriz de confusión modelo 1 (Random Forest, Probabilidad Log-Normal). .	46
5.2. Matriz de confusión modelo 2 (Random Forest, Probabilidad Gamma). . . .	46
5.3. Matriz de confusión modelo 3 (Árbol de regresión, Probabilidad Log-Normal).	46
5.4. Matriz de confusión modelo 4 (Árbol de Regresión, Probabilidad Gamma). .	46
5.5. Métricas de matrices de confusión para modelos de quiebre en productos de alta y media rotación. . . . .	47
5.6. Matriz de confusión modelo 1 (Random Forest, Probabilidad Poisson). . . .	48
5.7. Matriz de confusión modelo 2 (Árbol de Regresión, Probabilidad Poisson). .	48
5.8. Métricas de matrices de confusión para modelos de quiebre en productos de baja rotación. . . . .	48





# Introducción

Debido a la alta competencia en la industria del retail, las empresas de esta industria, constantemente buscan formas de mejorar su rendimiento, ya sea abaratando costos o aumentando sus ingresos. Si bien se realizan esfuerzos para mejorar el rendimiento, aún hay brechas que pueden ser optimizadas.

Una de estas brechas, que tiene un gran impacto en el desempeño de las empresas competidoras, es la que compete al factor asociado a la mano de obra en las labores de reposición de productos. En [11] los autores declaran que “Después del costo de los bienes vendidos, el gasto de mano de obra en la tienda es el componente de costo más grande en la industria del retail. Como resultado, desarrollar y ejecutar planes laborales es una tarea clave para los retailers”. En la actual industria chilena, los retailers han detectado un aumento en el tiempo ocioso de los trabajadores con labores de reposición, asociado a una sobre-dotación de personal provocada por la forma en que se realiza la planificación de sus tareas.

Uno de los factores clave para mejorar el rendimiento en la planificación de las tareas expuestas anteriormente, es tener un buen sistema de planificación de dotación. “La planificación y los pronósticos se consideran como la base para una toma de decisiones racional”[9]. Dado lo mencionado, es posible considerar que un sistema sofisticado de pronósticos de tiempos de trabajo podría disminuir los costos asociados al tiempo ocioso en las labores de reposición.

Es importante mencionar que para poder realizar buenas estimaciones de tiempos de trabajo, considerando que en este rubro el tiempo de trabajo está estrechamente relacionado con la demanda de productos, es necesario tener buenas estimaciones de demanda. En la literatura, existen diversos estudios y casos asociados a la predicción de demanda en tiendas de retail, desarrollando modelos robustos que permiten capturar efectos propios de las series de tiempo de ventas, como lo son patrones de tendencia y estacionalidad. Estos estudios muestran comparaciones en el rendimiento de diferentes modelos de predicción obteniendo diversos resultados de interés. Por ejemplo en [12], los autores comparan los modelos de espacio de estados con los modelos ARIMA al momento de realizar pronósticos (tanto de uno como varios pasos) para la venta de diferentes categorías de calzado femenino. Los resultados de este estudio muestran que cuando se utiliza un algoritmo automático, el rendimiento de ambos modelos en un pronóstico fuera de muestra son bastante similares, evaluando a través de criterios MAE, RMSE y MAPE. También concluye que dichos modelos producen probabilidades de cobertura cercanas a las tasas nominales para las predicciones de uno y varios pasos. En [4], se realiza una comparación entre modelos lineales y no lineales de pronóstico para ventas agregadas de retail, utilizando modelos de series de tiempo y regresiones con

variables ficticias de estacionalidad para el caso lineal, y redes neuronales para el caso no lineal. Este estudio concluye que los modelos no lineales se desempeñan de mejor forma que los lineales, y que un pre-ajuste estacional de los datos mejora significativamente el rendimiento del modelo de redes neuronales. Por otra parte, los modelos lineales tienen ventaja al momento de su implementación, ya que son de menor complejidad y requieren de menor capacidad de procesamiento.

La investigación presentada está enmarcada en el retail supermercadista de la Región Metropolitana (RM), en donde se utilizarán los datos de ventas de un proveedor de productos *food y non-food*. Con estos datos, se entrenan diferentes modelos de pronóstico de demanda para cada una de las categorías del proveedor en distintos locales de la RM. Así, identifica qué modelos responden mejor a las particularidades de cada una de las categorías, pudiendo generalizar modelos y replicar en los distintos locales. Una vez calibrados los modelos, se procede a estimar las horas hombre requeridas para las labores de reposición asociadas a las estimaciones de demanda realizadas. Para esto se calibra una función lineal afín que permite realizar una estimación de la cantidad de horas hombre necesarias por local en cada jornada, utilizando datos de mediciones de los tiempos de reposición obtenidas en el periodo diciembre 2019 - enero 2020. Finalmente, se realiza un modelo de predicción de quiebres de stock de productos a través de árboles de regresión y random forest, que permite determinar posibles hojas de ruta en la reposición de productos, optimizando el tiempo de trabajo.

Se cuenta con datos transaccionales diarios del proveedor en el periodo enero 2017 a la actualidad, en donde se puede encontrar data sobre categoría, unidades vendidas, precio, costo, SKU y local, entre otras variables. Además, se cuenta con el levantamiento de tiempos de diferentes actividades enmarcadas en las labores de reposición, como lo son el proceso de estimación de productos faltantes, proceso de reposición, recepción de productos y limpieza de góndolas, entre otras actividades. Para los tiempos de proceso de reposición, se cuenta con un desglose de información con tiempos de reposición por unidad para diversos productos del mix de SKU's del proveedor. Con respecto al modelo de quiebres de stock, se cuenta con datos de quiebres observados por SKU y local.

El objetivo del estudio presentado es obtener la mejor estimación posible de horas hombre requeridas por local con los datos en posesión, de forma que este resultado sea el input de un modelo de optimización de *scheduling* y ruteo, que permita una asignación eficiente de la fuerza de reposición, además de obtener una buena estimación de quiebres de stock que permitan optimizar y priorizar las actividades diarias que los trabajadores deben realizar en cada sala.

# Capítulo 1

## Datos

En el presente capítulo, se describen los datos utilizados en la investigación y la forma de obtención y recopilación de los mismos. Sumado a esto, se definen las variables que se utilizarán en el desarrollo de los modelos que se enmarcan en este trabajo.

### 1.1. Obtención de los datos

Los datos utilizados provienen principalmente de dos fuentes. La primera corresponde a datos de venta entregados por el proveedor de retail mediante la plataforma B2B *InStoreView*. Esta plataforma permite el almacenamiento y la descarga de los datos de venta diaria, stock y quiebres de cada producto en cada una de las tiendas asociadas, además de tener data sobre el local, cadena y subcadena, categoría de productos, monto vendido, entre otros campos. Una limitante de esta fuente de información es que el sistema de almacenamiento y descarga tiene un desfase de dos días, por lo que no se cuenta con datos en tiempo real y los análisis deben realizarse considerando este desfase.

Una segunda fuente de información corresponde a mediciones de tiempos de procesos en las labores de reposición realizadas en distintos locales de retail de la RM. Estas mediciones se realizaron mediante un levantamiento propio de la investigación, seleccionando un subconjunto de locales como muestra representativa del conjunto total de locales de la RM. En la sección 1.3 se abarcará con más detalle la forma en que se realiza la segmentación de locales realizada.

### 1.2. Datos

En relación a los datos de venta, se cuenta con los datos de 215 locales del país, correspondientes a las regiones de Tarapacá (I), Antofagasta (II), RM (XIII) y Arica y Parinacota (XV). A raíz de que la investigación se centra en la RM, este número de locales se reduce a 161. El nivel de agregación de los datos es diario, y se cuenta con un periodo temporal que abarca desde el 1 de enero del año 2017 hasta la actualidad, parcelados en bases de datos mensuales. En estas bases de datos, se puede encontrar la siguiente información.

Parámetros identificadores:

- *Cadena*: Corresponde a la cadena de retail de la observación. No se utilizará para los análisis.
- *Subcadena*: Corresponde a la subcadena de retail de la observación. No se utilizará para los análisis.
- *Local*: Corresponde al local al que se asocia la venta. Se identificará con el índice  $j$ .
- *Categoría*: Corresponde a la categoría o familia de producto al que pertenece la observación. Se identificará con el índice  $i$ .
- *Producto*: Corresponde al producto asociado a la observación. Se identificará con el índice  $p$ .
- *Fecha*: Corresponde a la fecha de la venta realizada. Se identificará con el índice  $t$ .

VARIABLES:

- $Unt_{ijkt}$ : Corresponde al número de unidades vendidas para el producto  $k$ , de la categoría  $i$ , en el local  $j$ , el día  $t$ .
- $CB2B_{ijkt}$ : Corresponde al costo B2B de las unidades vendidas del producto  $k$ , de la categoría  $i$ , en el local  $j$ , el día  $t$ .
- $Tonlts_{ijkt}$ : Corresponde al peso en toneladas o volumen en litros de las ventas del producto  $k$ , de la categoría  $i$ , en el local  $j$ , el día  $t$ .
- $Val_{ijkt}$ : Corresponde al monto vendido para el producto  $k$ , de la categoría  $i$ , en el local  $j$ , el día  $t$ .

Es importante recalcar que no hay productos que estén presentes en más de una categoría, pero en el estudio se realizarán análisis y pronósticos a nivel de categorías, para luego realizar las correspondientes detecciones de quiebre de stock a nivel de productos. Debido a esto, se usarán las combinaciones  $ijt$  y  $kjt$ , respectivamente y nunca se observarán combinaciones en las que se presenten los cuatro subíndices simultáneamente.

En relación a los datos de las labores de reposición, se cuenta con mediciones realizadas para 16 locales de la RM, durante tres jornadas. Estos datos entregan información sobre tiempos asociados a las tareas fijas de reposición (como lo son el registro de ingreso, la limpieza de góndolas, desecho de basura, entre otras) y los tiempos asociados a las tareas variables (reposición, estimación de productos faltantes, apantallado). Para el caso particular de la actividad de reposición, cada observación cuenta con un desglose de los productos que se reponen, donde se detalla el número de productos repuestos y el tiempo asociado a dicha reposición.

Finalmente y como adicional, se cuenta con datos meteorológicos históricos obtenidos desde el portal web *Weather Underground*, mostrando información sobre temperaturas máxima, mínima y promedio para cada día en el rango de estudio; y con datos del nivel de precipitaciones históricas obtenidos desde el portal de la *Dirección Meteorológica de Chile*. Estos datos se utilizarán únicamente como regresores de los modelos propuestos.

## 1.3. Análisis exploratorio de los datos

### 1.3.1. Análisis de ventas RM

En la figura 1.1 se puede observar la evolución de ventas semanales en unidades por categoría, agregadas a nivel RM.




Figura 1.1: Evolución de ventas semanales por categoría.

Se observa que las categorías con mayor nivel de ventas en unidades corresponden a Refrigerados y Galletas, seguidos por las categorías Culinarios, Chocolates y Lácteos Culinarios. Con respecto a las primeras dos categorías, se observa que superan por mucho las ventas de las demás categorías.

Con el objetivo de cuantificar esta diferencia, se construyen las figuras 1.2, 1.3 y 1.4, que muestran el porcentaje de ventas de cada categoría respecto a las ventas totales para los años 2017, 2018 y 2019, respectivamente. Se puede observar un comportamiento similar durante los tres años de observaciones: la categoría refrigerados representa cerca de un 30% de las ventas totales en unidades, seguido por Galletas con cerca de un 25%. La tercera categoría con mayor nivel de venta en unidades es Culinarios, con una participación cercana al 10%. Finalmente, las categorías Chocolate y Lácteos culinarios se llevan cerca de un 7% de las ventas totales. El resto de las categorías presenta ventas por bajo el 5% de las ventas totales.

En adelante, llamaremos a las categorías Refrigerados y Galletas como categorías de alta rotación; a las categorías Culinarios, Chocolates y Lácteos Culinarios como categorías de mediana rotación; y al resto de las categorías como categorías de baja rotación.




Figura 1.2: Porcentaje de ventas totales en unidades por categoría, 2017.




Figura 1.3: Porcentaje de ventas totales en unidades por categoría, 2018.

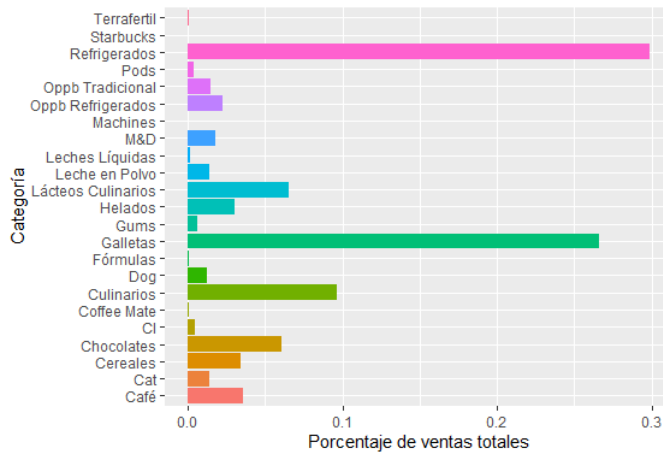


Figura 1.4: Porcentaje de ventas totales en unidades por categoría, 2019.

Continuando en esta línea, en las figuras 1.5 y 1.6 se muestra la distribución de las ventas semanales para las categorías de alta-media rotación y baja rotación, respectivamente. Para las categorías de alta y mediana rotación, se observa un comportamiento relativamente homogéneo en las ventas semanales, presentando algunos outliers por sobre el límite superior y bajo el límite inferior. Con respecto a las categorías de baja rotación, se puede observar que existen categorías que presentan un mayor grado de dispersión y una mayor cantidad de outliers. Por ejemplo las categorías Helados, Cereales y Café muestran un mayor grado de dispersión, mientras que las categorías Dog, Leche en Polvo y M&D presentan un mayor número de outliers.




Figura 1.5: Distribución de ventas semanales por categorías de rotación alta y media.

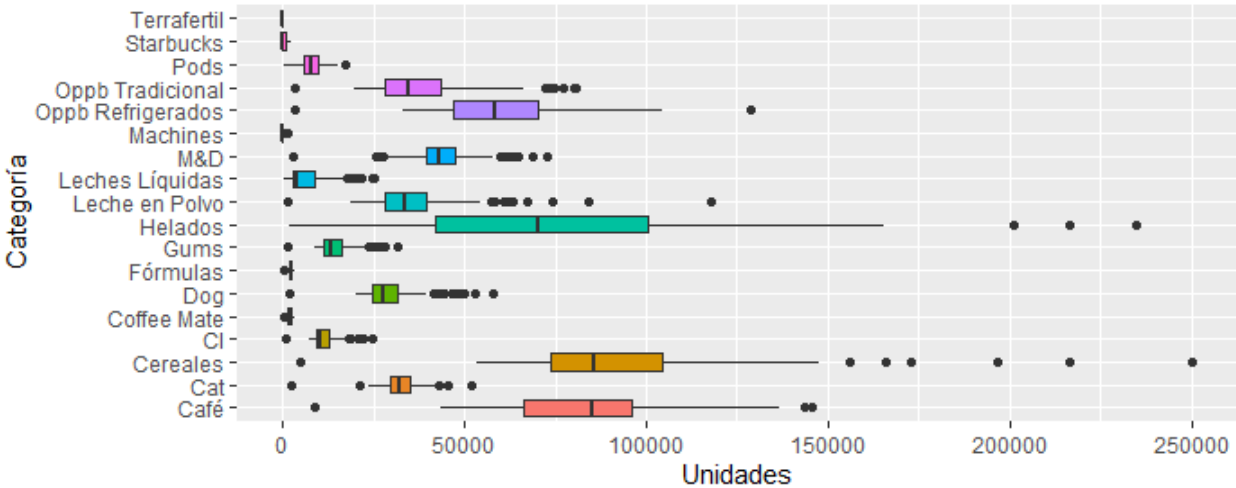


Figura 1.6: Distribución de ventas semanales por categoría de rotación baja.

En las figuras 1.7 y 1.8 se muestran nuevos gráficos de dispersión, para las ventas diarias por categoría, para las de alta-media rotación y las de baja rotación, respectivamente. Se observa que, a nivel desagregado por día, el comportamiento de la venta por categoría es similar al agregado semanal pero a menor escala. También se observa que existe una menor cantidad de outliers por categoría.



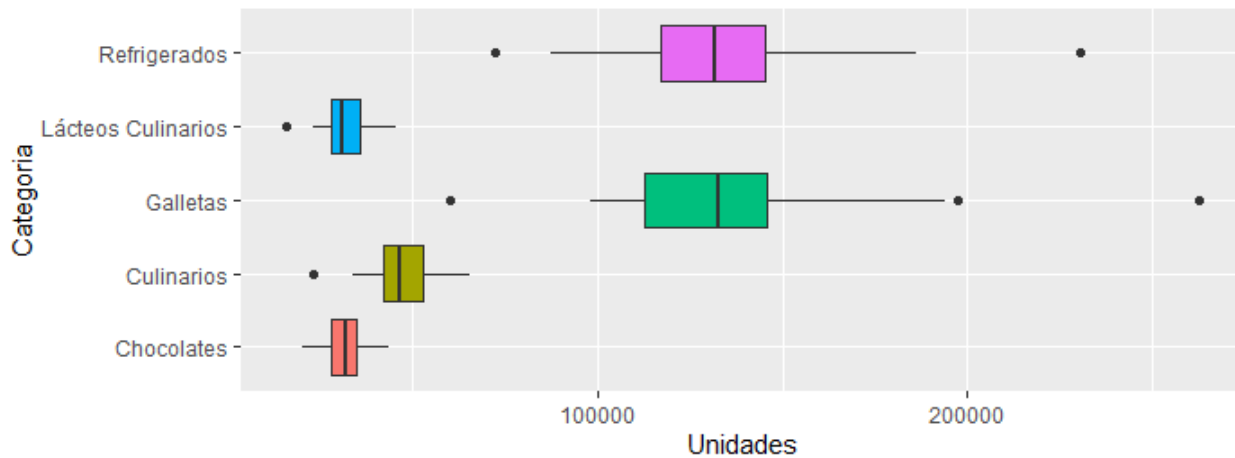


Figura 1.7: Distribución de ventas diarias por categorías de rotación alta y media.




Figura 1.8: Distribución de ventas diarias por categoría de rotación baja.

Las figuras 1.9 y 1.10 muestran la distribución del número promedio de ventas por categoría en los diferentes días de la semana. Se observa que para la gran mayoría de las categorías, el peak de ventas durante la semana se centra en los días sábado y domingo; comportamiento esperable debido a que gran parte de la población usa estos días para realizar compras. Dentro de estas observaciones es destacable observar el comportamiento de la categoría Helados, que durante el fin de semana aumenta sus ventas a más de el doble con respecto al día lunes. Además, las categorías Café y Leche en Polvo tienen su peak de ventas el día viernes, mientras que la categoría Pods lo presenta el día jueves.




Figura 1.9: Distribución ventas según día de la semana, para categorías de alta y media rotación.




Figura 1.10: Distribución de ventas según día de la semana, para categorías de baja rotación.

### 1.3.2. Análisis de ventas por locales

Una vez realizado el análisis a nivel RM, se procede a analogar dicho análisis pero a nivel de locales, pues la investigación y los modelos deben aplicarse a este nivel de agregación. Debido a la gran cantidad de locales presentes en la RM, se realiza una segmentación de locales para poder tratar de mejor forma los análisis. Para esto, se clasifican los locales mediante

el método de agrupación *k-medias*, generando clusters para locales de formato hipermercado y supermercado de forma independiente, utilizando el nivel de ventas en unidades como parámetro de segmentación. Para ambos grupos de locales (hiper y super) se utiliza el método del codo para definir el número de clusters que se definirá. Las figuras 1.11 y 1.12 muestran de forma gráfica los resultados de la aplicación del método del codo para los locales de tipo hipermercado y supermercado, respectivamente.




Figura 1.11: Método del codo para determinar número de clusters de locales formato hipermercado.

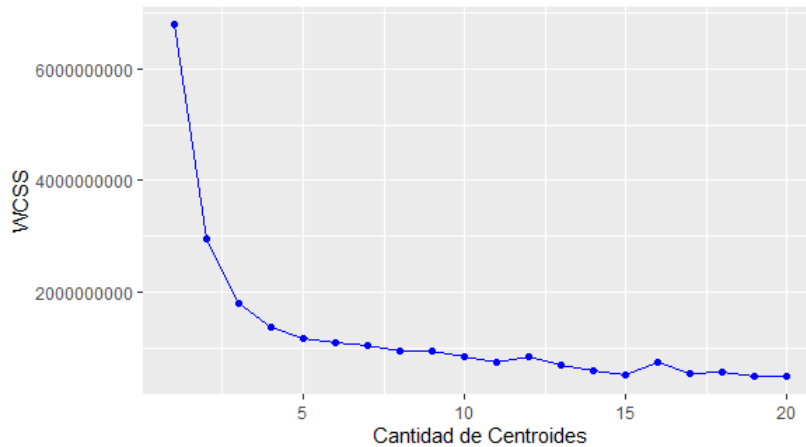


Figura 1.12: Método del codo para determinar número de clusters de locales formato supermercado.

Con esto, se determina que el número de clusters a utilizar tanto para hipermercados como para supermercados es 3. Así, en adelante se trabajará con un local representativo de cada segmento, donde los clusters 1 a 3 corresponden a locales de formato hipermercado y los clusters 4 a 6 corresponden a locales de tipo supermercado.

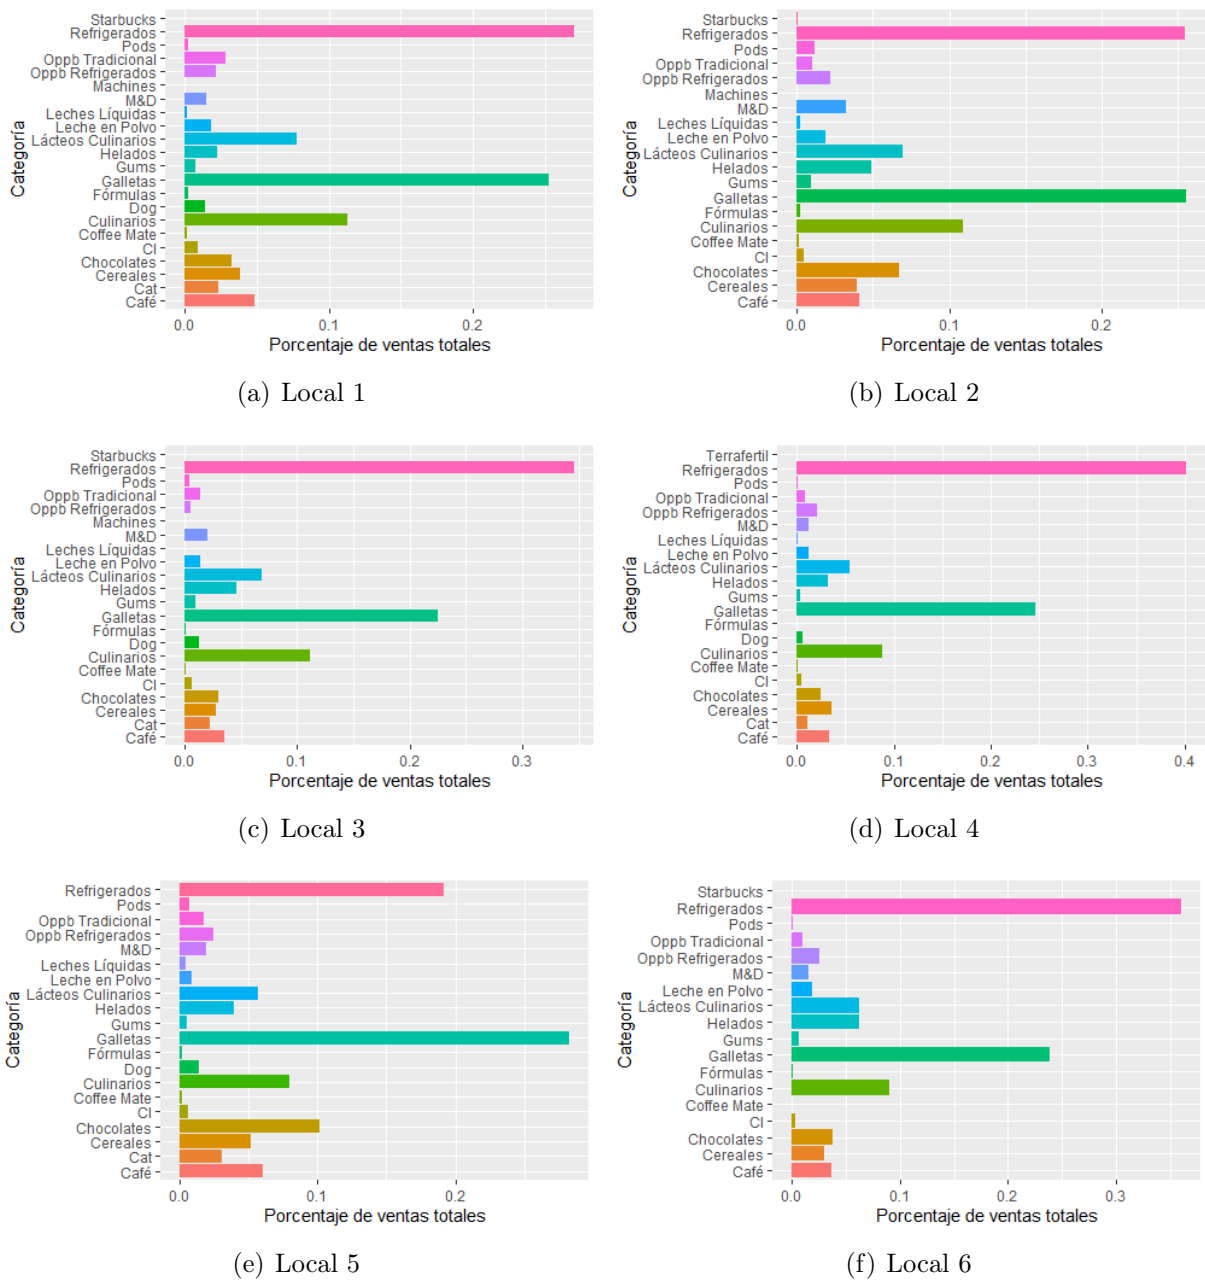
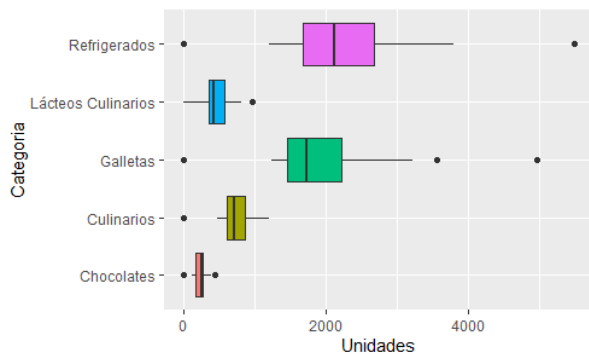


Figura 1.13: Porcentaje de ventas totales en unidades por categoría y local, 2019.

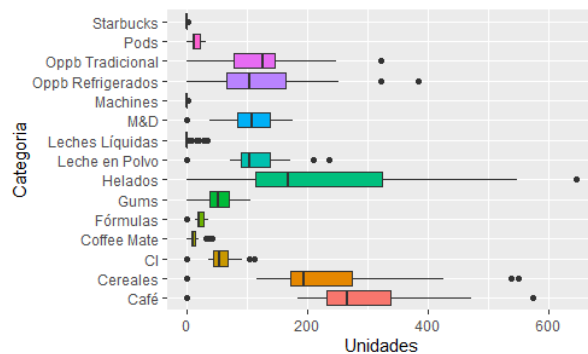
La figura 1.13 muestra el porcentaje de ventas con respecto a las ventas totales de cada uno de los locales seleccionados, para el año 2019. Con este nivel de agregación, es posible observar algunas diferencias al comportamiento visto en el inciso anterior. Si bien, las categorías con mayor rotación siguen siendo las mismas, hay variaciones porcentuales en el nivel de venta con respecto al comportamiento agregado RM. Para los locales 1 y 2, se observa que los niveles de ventas de las categorías Galletas y Refrigerados tienen menos diferencias que cuando se agregaba a RM, mientras que el nivel de ventas del resto de las categorías sigue un comportamiento similar al visto en RM. Con respecto a los locales 3 y 6 estos no presentan mayores diferencias en comportamiento respecto al visto en la sección anterior. El local 4 muestra un aumento considerable en la participación de la categoría Refrigerados, llegando

casi a un 40 %, mientras que el volumen de ventas de las categorías de baja rotación se ve disminuido aún más respecto al análisis RM El local 5, muestra diferencias en el nivel de venta de sus categorías, presentando la categoría Galletas como la que concentra mayor porcentaje de participación, aumenta la venta en Chocolates y las categorías Refrigerados y Lácteos Culinarios bajan sus niveles de ventas a cerca de un 19 % y 6 %, inferiores a los que presentan en otros locales. Se presume que este comportamiento se debe al formato del local número 5, ya que es un local más de paso que de abastecimiento.

Las figuras 1.14 a 1.19 muestran la distribución de ventas diarias por categoría en los diferentes locales. Con respecto a las categorías de rotación alta y media, se observa que en general, presentan poca dispersión de datos, a excepción de la categoría Refrigerados en los locales 3, 4 y 6, y la categoría Galletas en los locales 3 y 5. Con respecto a las categorías de baja rotación, es posible ver que todos los locales presentan un mayor grado de dispersión de datos, sobretodo la categorías Helados. Esto podría explicarse por la posible estacionalidad anual de la categoría. Otra cosa a destacar, es observar que el nivel de ventas diarias del local 5 es bastante inferior al de los demás locales, vendiendo entre 0 y 500 unidades para las categorías de alta rotación y entre 0 y 100 para las de baja rotación. Por otra parte, el local 1 es el que presenta mayores niveles de venta, moviendo cifras que van hasta las 4000 unidades diarias para categorías de alta rotación y hasta las 500 unidades para categorías de baja rotación. Esto se explica principalmente por el formato de los locales seleccionados.




(a) Categorías de rotación alta y media.




(b) Categorías de rotación baja.

Figura 1.14: Distribución de ventas diarias por categoría, Local 1.




(a) Categorías de rotación alta y media.

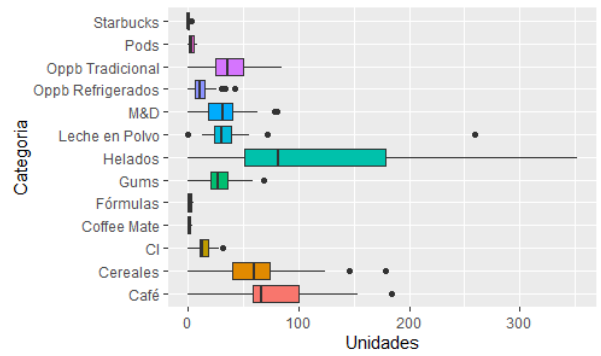


(b) Categorías de rotación baja.

Figura 1.15: Distribución de ventas diarias por categoría, Local 2.




(a) Categorías de rotación alta y media.




(b) Categorías de rotación baja.

Figura 1.16: Distribución de ventas diarias por categoría, Local 3.




(a) Categorías de rotación alta y media.




(b) Categorías de rotación baja.

Figura 1.17: Distribución de ventas diarias por categoría, Local 4.




(a) Categorías de rotación alta y media.




(b) Categorías de rotación baja.

Figura 1.18: Distribución de ventas diarias por categoría, Local 5.



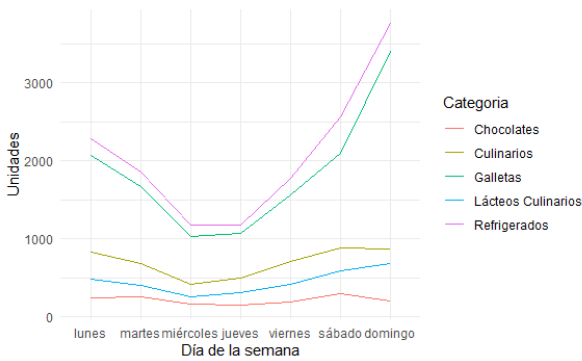
(a) Categorías de rotación alta y media.



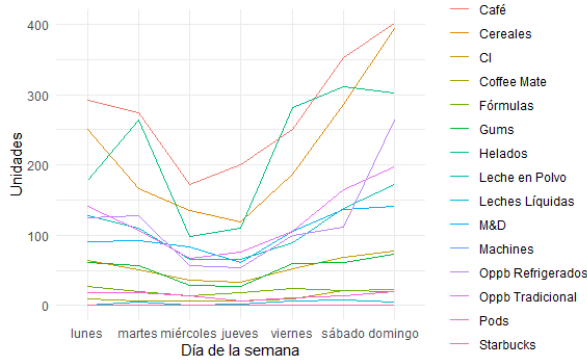
(b) Categorías de rotación baja.

Figura 1.19: Distribución de ventas diarias por categoría, Local 6.

Finalmente, las figuras 1.20 a 1.25 muestran la distribución de ventas según el día de la semana, por categorías para cada local.




(a) Categorías de rotación alta y media.




(b) Categorías de rotación baja.

Figura 1.20: Distribución de ventas según día de la semana, por categoría en Local 1.

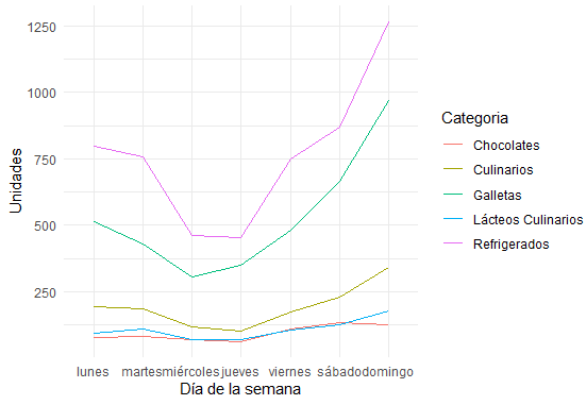


(a) Categorías de rotación alta y media.




(b) Categorías de rotación baja.

Figura 1.21: Distribución de ventas según día de la semana, por categoría en Local 2.




(a) Categorías de rotación alta y media.




(b) Categorías de rotación baja.

Figura 1.22: Distribución de ventas según día de la semana, por categoría en Local 3.




(a) Categorías de rotación alta y media.




(b) Categorías de rotación baja.

Figura 1.23: Distribución de ventas según día de la semana, por categoría en Local 4.



(a) Categorías de rotación alta y media.



(b) Categorías de rotación baja.

Figura 1.24: Distribución de ventas según día de la semana, por categoría en Local 5.



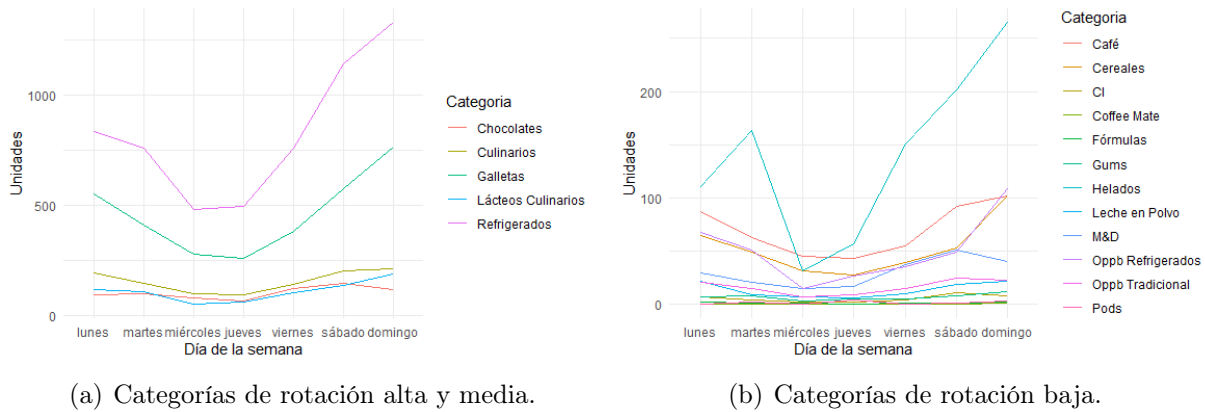


Figura 1.25: Distribución de ventas según día de la semana, por categoría en Local 6.

Se observa para todos los locales un efecto del día de la semana. Generalmente, y concordando con el comportamiento agregado a RM, los peaks de venta se registran durante los días viernes, sábado y domingo. También es posible observar que la categoría Helados, tiene además un peak de ventas los días martes consistentemente en todos los locales. Es importante considerar estos efectos para los modelos, ya que cada categoría podría presentar un efecto de estacionalidad semanal propia.

### 1.3.3. Efecto 18 Octubre y Pandemia

Es importante mencionar que, dentro del periodo de realización de esta investigación, ocurrieron dos sucesos importantes que afectaron los niveles de venta y el comportamiento de los consumidores: el estallido social del 18 de octubre de 2019 y el confinamiento producido por la pandemia COVID-19 en 2020. La figura 1.20 destaca el efecto de estos periodos en la evolución de ventas semanales.





Figura 1.26: Efecto de 18 de octubre y pandemia en evolución de ventas semanales.


Se observa que el efecto del estallido social del 18 de octubre presenta un impacto negativo en las ventas que perdura hasta mediados del mes de febrero del 2020, disminuyendo en aproximadamente un 30% las ventas por categoría. Luego, se observa un periodo de recuperación del nivel de venta en marzo. Finalmente se observa un nuevo decaimiento en el

nivel de venta, producido en un principio por la cuarentena que inició a finales del mes de marzo en las comunas del sector oriente de Santiago, para consolidarse la cuarentena total en Santiago en el mes de Mayo.

Además, debido al confinamiento se presume que el comportamiento de compras de los consumidores a lo largo de la semana pudo haber variado. Este efecto se presenta en la figura 1.21, donde se observa que para la gran mayoría de las categorías el efecto de estacionalidad semanal tiende a desaparecer, mostrando patrones mucho más aplanados y distribuidos a lo largo de la semana.



(a) Categorías de rotación alta y media.



(b) Categorías de rotación baja.

Figura 1.27: Distribución de ventas según día de la semana por categoría, en el periodo de confinamiento.

Debido a las complicaciones que supone incluir estos periodos en la calibración de los modelos de predicción, se toma la decisión de trabajar únicamente con la data comprendida entre enero de 2017 y septiembre de 2019.

# Capítulo 2

## Levantamiento de procesos

Previo a realizar un desarrollo de solución, es importante entender en profundidad el proceso de trabajo que realizan los reponedores de supermercados diariamente. Si bien, cada cadena supermercadista puede presentar particularidades que modifican levemente el proceso de reposición, el lineamiento general de este es el que se muestra en la figura 2.1. Diariamente, el reponedor inicia la jornada haciendo un check-in en la tienda, donde registra su entrada al local y se prepara para el ingreso a la sala de ventas. Una vez en la sala de ventas, el reponedor realiza una primera inspección al sector denominado “frentes de caja” (pequeñas góndolas situadas al lado de las cajas, generalmente con productos de consumo impulsivo), puesto a que el proveedor tiene como regla de negocios mantener disponibilidad de productos siempre estos puntos. Luego de reponer este sector, se realiza una inspección por los pasillos de la sala, observando qué productos se deberán reponer durante la jornada. Una vez terminada la inspección, se procede a reponer los productos que tengan disponibilidad y apantallar aquellos que no la tengan. Este par de procesos (inspección y reposición/apantallamiento) se repiten las veces que sea necesario para completar las necesidades de la sala. Una vez terminada la reposición, el reponedor destina el resto de su jornada a realizar actividades complementarias al proceso de reposición. Dentro de estas actividades complementarias podemos encontrar: limpieza de góndolas y flejeras, poner precio a productos, redistribución de productos no comprados, inventarios, creación de órdenes de compra, entre otras.

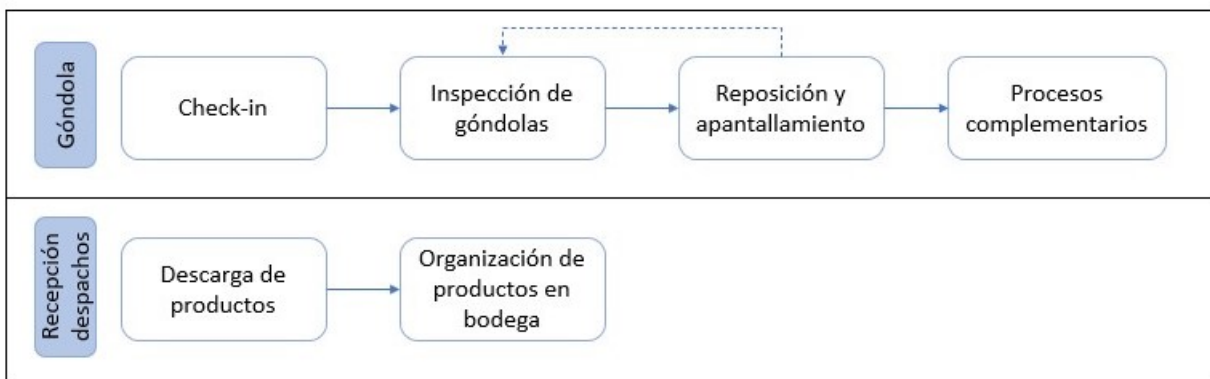


Figura 2.1: Macro-procesos labores de reposición.

Además de estas actividades asociadas principalmente al trabajo en la sala de ventas, se encuentran las actividades asociadas a la recepción de despachos y la gestión de productos en bodega. La recepción de despachos es el proceso en el que se reciben productos desde camiones que llegan al local, se corrobora la cuadratura de productos con la guía de despacho y se deja constancia de la recepción. Este proceso no se realiza necesariamente todos los días, ya que dependiendo del local y su nivel de ventas, se define la frecuencia de envío de productos. Así, locales con mayor nivel de ventas presentan generalmente una frecuencia de despachos mayor a locales con bajo nivel de ventas. Otro factor importante es que este proceso tampoco tiene un horario fijo, pues depende del momento del día en el que llega el camión con productos, por lo cual una vez llega el camión, el reponedor debe dejar la actividad que esté realizando para poder gestionar el ingreso de los productos. Una vez terminada la recepción, retoma las labores que haya estado haciendo previo a la llegada del camión. Con respecto a la organización de productos en bodega, esta siempre se hace en algún momento posterior al proceso de descarga de productos, generalmente una vez el reponedor haya terminado las labores diarias de procesos en góndolas. En este proceso, se gestionan los productos recepcionados, de forma de mantener un sistema de almacenaje FIFO (first in first out).

Debido a lo variable que puede ser el tiempo de trabajo que toman estas actividades, es que actualmente los proveedores han notado que usualmente están sobre-dotados de personal para cubrir dichas fluctuaciones. Así, se vuelve necesario diseñar una herramienta que permita facilitar la toma de decisiones respecto a la dotación de mercaderistas (mediante el pronóstico de tiempo de reposición necesario por local) y optimizar los tiempos que toman las tareas (mediante la detección de quiebres de stock). Respecto a esto, es posible visibilizar diferentes horizontes de decisión operacional según el nivel de agregación con que se trabaje.

		Nivel de agregación	
		Categoría	SKU
Horizonte de decisión	Diario	Dotación de reponedores	Detección de quiebres de stock
	Semanal	Frecuencia de reposición	Detección de quiebres de stock (SKU de baja rotación)

Figura 2.2: Horizonte de decisión vs. nivel de agregación.

En la figura 2.2 se pueden observar las combinaciones de horizonte de decisión y nivel de agregación necesarias para determinar y diseñar los modelos de toma de decisiones. Con esto, se diseña la siguiente estructura de solución.

- **Planificación de dotación de personal:** para una correcta planificación del número de trabajadores que se necesitan para cumplir las labores de reposición de las diferentes salas de la RM, se debe realizar en primera instancia un pronóstico de demanda diario con un nivel de agregación en categorías de productos. Este pronóstico de demanda permitirá estimar cuántos productos deben ser repuestos día a día, con lo cual se puede

generar un modelo de estimación de tiempos diarios de reposición por sala. Finalmente, conociendo el tiempo diario de reposición por sala, se puede desarrollar un modelo de optimización y asignación capaz de determinar el número óptimo de trabajadores necesarios para cubrir las necesidades de todas las salas (este último punto está fuera de los alcances de esta investigación).

- **Planificación de actividades diarias:** con el objetivo de optimizar las actividades diarias de los trabajadores y diseñar rutas de priorización dentro de la sala, se deben desarrollar modelos de predicción de quiebres de stock de productos, que indiquen a los reponedores qué productos pueden estar sin disponibilidad de ventas y focalicen el trabajo en esos productos. Debido a que existen productos que naturalmente tienen diferentes niveles de venta, es que estos modelos deben diseñarse considerando los dos horizontes de decisión propuestos. Así, para generar un modelo de detección de quiebres de stock para productos de alta y mediana rotación, se debe generar en primera instancia un modelo de pronóstico de demanda diario a nivel de SKU, mientras que para los productos de baja rotación se debe generar un modelo de pronóstico de demanda semanal a nivel de SKU. Una vez se tenga dicho pronóstico, es posible desarrollar el modelo de pronóstico de quiebres de stock.

Con esta propuesta de solución, se procede a desarrollar los modelos mencionados.

# Capítulo 3

## Estimación de demanda

### 3.1. Formulación de modelos de estimación de demanda

Una vez estudiado el comportamiento de las ventas y entendido el proceso de reposición, se procede a realizar modelos que permitan estimar la demanda diaria agregada por categoría. Estos modelos se formulan para cada local y para cada categoría, con el objetivo de tener mayor precisión en las estimaciones que luego se utilizarán para el pronóstico de tiempos de reposición por local. Para esto, se consideran inicialmente tres modelos: ARIMA, Exponential Smoothing y Prophet.

#### 3.1.1. Modelo ARIMA

ARIMA<sup>1</sup> combina factores de auto regresión y medias móviles, generalizando un modelo paramétrico de diferentes ordenes, que depende de dichos valores. Este modelo es uno de los más usados para aproximaciones de series de tiempo y sus respectivos pronósticos, ya que apunta a describir la autocorrelación de los datos.

Considerando que tenemos datos seriales sobre las ventas diarias de las  $i$  categorías en los  $j$  locales ( $Unit_{ijt}$ ), se describe el siguiente modelo  $ARIMA(p, d, q)$  para ajustar la data:

- Modelo 1: ARIMA

$$D'_{ijt} = c + \phi_1 D'_{ij(t-1)} + \dots + \phi_p D'_{ij(t-p)} + \theta_1 \varepsilon_{ij(t-1)} + \dots + \theta_q \varepsilon_{ij(t-q)} + \gamma_{ijt} \quad (3.1)$$

donde  $D'_{ijt}$  es la serie diferenciada de orden  $d$  para la categoría  $i$ , en el local  $j$  en el día  $t$ ;  $\phi$  son los coeficientes asociados a los retardos de la serie autoregresiva de orden  $p$ ;  $\theta$  los coeficientes asociados a la media móvil de orden  $q$  y  $\gamma_{ijt}$  es ruido blanco.

#### 3.1.2. Modelo Exponential Smoothing

El modelo Exponential Smoothing es un punto medio entre los modelos Naïve method (que estima que todas las observaciones futuras serán iguales al último valor de la serie de

---

<sup>1</sup>Autoregressive Integrated Moving Average.

tiempo, es decir, todo el peso de la predicción se concentra en el último valor observado) y el Average method (que estima los valores futuros como iguales al promedio simple de los datos observados, dándole el mismo peso a cada elemento del dataset). Este modelo provee la capacidad de darle mayor peso a las observaciones más recientes y un menor peso a aquellas lejanas al periodo sujeto a predicción. Dicho esto, se describe el siguiente modelo Exponential Smoothing con suavizamiento de nivel y tendencia para la estimación de las ventas diarias por categoría  $i$  en el local  $j$ :

- Modelo 2: Exponential smoothing

$$\begin{aligned}
 \hat{D}_{ij(t+h|t)} &= l_t + hb_t + c_{t-L+1+(h-1)_{\text{mod}L}} \\
 l_0 &= D_{ij0} \\
 l_t &= \alpha(D_{ijt} - c_{t-L}) + (1 - \alpha)(l_{t-1} + b_{t-1}) \\
 b_t &= \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1} \\
 c_t &= \gamma(D_{ijt} - l_{t-1} - b_{t-1}) + (1 - \gamma)c_{t-L}
 \end{aligned} \tag{3.2}$$

donde  $l_t$  representa una estimación del nivel de los datos en  $t$ ;  $b_t$  representa una estimación de la tendencia en  $t$ ;  $h$  representa el número de periodos en el futuro que queremos pronosticar;  $L$  representa el largo del ciclo de la estacionalidad y  $\alpha$ ,  $\beta$  y  $\gamma$  representan los parámetros de suavización para el nivel, la tendencia y la estacionalidad, respectivamente. Los valores de estos parámetros se estiman mediante máxima verosimilitud y se restringen a  $0 < \alpha, \beta, \gamma < 1$

### 3.1.3. Modelo Prophet

El modelo Prophet [13] desarrollado por Facebook<sup>2</sup>, es un modelo aditivo diseñado para pronosticar y operar las características de las series de tiempo. Este modelo se construye principalmente con tres componentes: una función de tendencia  $g(t)$  que modela los cambios aperiódicos, una función periódica  $s(t)$  que modela estacionalidades y una función  $h(t)$  de efectos de fechas especiales que podrían tener impacto en uno o más días puntuales. Así, el modelo se especifica:

$$y(t) = g(t) + s(t) + h(t) \tag{3.3}$$

La función de tendencia  $g(t)$ , presenta tres posibles configuraciones: tendencia no lineal, crecimiento no lineal saturado y tendencia lineal con quiebres. Para el caso particular de estudio, se usará la configuración de tendencia lineal con quiebres, ya que le permite al modelo ajustar la tendencia cada vez que detecta un cambio en los patrones de las observaciones, modificando el parámetro de crecimiento. Para esta configuración, la componente se formula:

$$g(t) = (k + \mathbf{a}(t)^T \boldsymbol{\delta})t + (m + \mathbf{a}(t)^T \boldsymbol{\gamma}) \tag{3.4}$$

donde  $k$  es la tasa de crecimiento,  $\boldsymbol{\delta}$  es el vector de tasas de ajuste,  $m$  es un parámetro de compensación y  $\boldsymbol{\gamma}$  es el vector de quiebres de tendencia.

---

<sup>2</sup><https://facebook.github.io/prophet/>

Con respecto a la función de estacionalidad  $s(t)$ , se construye como una serie de Fourier que puede ser adaptada dependiendo del tipo de estacionalidad que se quiera agregar (diaria, semanal, anual). Así, este componente se formula:

$$s(t) = \sum_{n=1}^N \left( a_n \cos \left( \frac{2\pi nt}{P} \right) + b_n \sin \left( \frac{2\pi nt}{P} \right) \right) \quad (3.5)$$

donde  $P$  es el periodo regular de la estacionalidad (365,25 para la anual, 7 para semanal) y  $N$  el orden de la serie de Fourier. Los autores presentan evidencia de que  $N = 10$  y  $N = 3$  funcionan sin problema para estimar estacionalidad anual y semanal, respectivamente.

Finalmente, para la función de fechas especiales  $h(t)$  se formula mediante un vector de indicatrices. Para cada fecha especial  $f$ , se construye el conjunto  $D_f$  de fechas de los eventos pasados y futuros de dicha fecha especial. Con esto se formula:

$$\begin{aligned} h(t) &= Z(t)\boldsymbol{\kappa} \\ Z(t) &= [\mathbf{1}_{\{t \in D_1\}}, \dots, \mathbf{1}_{\{t \in D_F\}}] \end{aligned} \quad (3.6)$$

donde  $\boldsymbol{\kappa}$  corresponde al vector de parámetros asociado a cada fecha especial.

Conociendo la formulación general del modelo Prophet, para el caso de estudio se formula:

- Modelo 3: Prophet sin efectos de fechas especiales

$$\begin{aligned} \hat{D}_{ijt} &= (k_{ijt} + \mathbf{a}_{ij}(t)^T \boldsymbol{\delta}_{ij})t + (m_{ij} + \mathbf{a}_{ij}(t)^T \boldsymbol{\gamma}_{ij}) + \sum_{n=1}^{10} \left( a_n \cos \left( \frac{2\pi nt}{365,25} \right) + b_n \sin \left( \frac{2\pi nt}{365,25} \right) \right) \\ &+ \sum_{n=1}^3 \left( a_n \cos \left( \frac{2\pi nt}{7} \right) + b_n \sin \left( \frac{2\pi nt}{7} \right) \right) \end{aligned} \quad (3.7)$$

En el modelo no se incluye la componente de fechas especiales, con el objetivo de poder comparar de mejor forma con los modelos ARIMA y Exponential Smoothing.

## 3.2. Resultados modelos y comparación

Los modelos presentados en el inciso anterior, se entrenan con data comprendida entre el 1 de enero de 2017 y el 31 de agosto de 2019, para los seis locales vistos en el capítulo 1. Luego, se realiza un pronóstico de demanda agregada para tres categorías de alta y media rotación: Refrigerados, Galletas y Culinarios. El pronóstico se realiza para un horizonte temporal de 10 periodos, fuera de la muestra de entrenamiento.



En las tablas 3.1 a 3.3 se muestra el MAPE<sup>3</sup> fuera de muestra de los modelos para las distintas categorías y locales.

	Local 1			Local 2		
	ARIMA	Exp Smth	Prophet	ARIMA	Exp Smth	Prophet
Refrigerados	21.44 %	25.41 %	19.28 %	24.17 %	24.98 %	20.56 %
Galletas	25.41 %	26.12 %	23.21 %	35.09 %	36.33 %	30.14 %
Culinarios	30.19 %	28.14 %	22.69 %	35.58 %	31.56 %	30.19 %

Tabla 3.1: MAPE fuera de muestra modelos estimación de demanda agregada para locales 1 y 2.

	Local 3			Local 4		
	ARIMA	Exp Smth	Prophet	ARIMA	Exp Smth	Prophet
Refrigerados	26.97 %	27.91 %	27.58 %	37.12 %	35.76 %	31.11 %
Galletas	20.66 %	20.19 %	13.85 %	26.77 %	28.12 %	25.84 %
Culinarios	25.70 %	26.40 %	25.89 %	20.43 %	21.61 %	16.13 %

Tabla 3.2: MAPE fuera de muestra modelos estimación de demanda agregada para locales 3 y 4.

	Local 5			Local 6		
	ARIMA	Exp Smth	Prophet	ARIMA	Exp Smth	Prophet
Refrigerados	25.61 %	24.17 %	18.03 %	28.64 %	30.59 %	23.47 %
Galletas	57.27 %	54.88 %	37.56 %	39.43 %	36.09 %	29.76 %
Culinarios	35.27 %	20.62 %	31.27 %	29.92 %	30.12 %	27.53 %

Tabla 3.3: MAPE fuera de muestra modelos estimación de demanda agregada para locales 5 y 6.

De las tablas expuestas, es posible observar que, al comparar los modelos para una misma categoría y un mismo local, los modelos que presentan un menor MAPE (recordando que menor MAPE implica menor error en la estimación) son los modelos Prophet en la gran mayoría de los casos. Se observa que únicamente en las categorías Refrigerados y Culinarios del local 3 el modelo ARIMA tiene un mejor desempeño, mientras que en la categoría Culinarios del local 5 se observa el mejor desempeño con el modelo Exponential Smoothing. No obstante, las diferencias entre modelos para estos casos son inferiores a dos puntos porcentuales, por lo que no interfiere sustantivamente en la comparación de los modelos. Por otra parte, al comparar el modelo ARIMA contra el de Exponential Smoothing no se observan diferencias significativas en sus resultados, siendo en algunos casos mejor ARIMA y en otros Exponential Smoothing.

Con esto, se decide en adelante refinar el modelo Prophet, con el objetivo de reducir los errores porcentuales de las estimaciones.

---

<sup>3</sup>Mean Absolute Percentage Error, es un indicador de precisión de predicción, que mide el error absoluto en términos porcentuales de la estimación.

### 3.3. Refinamiento modelo Prophet

Como se pudo apreciar en la sección anterior, el modelo Prophet fue el que tuvo el mejor desempeño entre los tres modelos testeados. Se presume que estos mejores resultados se deben a la mayor complejidad de los componentes del modelo. Aún así se cree que es posible obtener mejores resultados. Como primera mejora, se incluye una componente que modele la estacionalidad mensual para capturar el efecto que tienen quincenas y fines de mes (elemento de Fourier de orden 5 y periodo 30,5). Como segunda mejora, se incluyen las fechas especiales ( $h(t)$ ) que consideran feriados renunciables e irrenunciables, además de un periodo de dos días pre y post feriado, pues se sospecha que el efecto de los días feriados pueda distribuirse en los días previos y posteriores al mismo. También dentro de esta componente, se incluyen los efectos asociados a fechas especiales como semana santa, halloween, fiestas patrias y navidad. Se testearán las mejoras en dos pasos, primero ajustando y pronosticando únicamente con la inclusión de la componente de estacionalidad mensual; y luego ajustando y prediciendo el modelo completo (aquel que incluye las dos mejoras). Con esto, se formulan los siguientes modelos que incluyen las componentes recién mencionadas:

- Modelo 4: Prophet con inclusión de estacionalidad mensual.

$$\begin{aligned} \hat{D}_{ijt} = & (k_{ijt} + \mathbf{a}_{ij}(t)^T \boldsymbol{\delta}_{ij})t + (m_{ij} + \mathbf{a}_{ij}(t)^T \boldsymbol{\gamma}_{ij}) + \sum_{n=1}^{10} \left( a_n \cos \left( \frac{2\pi nt}{365, 25} \right) + b_n \sin \left( \frac{2\pi nt}{365, 25} \right) \right) \\ & + \sum_{n=1}^5 \left( a_n \cos \left( \frac{2\pi nt}{30,5} \right) + b_n \sin \left( \frac{2\pi nt}{30,5} \right) \right) + \sum_{n=1}^3 \left( a_n \cos \left( \frac{2\pi nt}{7} \right) + b_n \sin \left( \frac{2\pi nt}{7} \right) \right) \end{aligned} \quad (3.8)$$

- Modelo 5: Prophet con inclusión de estacionalidad mensual y fechas especiales.

$$\begin{aligned} \hat{D}_{ijt} = & (k_{ijt} + \mathbf{a}_{ij}(t)^T \boldsymbol{\delta}_{ij})t + (m_{ij} + \mathbf{a}_{ij}(t)^T \boldsymbol{\gamma}_{ij}) + \sum_{n=1}^{10} \left( a_n \cos \left( \frac{2\pi nt}{365, 25} \right) + b_n \sin \left( \frac{2\pi nt}{365, 25} \right) \right) \\ & + \sum_{n=1}^5 \left( a_n \cos \left( \frac{2\pi nt}{30,5} \right) + b_n \sin \left( \frac{2\pi nt}{30,5} \right) \right) + \sum_{n=1}^3 \left( a_n \cos \left( \frac{2\pi nt}{7} \right) + b_n \sin \left( \frac{2\pi nt}{7} \right) \right) + Z(t) \boldsymbol{\kappa}_{ij} \end{aligned} \quad (3.9)$$

Nuevamente, se entrenan los modelos con datos comprendidos entre el 1 de enero de 2017 y el 31 de agosto de 2019, para los cuatro locales en cuestión. Además, se decide incluir en el testeo una categoría de baja rotación para chequear como se comporta el modelo en estos casos. Así, las categorías con las que se trabaja este modelo son: Refrigerados, Galletas, Culinarios y Fórmulas. Los pronósticos esta vez se realizan para dos horizontes temporales fuera de muestra: uno de 8 días y uno de 30 días.

En las tablas 3.4 a 3.7 se presentan los valores de MAPE fuera de muestra para los modelos 4 y 5 con horizontes temporales de 8 y 30 días, para los 6 locales y las 4 categorías mencionadas anteriormente.

Modelo 4, horizonte 8 días				
	Culinarios	Fórmulas	Galletas	Refrigerados
Local 1	15.60 %	23.85 %	20.65 %	27.79 %
Local 2	18.29 %	38.08 %	21.62 %	25.15 %
Local 3	25.89 %	56.57 %	13.85 %	27.58 %
Local 4	16.13 %	37.06 %	25.94 %	31.11 %
Local 5	36.27 %	42.59 %	37.56 %	18.03 %
Local 6	22.19 %	39.94 %	23.12 %	27.33 %

Tabla 3.4: MAPE fuera de muestra modelo Prophet con inclusión de estacionalidad mensual, con horizonte de predicción de 8 días.

Modelo 5, horizonte 8 días				
	Culinarios	Fórmulas	Galletas	Refrigerados
Local 1	19.84 %	27.12 %	23.49 %	18.34 %
Local 2	20.76 %	40.03 %	22.37 %	21.13 %
Local 3	28.05 %	57.67 %	13.89 %	27.79 %
Local 4	13.89 %	36.64 %	20.70 %	29.16 %
Local 5	33.27 %	44.92 %	35.31 %	18.32 %
Local 6	25.12 %	49.47 %	21.65 %	19.81 %

Tabla 3.5: MAPE fuera de muestra modelo Prophet con inclusión de estacionalidad mensual y fechas especiales, con horizonte de predicción de 8 días.

Modelo 4, horizonte 30 días				
	Culinarios	Fórmulas	Galletas	Refrigerados
Local 1	17.78 %	24.10 %	21.02 %	17.95 %
Local 2	20.10 %	41.93 %	25.28 %	24.34 %
Local 3	30.44 %	58.59 %	30.97 %	24.93 %
Local 4	25.49 %	42.64 %	17.41 %	26.58 %
Local 5	42.83 %	44.70 %	36.76 %	17.05 %
Local 6	25.43 %	44.86 %	26.46 %	25.76 %

Tabla 3.6: MAPE fuera de muestra modelo Prophet con inclusión de estacionalidad mensual, con horizonte de predicción de 30 días.

Modelo 5, horizonte 30 días				
	Culinarios	Fórmulas	Galletas	Refrigerados
Local 1	21.87 %	21.22 %	16.19 %	20.92 %
Local 2	21.03 %	39.87 %	24.43 %	22.85 %
Local 3	37.31 %	55.16 %	28.66 %	24.45 %
Local 4	30.26 %	42.82 %	18.68 %	22.15 %
Local 5	32.20 %	49.08 %	31.78 %	20.38 %
Local 6	25.99 %	53.16 %	23.13 %	22.46 %

Tabla 3.7: MAPE fuera de muestra modelo Prophet con inclusión de estacionalidad mensual y fechas especiales, con horizonte de predicción de 30 días.

Lo primero que se puede observar es que el pronóstico de la nueva categoría incluida, tiene un rendimiento inferior que el resto de las categorías al medir mediante MAPE. Esto puede ser originado debido a la misma naturaleza de baja rotación de la categoría, pues mientras menor sea la observación real, el error porcentual de equivocarse en una unidad en el pronóstico es mayor. Debido a esto, se cree que para las categorías de menor rotación se debe utilizar un modelo de estimación diferente.

En las tablas 3.3 y 3.4 se puede observar que el incluir las fechas especiales no se traducen necesariamente en una mejora de los resultados del MAPE, pues en algunos casos el MAPE de la estimación empeora. Es importante mencionar que estas variaciones porcentuales (tanto de aumento como de reducción), son inferiores a un 5 %. Se presume que el aumento en el MAPE al incluir las fechas especiales puede estar siendo producido por un sobreajuste del modelo.

Al comparar los modelos de 8 días con los de 30 días se puede observar que, en general el MAPE aumenta. Este resultado es esperable, pues se está prediciendo una mayor cantidad de días. Otra cosa que vale la pena mencionar es que la categoría Refrigerados disminuye su MAPE para todos los locales cuando se estima usando el modelo sin fechas especiales. No es posible generalizar este último hallazgo para el modelo que incluye las fechas especiales, ya que solo mejora en 2 de los 4 locales.

Finalmente, al comparar los resultados de ambos modelos a 30 días, se puede realizar la misma observación que cuando se comparaban los modelos a 8 días. Los aumentos o disminuciones del error, no siguen un patrón consistente, por lo que no es posible determinar cuál de los dos modelos tiene un mejor resultado.

### 3.4. Rolling Forecast

Finalmente, con el objetivo de testear el comportamiento de las predicciones en un horizonte temporal más amplio y extender los resultados verificando que los mismos no son una buena o mala coincidencia local, se realiza un rolling forecast para las categorías y locales vistos anteriormente.

Un rolling forecast consiste en una serie de predicciones continuas en un horizonte temporal, actualizando la data para pronosticar diferentes periodos. En la figura 2.1 se puede observar

una representación gráfica de cómo funciona un rolling forecast. En [14], los autores declaran que al mantener un horizonte actualizado continuamente y al requerir la entrada de datos actuales, los pronósticos continuos permiten a la administración asignar apropiadamente sus recursos a inversiones discretionales. Una previsión adecuada permite a la empresa comparar dónde se encuentran, adónde pueden ir y, en última instancia, adónde quieren estar.




Figura 3.1: Representación gráfica de un rolling forecast.

Previo a la ejecución del rolling forecast, se modifican los modelos de la sección anterior, incluyendo regresores asociados a factores climáticos de la Región Metropolitana. Para esto, se cuenta con dos bases de datos: una obtenida del sitio *Weather Underground* que entrega información sobre temperaturas mínima, máxima y promedio para cada día; y otra obtenida desde el portal de la *Dirección Meteorológica de Chile* que entrega información sobre el nivel de precipitación diaria en mm. Así, se definen 3 nuevas variables:

- $Tmin_t$  : Temperatura mínima del día  $t$ .
- $Tmax_t$  : Temperatura máxima del día  $t$ .
- $Precip_t$  : Volumen de precipitación medido en mm del día  $t$ .

De esta forma, los nuevos modelos a testear en el rolling forecast son los siguientes:

- Modelo 6: Prophet con inclusión de estacionalidad mensual y factores climáticos.

$$\begin{aligned}
 \hat{D}_{ijt} = & (k_{ijt} + \mathbf{a}_{ij}(t)^T \boldsymbol{\delta}_{ij})t + (m_{ij} + \mathbf{a}_{ij}(t)^T \boldsymbol{\gamma}_{ij}) \\
 & + \sum_{n=1}^{10} \left( a_n \cos \left( \frac{2\pi nt}{365,25} \right) + b_n \sin \left( \frac{2\pi nt}{365,25} \right) \right) + \sum_{n=1}^5 \left( a_n \cos \left( \frac{2\pi nt}{30,5} \right) + b_n \sin \left( \frac{2\pi nt}{30,5} \right) \right) \\
 & + \sum_{n=1}^3 \left( a_n \cos \left( \frac{2\pi nt}{7} \right) + b_n \sin \left( \frac{2\pi nt}{7} \right) \right) + \beta_1 * Tmin_t + \beta_2 * Tmax_t + \beta_3 * Precip_t
 \end{aligned} \tag{3.10}$$

- Modelo 7: Prophet con inclusión de estacionalidad mensual, fechas especiales y factores climáticos.

$$\begin{aligned}
\hat{D}_{ijt} &= (k_{ijt} + \mathbf{a}_{ij}(t)^T \boldsymbol{\delta}_{ij})t + (m_{ij} + \mathbf{a}_{ij}(t)^T \boldsymbol{\gamma}_{ij}) \\
&+ \sum_{n=1}^{10} \left( a_n \cos \left( \frac{2\pi nt}{365,25} \right) + b_n \sin \left( \frac{2\pi nt}{365,25} \right) \right) + \sum_{n=1}^5 \left( a_n \cos \left( \frac{2\pi nt}{30,5} \right) + b_n \sin \left( \frac{2\pi nt}{30,5} \right) \right) \\
&+ \sum_{n=1}^3 \left( a_n \cos \left( \frac{2\pi nt}{7} \right) + b_n \sin \left( \frac{2\pi nt}{7} \right) \right) + Z(t) \boldsymbol{\kappa}_{ij} + \beta_1 * T \min_t \\
&+ \beta_2 * T \max_t + \beta_3 * Precip_t
\end{aligned} \tag{3.11}$$

El rolling forecast inicia tomando la data comprendida entre el 1 de enero de 2017 y el 30 de junio de 2019 y pronostica un periodo de 14 días. Una vez realizado esto se modifica el dataset de entrenamiento, desfasándolo en 14 días y pronosticando los siguientes 14 días. Esto se realiza hasta completar un horizonte de pronósticos comprendido entre el 1 de julio de 2019 y el 6 de octubre de 2019.

En las tablas 3.8 y 3.9 se pueden observar errores porcentuales absolutos fuera de muestra (MAPE) de los modelos 6 y 7 propuestos anteriormente.

	Modelo 6, rolling forecast		
	Culinarios	Galletas	Refrigerados
Local 1	22.05 %	18.82 %	24.12 %
Local 2	23.65 %	21.84 %	23.54 %
Local 3	25.98 %	28.52 %	28.48 %
Local 4	19.31 %	18.34 %	21.16 %
Local 5	28.00 %	37.26 %	16.71 %
Local 6	25.12 %	25.67 %	24.39 %

Tabla 3.8: MAPE fuera de muestra rolling forecast modelo Prophet con inclusión de estacionalidad mensual y factores climáticos.

	Modelo 7, rolling forecast		
	Culinarios	Galletas	Refrigerados
Local 1	22.16 %	19.07 %	24.80 %
Local 2	24.81 %	21.44 %	22.91 %
Local 3	25.34 %	29.62 %	28.95 %
Local 4	18.85 %	18.08 %	20.81 %
Local 5	24.72 %	36.67 %	16.52 %
Local 6	26.18 %	25.21 %	23.83 %

Tabla 3.9: MAPE fuera de muestra rolling forecast modelo Prophet con inclusión de estacionalidad mensual, fechas especiales y factores climáticos.

Se observa que al realizar el rolling forecast, los resultados no difieren mucho de los pronósticos estacionarios. Esto sugiere que el modelo es consistente en el tiempo y no presentaría problemas para pronosticar otros periodos. Además de esto, y al igual que en las comparaciones anteriores, se puede ver que al incluir el efecto de las fechas especiales no hay una mejora

generalizada en los resultados al contrastar el modelo sin fechas especiales con el modelo que si las incluye. Es más, para el local 1 el modelo 6 (estacionalidad mensual y factores climáticos) presenta mejores resultados que el modelo 7 (estacionalidad mensual, fechas especiales y factores climáticos) en todas las categorías, mientras que para los locales 3 y 4, el modelo 7 presenta mejores resultados.

# Capítulo 4

## Estimación de tiempos de reposición

Una vez obtenidas las estimaciones de demanda, se procede a estimar los tiempos de reposición total diarios por local. Dicho tiempo estimado será el input del modelo de asignación eficiente de reponedores que se desarrollará a futuro.

### 4.1. Tiempos de reposición

Como se mencionó anteriormente, se realizaron mediciones de tiempos de reposición a diferentes locales de la Región Metropolitana. En este proceso, se midieron diferentes procesos de las labores que realizan los reponedores, las cuales se pueden clasificar en dos grupos: actividad de reposición, (dependiente de la demanda) y aquellas actividades independientes de la demanda (por ejemplo: limpieza de góndolas, tiempos de traslado y reuniones con personal del local, entre otras actividades). En adelante, se hará referencia a estos tiempos como tiempos variables y tiempos fijos, respectivamente.

Estas mediciones, se realizan en una submuestra de 17 locales de RM y se cuenta con entre 2 y 6 observaciones para cada uno de ellos. En cada observación, se monitorea una jornada completa de reposición, en la que se registran tanto los tiempos de las actividades de tiempo fijo como las de tiempo variable. Es importante mencionar que en el registro de tiempos variables, se cuenta con el detalle de los SKU que se repusieron, la cantidad que se repuso y su respectivo tiempo de reposición. A partir de esto, se generan dos datasets: uno que agrupa los tiempos fijos de cada local, que se presume pueden ser diferentes según la clasificación del local; y uno que agrupa los tiempos variables independiente del local, ya que, se estima que para un mismo SKU no debiesen existir diferencias significativas en los tiempos de reposición entre un local y otro.

### 4.2. Formulación de modelos de estimación de tiempos de reposición

Usando la data recopilada, se procede a realizar modelos que permitan estimar el tiempo diario de labores de reposición para el local  $j$  en el periodo  $t$  (en adelante,  $T_{jt}$ ). Así, se define



la variable  $D_{ijt}$  como la cantidad de productos de la categoría  $i$  a reponer en el local  $j$  en el periodo  $t$ . En la figura 3.1 se observa una representación gráfica del sistema de reposición que se utiliza en los locales. Dado un espacio en góndola  $Q$  destinado a la categoría  $i$  en un local cualquiera, cada periodo se repone la cantidad demandada en el periodo inmediatamente anterior.




Figura 4.1: Representación gráfica del sistema de reposición para un local.

Con esto, para cada local se propone calibrar una función lineal con componentes de tiempo fijo y variable. Así, la función propuesta sigue la siguiente forma:

$$\begin{aligned}
 T_{jt} &= f(D_{ij(t-1)}) \\
 f(D_{ij(t-1)}) &= TF_{jt} + TV_{jt} \\
 T_{jt} &= \alpha_j + \beta \cdot D_{ij(t-1)}
 \end{aligned} \tag{4.1}$$

donde la componente  $TF_{jt}$  corresponde al tiempo fijo inherente al local  $j$  en el día  $t$  y la componente  $TV_{jt}$  corresponde al tiempo variable asociado a la reposición de productos.

#### 4.2.1. Calibración de la función

Conociendo la forma general de la función, se procede a calibrar la misma. Para estimar la parte fija del tiempo de reposición, se decide que la variable  $\alpha_j$  responda a los distintos clusters en los que se segmentaron los locales. De esta forma, se estiman seis valores para  $\alpha$ , ajustando el tiempo fijo medio de reposición correspondiente a las observaciones de los locales cada cluster. Con esto, se obtienen los siguientes valores para  $\alpha$ :

Cluster	Variable	Valor Estimado
1	$\alpha_1$	6:02:07
2	$\alpha_2$	6:14:40
3	$\alpha_3$	4:39:09
4	$\alpha_4$	3:38:33
5	$\alpha_5$	5:04:54
6	$\alpha_6$	2:58:24

Tabla 4.1: Valores estimados para componente fija de tiempos de reposición, según segmento de local.

Con respecto a la parte variable, se formulan los siguientes 5 modelos:

- Modelo 1: Modelo lineal de tiempo de reposición en función de unidades repuestas por categoría.

$$TV_{jt} = \beta_0 + \sum_{i \in \text{Categorías}} \beta_i * D_{ij(t-1)} \quad (4.2)$$

- Modelo 2: Modelo lineal de tiempo de reposición en función de unidades repuestas por grupo de categorías.

$$TV_{jt} = \beta_0 + \sum_{i \in \text{Grupos}} \beta_i * D_{ij(t-1)} \quad (4.3)$$

- Modelo 3: Modelo lineal de tiempo de reposición en función de unidades repuestas por categoría, sin intercepto.

$$TV_{jt} = \sum_{i \in \text{Categorías}} \beta_i * D_{ij(t-1)} \quad (4.4)$$

- Modelo 4: Modelo lineal de tiempo de reposición en función de unidades repuestas por grupo de categorías, sin intercepto.

$$TV_{jt} = \sum_{i \in \text{Grupos}} \beta_i * D_{ij(t-1)} \quad (4.5)$$

- Modelo 5: Modelo de promedios ponderados para tiempos de reposición en función de unidades repuestas por grupo.

$$TV_{jt} = \sum_{i \in \text{Grupos}} \beta_i * D_{ij(t-1)} \quad (4.6)$$

$$\beta_i = \frac{\sum_t Rep_{it}}{\sum_t D_{it}}$$

donde  $Rep_{it}$  corresponde al tiempo de reposición medido para productos del grupo  $i$  en el día  $t$ .

Para los modelos que presentan agrupación de categorías, se definen los siguientes cinco grupos, asociados según similitud de productos:

- Grupo 1: Helados y Refrigerados.
- Grupo 2: Leches Líquidas, Oppb Tradicional, Oppb Refrigerado, Lácteos Culinarios.
- Grupo 3: Café, Coffee Mate, M&D, Pods.
- Grupo 4: Cereales, CI, Gums, Fórmulas, Leche en Polvo.
- Grupo 5: Chocolates, Galletas, Culinarios.

La estimación de los modelos 1, 2, 3 y 4 se realiza usando regresiones lineales mediante el método de Mínimos Cuadrados Ordinarios, mientras que el modelo 5 se calcula usando directamente las mediciones de las bases de datos. En las tablas 4.2 a 4.6 se pueden observar los resultados de la estimación de estos modelos, su significancia estadística, su desviación estándar y sus valores de  $R^2$  y  $R^2$  ajustado.

Con respecto a los estimadores, estos deben interpretarse como el tiempo en segundos que supone reponer una unidad de la respectiva categoría o grupo. Se observa que para los modelos sin agrupación de categorías estos estimadores varían entre 0 y 10 segundos por unidad repuesta, dependiendo de la categoría; mientras que en los modelos que tienen agrupación de categorías, los estimadores se mueven entre 1 y 6 segundos, según el grupo. Con respecto a la desviación estándar y significancia estadística, para los modelos que incluyen todas las categorías como regresores se observa que existen categorías que presentan un p-valor mayor a 0.1, por lo que resultan estadísticamente no significativos, mientras que para aquellos modelos que agrupan categorías, la significancia estadística existe para todos los regresores, mostrando p-valores menores a 0.01. De la mano de esto, podemos observar que las variables con menor nivel de confianza estadística, también presentan los mayores valores en su desviación estándar. Se presume que la baja confianza estadística y los altos valores de desviación estándar responden a un bajo número de observaciones alusivas a dicha categoría. Finalmente, y con respecto a los valores de  $R^2$  y  $R^2$  ajustado, se puede observar que los modelos que incluyen las categorías individualmente, tienen mejores valores para que los modelos que agrupan categorías.

Variable	Estimador	Desviación Estándar
Intercepto	72.910 .	42.885
Unit*Cat_Helados	4.151 ***	0.517
Unit*Cat_LechesLíquidas	1.074	16.692
Unit*Cat_Refrigerados	1.460 ***	0.144
Unit*OppbRefrigerados	1.440 *	0.661
Unit*Cat_Café	6.374 ***	1.009
Unit*Cat_Cereales	4.294 ***	0.795
Unit*Cat_Chocolates	1.798 ***	0.221
Unit*Cat_CI	4.624 **	1.713
Unit*Cat_CoffeeMate	6.216	6.349
Unit*Cat_Culinarios	0.440 ***	0.087
Unit*Cat_Fórmulas	8.722 .	4.468
Unit*Cat_Galletas	5.092 ***	0.155
Unit*Cat_Gums	3.813	10.673
Unit*Cat_LácteosCulinarios	3.657 ***	0.305
Unit*Cat_LecheEnPolvo	6.639 ***	1.51
Unit*Cat_M&D	3.827 ***	1.08
Unit*Cat_OppbTradicional	5.472 *	2.454
Unit*CatPods	6.533	5.265
Signif. codes: 0.001 "***"; 0.01 "**"; 0.05 "*"; 0.1 "."		
Multiple R-squared: 0.852		Adjusted R-squared: 0.841

Tabla 4.2: Resultados estimación modelo 1.

Variable	Estimador	Desviación Estándar
Intercepto	230.461 **	78.382
Unit*Grupo1	1.516 ***	0.277
Unit*Grupo2	3.038 ***	0.551
Unit*Grupo3	4.320 **	1.472
Unit*Grupo4	3.945 **	1.309
Unit*Grupo5	1.522 ***	0.145
Signif. codes: 0.001 "***"; 0.01 "**"; 0.05 "*"; 0.1 "."		
Multiple R-squared: 0.389		Adjusted R-squared: 0.377

Tabla 4.3: Resultados estimación modelo 2.

Variable	Estimador	Desviación Estándar
Unit*Cat_Helados	4.345 ***	0.506
Unit*Cat_LechesLíquidas	3.990	16.669
Unit*Cat_Refrigerados	1.513 ***	0.141
Unit*OppbRefrigerados	1.583 *	0.658
Unit*Cat_Café	6.875 ***	0.968
Unit*Cat_Cereales	4.687 ***	0.763
Unit*Cat_Chocolates	1.893 ***	0.214
Unit*Cat_CI	4.952 **	1.709
Unit*Cat_CoffeeMate	7.385	6.336
Unit*Cat_Culinarios	0.459 ***	0.086
Unit*Cat_Fórmulas	9.773 *	4.442
Unit*Cat_Galletas	5.145 ***	0.152
Unit*Cat_Gums	6.830	10.566
Unit*Cat_LácteosCulinarios	3.763 ***	0.299
Unit*Cat_LecheEnPolvo	7.054 ***	1.495
Unit*Cat_M&D	4.116 ***	1.071
Unit*Cat_OppbTradicional	6.360 **	2.407
Unit*CatPods	8.123	5.202
Signif. codes: 0.001 "***"; 0.01 "**"; 0.05 "*"; 0.1 "."		
Multiple R-squared: 0.881		Adjusted R-squared: 0.872

Tabla 4.4: Resultados estimación modelo 3.

Variable	Estimador	Desviación Estándar
Unit*Grupo1	1.718 ***	0.272
Unit*Grupo2	3.427 ***	0.543
Unit*Grupo3	5.702 ***	1.417
Unit*Grupo4	5.244 ***	1.251
Unit*Grupo5	1.634 ***	0.142
Signif. codes: 0.001 "***"; 0.01 "**"; 0.05 "*"; 0.1 "."		
Multiple R-squared: 0.496		Adjusted R-squared: 0.486

Tabla 4.5: Resultados estimación modelo 4.

Variable	Estimador
Grupo 1	2.21
Grupo 2	3.71
Grupo 3	5.93
Grupo 4	5.35
Grupo 5	2.79

Tabla 4.6: Resultados estimación modelo 5.

Como ya fue mencionado, los modelos que incluyen todas las categorías como regresores tienen un mejor  $R^2$  y  $R^2$  ajustado, por lo que se cree que estos modelos podrían explicar de

mejor forma el tiempo de reposición de los productos. A pesar de esto, y debido al hecho de que dichos modelos tengan estimadores con alto nivel de desviación, se cree que puede no ser del todo correcto usarlos ciegamente. Como el objetivo es obtener una buena estimación de los tiempos de reposición, se testeará con los resultados de los cuatro modelos ajustados. Para esto, se aplicará la función de estimación de tiempo para la parte variable (ecuación 4.1) tanto a los valores de demanda real como a las estimaciones de demanda, para luego calcular el MAPE que presenta cada una de las predicciones. Al igual que en la sección de estimación de demanda, los testeos comprenden el mes de septiembre de 2019 y se prueban en un local para cada cluster. Además, debido a requerimientos del proveedor, las estimaciones de tiempo deben ser diferenciadas para categorías refrigeradas y no refrigeradas, por lo que los MAPE se presentan de forma separada.

Local	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5
Local 1	13.44 %	10.59 %	14.22 %	14.19 %	13.76 %
Local 2	14.12 %	11.23 %	15.47 %	15.03 %	15.67 %
Local 3	20.50 %	9.66 %	24.18 %	20.60 %	20.64 %
Local 4	10.87 %	6.19 %	12.85 %	12.77 %	12.76 %
Local 5	14.43 %	4.65 %	19.69 %	14.76 %	16.99 %
Local 6	10.19 %	8.14 %	12.65 %	11.44 %	12.42 %

Tabla 4.7: MAPE tiempo variable de reposición, categorías no refrigeradas.

Local	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5
Local 1	16.36 %	11.99 %	18.47 %	17.78 %	17.32 %
Local 2	18.72 %	13.57 %	19.42 %	20.76 %	19.29 %
Local 3	16.40 %	14.24 %	18.89 %	21.85 %	21.83 %
Local 4	19.77 %	22.92 %	21.52 %	28.53 %	27.34 %
Local 5	13.65 %	7.24 %	21.81 %	22.48 %	21.82 %
Local 6	15.98 %	9.73 %	16.12 %	18.59 %	19.06 %

Tabla 4.8: MAPE tiempo variable de reposición, categorías refrigeradas.

En las tablas 4.7 y 4.8 se observan los MAPE de los cinco modelos en los seis locales testeados, tanto para las categorías refrigeradas como las no refrigeradas. Se puede observar que la inclusión de un intercepto mejora los resultados de la estimación de tiempos, tanto para las categorías refrigeradas como las no refrigeradas, pero se cree que dicho intercepto fija gran parte del tiempo que se busca sea variable, por lo que se estipula que puede no ser correcto incluir un intercepto. Con respecto a la agrupación de categorías, se puede observar que el modelo que agrupa categorías tiene menor error en la estimación que el modelo que las incluye individualmente, reportando mejores resultados al comparar tanto con como sin intercepto. Los modelos 4 y 5, son similares en construcción (ambos buscan encontrar parámetros para grupos de categoría, sin intercepto) pero se estiman de forma diferente; sin embargo, se observa que no presentan diferencias remarcables en sus resultados a nivel de error.

Al comparar las categorías no refrigeradas y refrigeradas, se puede observar que las primeras tienen un menor nivel de error que las segundas. Esto se puede explicar principalmente por que

existen únicamente 3 categorías refrigeradas versus 20 categorías no refrigeradas. Al estimar tiempos de reposición, hay categorías que sobre estiman el tiempo y otras que subestiman, por lo que al agregar, existe un efecto de neutralización en dichos tiempos. En consecuencia, a este nivel de agregación el efecto de neutralización en las categorías refrigeradas es menor al de las categorías no refrigeradas, provocando estas diferencias en el error.

Dicho lo anterior, se decide utilizar el modelo 4 para estimar los tiempos de reposición por local. Utilizando los estimadores de dicho modelo en la función presentada en la ecuación 4.1, se obtienen los siguientes resultados para las horas hombre necesarias para reposición por local:

Local	Tiempo fijo promedio (hh:mm:ss)	Tiempo variable promedio (hh:mm:ss)	Tiempo total promedio (hh:mm:ss)
Local 1	06:02:07	04:07:55	10:10:02
Local 2	06:14:40	03:35:12	09:49:52
Local 3	04:39:09	02:10:20	06:49:29
Local 4	03:38:33	02:53:55	06:32:28
Local 5	05:04:54	01:33:21	06:38:15
Local 6	02:58:24	01:13:33	04:11:57

Tabla 4.9: Tiempos de reposición estimados por local.

### 4.3. Balance de tiempo fijo y tiempo variable

Como se puede observar en la tabla 4.9, existe un desbalance entre la cantidad de hora hombre demandadas para tiempo fijo y tiempo variable. Esta diferencia discrepa con la realidad, pues se cree que el tiempo variable debiese ser más cercano en cantidad o incluso mayor al tiempo fijo. Para compensar estas diferencias, se propone realizar una modificación en la función de calibración de tiempos de reposición. Para esto, se identifican procesos que anteriormente se consideraban dentro del tiempo fijo, pero que podrían depender de las unidades a reponer. Así, se define la nueva función de tiempos de reposición presentada en la ecuación 4.7.

$$\begin{aligned}
 T_{jt} &= f(D_{ij(t-1)}) \\
 f(D_{ij(t-1)}) &= TF_{jt} + TV1_{jt} + TV2_{jt}
 \end{aligned}
 \tag{4.7}$$

donde  $TF_{jt}$  corresponde a la nueva componente de tiempo fijo para el local  $j$  en el día  $t$ , que como se mencionó, incluye menos procesos que en la sección anterior;  $TV1_{jt}$  corresponde al tiempo variable asociado únicamente a la reposición de productos; y  $TV2_{jt}$  corresponde al tiempo variable asociado a los nuevos procesos dependientes de la demanda identificados. Los procesos identificados son: tiempo de traslado a bodega, sala y depósito; buscar productos en bodega; cargar carro en bodega; ordenar productos en góndola; y apantallar. Con esto, el modelo que se propone es el presentado en la ecuación 4.8.

$$T_{jt} = \alpha_j + \beta \cdot D_{ij(t-1)} + \gamma_j D_{ij(t-1)} \quad (4.8)$$

Para esta metodología, los estimadores de la componente fija  $TF_{jt}$  ( $\alpha_j$ ) se estiman de igual forma que en la sección anterior, es decir, como un promedio simple por cluster de aquellas actividades consideradas como fijas. Los estimadores variables para la componente  $TV1_{jt}$  ( $\beta$ ) se estiman mediante la metodología aplicada en el modelo 5 de la sección anterior, es decir, como un promedio simple por grupo de categorías que entregará el tiempo estimado de reponer una unidad perteneciente a cada grupo de categorías. Finalmente, los estimadores para la componente variable  $TV2_{jt}$  ( $\gamma_j$ ) se estiman mediante un promedio simple por cluster del tiempo de los nuevos procesos asociados a la demanda. En las tablas 4.10, 4.11 y 4.12 se observan los resultados de estas estimaciones.

Cluster	Variable	Valor Estimado (hh:mm:ss)
1	$\alpha_1$	03:54:29
2	$\alpha_2$	04:15:17
3	$\alpha_3$	02:16:34
4	$\alpha_4$	02:32:31
5	$\alpha_5$	03:00:47
6	$\alpha_6$	01:38:57

Tabla 4.10: Valores estimados por cluster para tiempo fijo.

Grupo	Valor Estimado (segundos por unidad)
1	2.21
2	3.71
3	5.93
4	5.35
5	2.79

Tabla 4.11: Valores estimados por grupo de categoría para tiempo variable asociado a proceso de reposición.

Grupo	Variable	Valor Estimado (segundos por unidad)
1	$\gamma_1$	1.39
2	$\gamma_2$	1.97
3	$\gamma_3$	2.84
4	$\gamma_4$	4.94
5	$\gamma_5$	3.81
6	$\gamma_6$	2.57

Tabla 4.12: Valores estimados por cluster para tiempo variable asociado a nuevos procesos relacionados con la demanda.



A partir de estos estimadores, y de la misma forma que como se realizó para la metodología anterior, se estima el tiempo por jornada de reposición para los seis locales en estudio, pronosticando dicho tiempo para cada día del mes de septiembre de 2019. Finalmente, se calcula el indicador MAPE para la componente variable del tiempo de reposición aplicando la función presentada en la ecuación 4.7 a la demanda real y a la demanda pronosticada.

Cluster	Local	MAPE categorías no refrigeradas	MAPE categorías refrigeradas
1	Local 1	13.68 %	17.05 %
2	Local 2	16.43 %	19.88 %
3	Local 3	21.44 %	21.81 %
4	Local 4	13.62 %	24.43 %
5	Local 5	19.68 %	20.70 %
6	Local 6	14.22 %	20.18 %

Tabla 4.13: MAPE tiempo variable de reposición para nueva metodología, para categorías no refrigeradas y refrigeradas.

Al comparar los valores MAPE de esta metodología con los vistos en la sección anterior, es posible observar que con el único modelo que presenta diferencias significativas es con el modelo 2, que presenta valores menores que los observados con la nueva metodología. Para el resto de los modelos, el valor del MAPE permanece relativamente igual (tanto para categorías refrigeradas como no refrigeradas). Esto da indicios de que la nueva metodología no supone complicaciones en lo que respecta a error en la estimación.

Finalmente, se muestran los resultados desglosados en tiempo fijo y tiempo variable, junto con las horas hombre promedio totales necesarias para una jornada de reposición por local.

Local	Tiempo fijo promedio (hh:mm:ss)	Tiempo variable promedio (hh:mm:ss)	Tiempo total promedio (hh:mm:ss)
Local 1	03:54:29	06:16:31	10:11:00
Local 2	04:15:17	05:02:46	09:18:03
Local 3	02:16:34	03:06:58	05:23:32
Local 4	02:32:31	06:42:24	09:14:55
Local 5	03:00:47	01:13:36	04:13:23
Local 6	01:38:57	02:10:17	03:49:14

Tabla 4.14: Tiempos de reposición estimados por local bajo nueva metodología.

Al comparar el tiempo total de reposición por local con el tiempo estimado en la sección anterior, se pueden observar diferencias importantes en los locales 3, 4, 5 y 6. Esto se puede explicar por los valores  $\gamma$  obtenidos para dichos locales, que aumentan el tiempo proporcionalmente a la demanda observada en dichos locales, por lo que la componente variable asociada a dicho factor, podría estar entregando un valor mayor al sustraído desde la componente fija. Si se compara la componente fija, es posible observar que todos los valores estimados para esta metodología son menores a los estimados en la sección anterior. Esto es evidente

al considerar la construcción de esta nueva metodología, pues es desde esta componente que se extrajeron los procesos considerados para la nueva componente variable. Aún así, es importante destacar que con esta metodología, el tiempo fijo de reposición se redujo entre un 26 % y un 52 %. Con respecto a la componente variable, y como es de esperar, se observa un aumento en el tiempo observado en todos los locales con respecto a la metodología de la sección anterior, mostrando cambios que van desde un 36 % para el local 2 a un 172 % para el local 4.

Esta metodología permite tener un desglose de la estimación de tiempos fijos y tiempos variables más consistente y cercana a la realidad que la observada en la sección anterior, pero es importante mencionar que la componente variable es muy sensible a la demanda pronosticada, lo que podría provocar que ante un aumento de la demanda, los tiempos de reposición se vean sobreestimados, provocando futuros problemas en modelos de dotación óptima.

# Capítulo 5

## Detección de quiebres de stock

A continuación, y como última línea de investigación de este trabajo, se desarrollan modelos de predicción de quiebres de stock, que permitirán detectar cuando un producto se encuentra potencialmente sin unidades disponibles para venta, información que podría ser de utilidad para priorizar las actividades de reposición en la jornada de los trabajadores. Estos modelos se desarrollarán usando dos métodos de clasificación distintos: árbol de regresión y random forest, para luego comparar el rendimiento de ambos y definir cuál tiene mejores resultados.

### 5.1. Formulación de modelos de quiebres de stock

Los dos métodos de estimación que se utilizarán se enmarcan en el *Classification and regression tree (CART) analysis*. Estos métodos se desarrollan para resolver problemas de clasificación y de toma de decisiones, basándose en árboles de decisión. Como su nombre lo indica, en este método se consideran dos tipos de árboles de decisión: árboles clasificadores y árboles de regresión.

Un árbol de clasificación es un algoritmo que ayuda a predecir variables categóricas o variables fijas. Así, este algoritmo se usa para identificar en qué “clase” es más probable se encuentre la variable dependiente dada una colección de variables independientes. Por otra parte, un árbol de regresión es un modelo de predicción similar a un árbol de clasificación, con la diferencia de que este permite que los valores de la predicción deseada puedan ser continuos y no únicamente categóricos como lo son en el de clasificación.

Un Random Forest es un modelo de clasificación basado en una colección de árboles clasificadores que dependen de un vector de aleatorio de variables independientes e idénticamente distribuidos para cada árbol. Este modelo simula un gran número de árboles de decisión independientes, que toman dicho vector aleatorio y clasifican un resultado basado en los valores del vector. Luego de esto, ponderan la clasificación de cada árbol generando una predicción. Brieman en [3] muestra que el error generalizado del Random Forest presenta convergencia casi segura a un límite a medida que se aumenta el número de árboles simulados. En [5], los autores señalan que este algoritmo de clasificación es atractivo tanto estadística como computacionalmente. Desde el punto de vista estadístico el modelo es interesante ya que

proporciona detección de *outliers*, aprendizaje sin supervisión, imputación de *missing values*, ponderación diferenciada de clases, entre otras. Desde el punto de vista computacional puede manejar regresiones y clasificación multiclase, es relativamente rápido de entrenar y predecir, puede usarse directamente en problemas multidimensionales, entre otras características.

Considerando lo anterior, se desarrolla un modelo basado en un Árbol de regresión y otro modelo basado en un Random Forest.

### 5.1.1. Productos de alta y media rotación

Para generar el vector aleatorio que alimentará los modelos de detección de quiebres de productos de alta y media rotación, se toman algunos indicadores de bases de datos existentes, como por ejemplo el indicador del SKU del producto y el identificador del local. Por otra parte, también se crean indicadores de rendimiento que permitirán al modelo estimar de mejor forma los resultados.

El primer indicador de rendimiento que se genera es el porcentaje de participación de la categoría  $i$  asociada al producto  $k$ , en el local  $j$  para el día  $t$ . Este indicador se calcula como se muestra en la ecuación 5.1 y tiene el objetivo de entregarle al modelo información acerca de posibles efectos generalizados de la categoría en días determinados; es decir, le brindará información para mitigar predicciones de quiebre debido a bajas ventas que tenga un producto de la categoría  $i$  que realmente corresponde a un día de ventas bajas en la categoría.

$$Partic_{ijt} = \frac{\sum_{k \in i} D_{kjt}}{\sum_k D_{kjt}} \quad (5.1)$$

El segundo indicador de rendimiento que se crea es un vector con la probabilidad de encontrar residuos menores a los residuos observados. Para esto, se procede de la siguiente forma: Para cada combinación SKU-Local se realiza una estimación de demanda mediante el modelo *Prophet*, incluyendo estacionalidad, tendencia y las covariables asociadas a clima (Temperaturas mínima, máxima y precipitaciones) y precio. Una vez realizada la estimación, se crea la variable residuos del producto  $k$ , en el local  $j$ , para el día  $t$ .

$$r_{kjt} = D_{kjt} - \hat{D}_{kjt} \quad (5.2)$$

Una vez calculados los residuos para cada combinación SKU-Local, se analiza que distribución siguen. Para esto, se realiza un gráfico de *Cullen and Frey* por cada combinación SKU-Local que permite dar una primera aproximación al tipo de distribución ajusta de mejor forma los residuos.




Figura 5.1: Gráfico Cullen and Frey de residuos para una combinación SKU-Local.

La figura 5.1 muestra el gráfico de Cullen and Frey para una combinación SKU-Local particular donde el punto azul representa la data y los puntos amarillos representan valores obtenidos mediante *bootstrap sampling* de la data original. Una vez realizado este análisis para todas las combinaciones, se observa que todas se comportan de la misma forma. Del gráfico es posible interpretar que la distribución que más se asemeja a los datos es la distribución Log-Normal, pero esta supone un problema cuando los residuos toman valores negativos, es decir, cuando la demanda estimada es mayor a la demanda observada. Para corregir esto, se decide modelar la demanda observada en función de la demanda estimada.

$$D_{kjt}^{\sim} = F(D_{kjt}^{\hat{}}) \quad (5.3)$$

Nuevamente, se grafica la demanda en un gráfico Cullen and Frey para cada combinación y se observa que para esta formulación, los datos podrían ser ajustados mediante una distribución Log-Normal o una distribución gamma.




Figura 5.2: Gráfico Cullen and Frey de demanda para una combinación SKU-Local.

Como se mencionó, la demanda modelada puede ajustarse mediante dos distribuciones, lo que lleva a que a partir de este indicador, se generen dos formas de calcularlo. Con esto, los dos indicadores de rendimiento asociados a la probabilidad de encontrar ventas menores a las observadas:

$$\begin{aligned} ProbNorm_{kjt} &= \mathbb{P}(\tilde{D}_{kjt} < D_{kjt}) \\ \tilde{D}_{kjt} &\sim \text{Log - Normal}(f(\hat{D}_{kjt}), \sigma^2) \end{aligned} \quad (5.4)$$

$$\begin{aligned} ProbGamma_{kjt} &= \mathbb{P}(\tilde{D}_{kjt} < D_{kjt}) \\ \tilde{D}_{kjt} &\sim \text{Gamma}(\alpha, \lambda) \end{aligned} \quad (5.5)$$

Finalmente, se formulan los modelos de predicción de quiebres usando las variables construidas. De esta forma los modelos postulados son:

- Modelo 1: Random Forest con vectores de alimentación IdLocal, Participación de categoría y Probabilidad Log-Normal.
- Modelo 2: Random Forest con vectores de alimentación IdLocal, Participación de categoría y Probabilidad Gamma.
- Modelo 3: Árbol de regresión con vectores de alimentación IdLocal, Participación de categoría y Probabilidad Log-Normal.
- Modelo 4: Árbol de regresión con vectores de alimentación IdLocal, Participación de categoría y Probabilidad Gamma.

### 5.1.2. Productos de baja rotación

Con respecto a los productos de baja rotación, para formular los modelos se procede de la misma forma a como se realizó con los de alta y media rotación: se toman los indicadores de SKU e identificador de local, se calcula el porcentaje de participación diaria de la categoría asociada al producto y se calcula la probabilidad de encontrar ventas menores a las observadas. Con respecto a esta última, se debe ajustar el método con el que se calcula esta probabilidad.

Debido a que los productos de baja rotación consistentemente presentan ventas observadas cercanas a 0 unidades diarias por local, la forma en que se modela la demanda debe ser diferente a como se hizo con los productos de alta y media rotación. Para esto, se modela nuevamente la demanda observada en función de la demanda estimada, pero esta vez siguiendo una distribución de Poisson.

$$\begin{aligned} ProbPoisson_{kjt} &= \mathbb{P}(\tilde{D}_{kjt} < D_{kjt}) \\ \tilde{D}_{kjt} &\sim \text{Poisson}(\lambda(\hat{D}_{kjt})) \end{aligned} \quad (5.6)$$

Así, se postulan los siguientes 2 modelos de predicción de quiebres para productos de baja rotación a partir de los indicadores construidos:

- Modelo 1: Random Forest con vectores de alimentación IdLocal, Participación de categoría y Probabilidad Poisson.
- Modelo 2: Árbol de regresión con vectores de alimentación IdLocal, Participación de categoría y Probabilidad Poisson.

## 5.2. Resultados

### 5.2.1. Productos de alta y media rotación

Los modelos son entrenados mediante un dataset que contiene los indicadores presentados en la sección anterior. Este dataset se cruza con datos que muestran si hubo quiebre de producto, desglosado por fechas y locales. La data resultante consta de 5640 observaciones, de las cuales se fracciona un 80 % para entrenamiento y un 20 % para testeo.

Los resultados se presentan mediante matrices de confusión que permitirá comparar el porcentaje de acierto de los modelos predictivos propuestos.

		Predicción	
		Quiebre	Disponible
Observación	Quiebre	112	470
	Disponible	86	460

Tabla 5.1: Matriz de confusión modelo 1 (Random Forest, Probabilidad Log-Normal).

		Predicción	
		Quiebre	Disponible
Observación	Quiebre	134	448
	Disponible	102	444

Tabla 5.2: Matriz de confusión modelo 2 (Random Forest, Probabilidad Gamma).

		Predicción	
		Quiebre	Disponible
Observación	Quiebre	214	368
	Disponible	170	376

Tabla 5.3: Matriz de confusión modelo 3 (Árbol de regresión, Probabilidad Log-Normal).

		Predicción	
		Quiebre	Disponible
Observación	Quiebre	228	354
	Disponible	163	383

Tabla 5.4: Matriz de confusión modelo 4 (Árbol de Regresión, Probabilidad Gamma).

Como primera impresión, al comparar el número de verdaderos positivos y verdaderos negativos, se puede observar que los modelos de Árbol de regresión tiene mejores resultados estimando quiebres y disponibles que los modelos de Random Forest. Por otra parte, también se puede observar que cuando se calcula el indicador de rendimiento asociado a la probabilidad de encontrar ventas menores a las observadas, el uso de una distribución Gamma tiene resultados levemente mejores que cuando se usa la distribución Log-Normal. Para hacer una comparación más profunda, se construye la tabla 5.5, que muestra diferentes métricas de evaluación para los cuatro modelos.

	Exactitud	Precisión	Sensibilidad	Especificidad
Modelo 1 (RF, Prob Log-Normal)	0.507	0.565	0.192	0.842
Modelo 2 (RF, Prob Gamma)	0.512	0.567	0.230	0.813
Modelo 3 (AdR, Prob Log-Normal)	0.523	0.557	0.367	0.688
Modelo 4 (AdR, Prob Gamma)	0.541	0.583	0.391	0.701

Tabla 5.5: Métricas de matrices de confusión para modelos de quiebre en productos de alta y media rotación.

La exactitud muestra la capacidad del modelo de acercarse a los valores reales, en otras palabras, es la proporción de predicciones que se realizaron correctamente. Se puede observar que el modelo 4 es el que tiene una mejor tasa de aciertos en la predicción. La precisión representa la proporción entre el número de quiebres correctamente identificados versus el total de quiebres detectados por el modelo. Nuevamente se observa que el modelo 4 es el mejor al momento de estimar, en este caso, los quiebres. Con respecto a la métrica sensibilidad, que mide la proporción de quiebres correctamente identificados entre el total de quiebres en las observaciones, se observa nuevamente que el modelo 4 presenta los mejores resultados. Finalmente, respecto a la especificidad, que mide la proporción de casos negativos que el modelo clasifica correctamente, se observa que el modelo 1 tiene el mejor resultado.

Es importante destacar, que los resultados obtenidos están distantes de ser los deseados, pues los modelos postulados tienen, exceptuando la de especificidad, métricas muy bajas. Se observa principalmente que existe una gran tasa de falsos negativos, que en términos prácticos se traduce en quiebres de stock no detectados. Una posible explicación para los resultados obtenidos, es que los modelos pueden no estar recibiendo suficiente información que permita una mejor clasificación. La inclusión de información sobre promociones, número de transacciones del local, stock disponible los días previos, entre otras variables con las que no se cuenta, podrían mejorar los resultados de las predicciones.

### 5.2.2. Productos de baja rotación

De la misma forma que con los productos de alta y media rotación, se genera un dataset, esta vez con 3840 observaciones, fraccionando un 80 % para entrenamiento y un 20 % para testeo.

Así, los resultados de los modelos se muestra en las siguientes matrices de confusión.



		Predicción	
		Quiebre	Disponible
Observación	Quiebre	64	225
	Disponible	108	371

Tabla 5.6: Matriz de confusión modelo 1 (Random Forest, Probabilidad Poisson).

		Predicción	
		Quiebre	Disponible
Observación	Quiebre	101	188
	Disponible	85	394

Tabla 5.7: Matriz de confusión modelo 2 (Árbol de Regresión, Probabilidad Poisson).

Nuevamente, al comparar el número de verdaderos positivos y verdaderos negativos, es posible observar que el modelo de Árbol de regresión obtiene mejores resultados. Para comparar más profundamente el rendimiento de los modelos, se vuelve a construir la tabla de métricas de desempeño de los modelos obtenidas a través de la matriz de transición.

	Exactitud	Precisión	Sensibilidad	Especificidad
Modelo 1 (RF, Prob Poisson)	0.566	0.372	0.221	0.774
Modelo 2 (AdR, Probabilidad Poisson)	0.644	0.543	0.348	0.822

Tabla 5.8: Métricas de matrices de confusión para modelos de quiebre en productos de baja rotación.

Es posible observar que en todas las métricas, el modelo de Árbol de Regresión es el mejor. Además, se repite el comportamiento observado con los productos de alta y media rotación, obteniendo resultados no satisfactorios. Se puede notar que las métricas obtenidas a este nivel de rotación son bastante similares a las obtenidas para rotación alta y media, esto conduce a pensar que existe una parte del efecto de predicción que está siendo capturada correctamente por la información que alimenta los modelos de clasificación, reafirmando la posibilidad de que el modelo tenga espacios de mejora al incluir mayor cantidad de información.

# Conclusión

En la investigación realizada se modelan herramientas de aprendizaje automático que, mediante el uso de datos transaccionales, mediciones de tiempo y quiebres observados, buscan describir y pronosticar el comportamiento de las ventas futuras y quiebres de stock de productos de un proveedor del retail supermercadista y los tiempos de trabajo de los mercaderistas de dicho proveedor, con la finalidad de generar un punto inicial para un modelo de dotación y asignación eficiente en la fuerza de reposición.

Para el pronóstico de ventas futuras, se plantearon 3 modelos de predicción de demanda: ARIMA, Exponential Smoothing y Prophet, utilizando principalmente modelamiento de series de tiempo. Dichos modelos se enfocan en pronosticar la venta diaria agregada por categoría de 6 locales representativos de la Región Metropolitana, para una submuestra de 3 categorías de media y alta rotación en un horizonte de 10 días. Se encontró que el modelo Exponential Smoothing es el modelo que presenta un mayor MAPE fuera de muestra, entregando errores que superan aproximadamente en 10 puntos porcentuales a los errores de los otros modelos. Además de esto, es el modelo que presenta mayor grado de dispersión en sus errores, mostrando errores de estimación que van desde 20 % a 75 %. Con respecto a los modelos ARIMA y Prophet, se observó que ambos modelos presentan errores de estimación más heterogéneos, mostrando errores que varían en los rangos 21 % a 57 % y 13 % a 37 %, respectivamente. Al comparar estos dos modelos, se observa que los errores del modelo Prophet están generalmente entre 2 y 5 puntos porcentuales por debajo de los errores del modelo ARIMA, lo que sugiere que al comparar los 3 modelos, el modelo Prophet es aquel que pronostica de mejor forma las demanda agregada por categoría.

Con esta información se refinó el modelo Prophet con el objetivo de reducir los errores en el pronóstico, incluyendo estacionalidad mensual e información sobre fechas especiales. Además, se incluyó una categoría de baja rotación, con la finalidad de observar como se comporta el modelo ante bajos niveles de venta. Finalmente, se decide evaluar el desempeño del modelo horizontes de 8 y 30 días, para observar si ampliar el horizonte de pronóstico impacta significativamente en la estimación. Lo primero que se observó fue que el modelo tiene un peor desempeño en la categoría de baja rotación, mostrando errores que varían entre un 21 % y un 59 %; aproximadamente 15 puntos porcentuales por sobre las categorías de media y alta rotación. Los altos errores observados en esta categoría se explican debido a que, al vender pocas unidades, pronosticar una unidad por sobre o debajo del valor real, genera un gran impacto en el error porcentual. El nivel de error en estas categorías podría sugerir un problema si se quisiera obtener únicamente una estimación de demanda de productos, pero dado que el objetivo de la investigación no es el pronóstico de demanda, si no el pronóstico

de tiempo, se presume que estas variaciones en las estimaciones no tendrán un impacto significativo en los tiempos de reposición estimados. Respecto a las categorías de media y alta rotación, la inclusión de estacionalidad mensual y fechas especiales empeora levemente (2 puntos porcentuales, en promedio) los resultados del modelo. Esto puede deberse a un sobreajuste del modelo, que puede ya estar capturando estos efectos en la estacionalidad anual. Respecto al horizonte de tiempo, se encontró que el pronóstico de 30 días tiene un nivel de error, en promedio, 5% mayor que el pronóstico de 8 días. Esto es esperable, ya que al ampliar el horizonte de pronóstico, las fechas más alejadas tienden a tener un mayor error de predicción.

Para concluir con los pronósticos de demanda, se realiza un Rolling Forecast del modelo Prophet con la finalidad de saber si el modelo es consistente al pronosticar otros periodos de tiempo (hasta este punto, siempre se había pronosticado un mes en particular). Así, se pronostican un periodo de tiempo comprendido entre julio y octubre del año 2019, usando un set de entrenamiento móvil. A través de eso, se observó que el error no difiere significativamente con respecto al pronóstico estacionario, puesto que los valores para el MAPE se mantuvieron en los rangos presentados anteriormente. Con esto se puede concluir que el modelo es consistente en el tiempo y no presentaría complicaciones al pronosticar cualquier periodo del año.

Una vez terminado el estudio de pronóstico de demanda, se procedió a estimar el tiempo de trabajo diario necesario en cada sala. Para esto, se calibró una función afín compuesta por una componente de tiempo fijo no dependiente de la demanda y una parte variable asociada a la demanda (cantidad de productos a reponer). Se diseñan diferentes modelos lineales que permiten calcular en tiempo estimado de reponer una unidad dependiendo de su categoría, encontrando tiempos que varían entre los 0.5 y los 10 segundos por unidad. Una vez calibradas las componentes de la función, se aplica tanto a la demanda real como a la demanda pronosticada y se procede a calcular el error entre ambos resultados. Se observó que el error en los tiempos de reposición disminuye considerablemente respecto a el error observado en los pronósticos de demanda, presentando un rango de error entre el 12% y 20%. Esta disminución se explica debido a un efecto de “neteo” entre aquellas categorías que tuvieron un pronóstico sobre-estimado con aquellas que tuvieron uno subestimado. De esta forma, se obtienen tiempos totales promedio por jornada que varían entre las 3.5 a las 10.5 horas diarias, dependiendo del volumen de ventas del local.

Al desglosar este tiempo total en sus componentes fijas y variables, se observa que los tiempos fijos están sobre-estimados (variando entre 3 y 6 horas según local) mientras que los tiempos variables están subestimados (1 a 4 horas según local). Para solucionar esto, se redistribuyen las actividades consideradas como actividades de tiempo fijo y se crea con ellas una nueva componente de tiempo variable que capture el tiempo de estas actividades según categoría. Con este ajuste, se logra invertir la proporción de tiempos destinada a actividades fijas y variables, llegando a rangos estimados de 1 a 4 horas y 1 a 6 horas según local, respectivamente y manteniendo los tiempos totales diarios.

Finalmente, y con respecto a la línea de investigación asociada a los modelos de predicción de quiebres de stock, se formulan modelos de clasificación tipo Random Forest y Árbol de Regresión. Como variables clasificadoras, se incluyeron la identificación del local, el porcentaje

de ventas de la categoría asociada al producto y la probabilidad de encontrar ventas menores a las observadas. Esta última variable se construyó diferenciando los productos de alta y media rotación de los productos de baja rotación. Para los productos de alta y media rotación, se modela la demanda a través de distribuciones Log-Normal y Gamma dependientes de la demanda pronosticada, previamente ajustada usando Prophet a nivel SKU, con inclusión de tendencia, estacionalidad y covariables de clima y precio. Para los productos de baja rotación, la demanda se modela mediante una distribución de Poisson dependiente de la demanda pronosticada. Una vez entrenados los modelos, se testean en una submuestra de los datos, obteniendo resultados no satisfactorios que oscilan cerca del 50 % de exactitud para los productos de alta y media rotación y cerca del 60 % para los de baja rotación. Se observa que el modelo falla en pronosticar una parte importante de los quiebres de stock, ya que observando las matrices de confusión se puede notar un alto número de falsos negativos. De aquí se concluye que el modelo tiene amplios espacios de mejora si se lograra recopilar mayor cantidad de información que permita clasificar de mejor forma los quiebres, como por ejemplo, contar con información que muestre existencia de promociones, contar con el número de transacciones del local o incluir la información de stock disponible los días previos.

El objetivo de esta investigación era obtener una buena estimación de tiempos de reposición por local, para a partir de ellas, poder generar un modelo de optimización que permita solucionar las actuales deficiencias en el sistema de dotación y asignación de trabajadores. Este objetivo se logra satisfactoriamente, generando modelos de estimación de tiempo con errores del orden de un 15 %. Como segundo objetivo, se planteaba obtener un modelo de predicción de quiebres de stock, que sirviera como alimentador de un modelo de optimización de las tareas diarias que el trabajador debe realizar en los locales, generando rutas de priorización en aquellos productos que sean más propensos a no tener disponibilidad en góndola. Este objetivo se logra parcialmente, ya que los modelos presentados logran predecir correctamente los quiebres en ordenes de entre un 50 % a un 60 %. Queda entonces como trabajo futuro, el mejorar la estimación de quiebres de stock a través de la inclusión de más información en las variables que alimentan al modelo.

# Bibliografía

- [1] Ratnadip Adhikari and R. Agrawal. *An Introductory Study on Time Series Modeling and Forecasting*. LAP Lambert Academic Publishing, 2013.
- [2] Ilan Alin, Min Qi, and Robert Sadowski. *Forecasting aggregate retail sales: a comparison of artificial neural networks and traditional methods*. Journal of Retailing and Consumer Services, 2000.
- [3] L. Breiman. *Random Forests, pages 5–32*. Kluwer Academic Publishers, Berkley, CA, 2001.
- [4] Ching-Wu Chu and Guoqiang Zhang. *A comparative study of linear and nonlinear models for aggregate retail sales forecasting*. International Journal of Production Economics, 2003.
- [5] Adele Cutler, D. Richard Cutler, and John R. Stevens. *Random Forests, pages 157–175*. Springer US, Boston, MA, 2012.
- [6] Rob Hyndman and George Athanasopoulos. *Forecasting: Principles and Practice*. OTexts, 2013.
- [7] Rob Hyndman and Yeasmin Khandakar. *Automatic time series forecasting: The forecast package for r*. Journal of Statistical Software, 27(3), 2008.
- [8] Pablo Jofré. *Asignación eficiente de la fuerza de venta en tiempo real: Aplicación en una tienda de retail*. Master’s thesis, Universidad de Chile, 2017.
- [9] Lucjan Kurzak. *Importance of forecasting in enterprise management*. Advanced Logistic Systems, 6(2), 2012.
- [10] Wei-Yin Loh. *Classification and regression trees*. WIREs Data Mining and Knowledge Discovery, 1(1):14–23, 2011.
- [11] Seguei Netessine, Marshall Fisher, and Jayanth Krishnan. *Labor planning, execution, and retail store performance: An exploratory investigation*. Labor Planning, Execution, and Retail Store Performance: An Exploratory Investigation, 2010.
- [12] atrícia Ramos, Nicolau Santos, and Rui Rebelo. *Performance of state space and arimamodels for consumer retail sales forecasting*. Robotics and Computer-integrated Manufacturing, 2015.

[13] SJ Taylor and B. Letham. *Forecasting at scale*. PeerJ Preprints 5:e3190v2, 2017.

[14] Thomas Zeller and Laurence Metzger. *Good bye traditional budgeting, hello rolling forecast: Has the time come?* American Journal of Business Education, 6(3), 2013.