

**Escuela de Negocios**  
**Tipo de documento:** Tesis de maestría



*Master in Management + Analytics*

# Modelo de pronóstico de Demanda y Redistribución óptima del Inventario

**Autoría:** Hasman, Alan Emanuel

**Año:** 2025

## ¿Cómo citar este trabajo?

Hasman, A. (2025) "Modelo de pronóstico de Demanda y Redistribución óptima del Inventario". [Tesis de maestría. Universidad Torcuato Di Tella]. Repositorio Digital Universidad Torcuato Di Tella  
<https://repositorio.utdt.edu/handle/20.500.13098/13736>

El presente documento se encuentra alojado en el **Repositorio Digital de la Universidad Torcuato Di Tella** bajo una licencia Creative Commons Atribución-No Comercial-Compartir Igual 4.0 Internacional  
**Dirección:** <https://repositorio.utdt.edu>



**UNIVERSIDAD  
TORCUATO DI TELLA**

MASTER IN MANAGEMENT + ANALYTICS

MODELO DE PRONÓSTICO DE DEMANDA Y  
REDISTRIBUCIÓN ÓPTIMA DEL INVENTARIO

**TESIS**

Alan Emanuel Hasman

Mayo 2025

Director : Juan José Miranda Bront

Co-Director: Nicolás García Aramouni

## **Resumen**

En este trabajo se desarrolla un modelo de pronóstico de demanda de corto plazo con el objetivo de lograr una redistribución óptima del inventario entre las tiendas de una empresa mexicana de venta de ropa deportiva, tratando de minimizar así los quiebres de stock. Para ello se utilizó el modelo de pronóstico Facebook Prophet y sus resultados sirvieron para alimentar a un modelo de redistribución de inventarios entre tiendas implementado mediante un modelo de programación lineal entera enfocado principalmente en maximizar los porcentajes de cobertura en las tiendas con faltantes para una categoría, subcategoría y género específicos. La performance de los modelos de pronóstico evaluada sobre los meses de febrero, marzo y abril de 2022 fue óptima; por lo que en conjunto con la empresa se decidió comenzar a utilizar los resultados de la redistribución de inventarios sugerida a partir de la segunda quincena del mes de mayo de 2022. Su efecto sobre los quiebres de stock fue evaluado a través de un backtesting sobre las quincenas comprendidas entre los meses de enero y abril, dejando evidencia de resultados satisfactorios.

## **Abstract**

*This project develops a short-term demand forecasting model pursuing an optimal stock redistribution across several stores from a Mexican sportswear sales company, to minimize stock breaks. For that purpose, Facebook Prophet forecasting model was implemented using its outputs to feed a stock redistribution model across stores, performed with an integer linear programming model focused on maximizing stores coverage for missing products under a specific category, subcategory, and gender. Forecasting models performance assessed during February, March and April 2022 has been optimal; thus, encouraging company members to start using the stock redistribution model results since second half of May 2022. The effect on stock breaks has been assessed over the fortnights among the period January-April using a backtesting technique which has shown successful results.*

## Índice

Índice de Tablas.....	3
Índice de Ilustraciones.....	6
1. Introducción.....	7
1.1. Contexto.....	9
1.2. Problema.....	11
1.3. Objetivo.....	12
2. Datos.....	13
3. Metodología .....	26
3.1. Modelo de <i>Forecasting</i> .....	26
3.2. Modelo de Redistribución .....	48
4. Resultados .....	54
5. Conclusiones.....	69
Referencias.....	71
Apéndice A. Resultados adicionales de la validación del Modelo de Pronóstico .....	72
Apéndice B. Herramienta de registro de quiebres de stock .....	83

## Índice de Tablas

Tabla 1: Desagregación de la categoría Calzado en subcategorías y géneros .....	14
Tabla 2: Distribución de las tiendas por zona y ubicación.....	14
Tabla 3: Comparativa de MAPE entre modelos a nivel categoría y a nivel categoría-tienda (marzo 2022) .....	37
Tabla 4: % de corrección de unidades en base a quiebres de stock.....	40
Tabla 5: MAPE en Calzado Casual para los distintos algoritmos testeados (en %).....	40
Tabla 6: MAPE en Calzado Skate para los distintos algoritmos testeados (en %) .....	41
Tabla 7: MAPE en Calzado Basketball para los distintos algoritmos testeados (en %).....	41
Tabla 8: MAPE en Calzado Running para los distintos algoritmos testeados (en %).....	41
Tabla 9: MAPE en Calzado Training para los distintos algoritmos testeados (en %) .....	41
Tabla 10: MAPE en Calzado Soccer para los distintos algoritmos testeados (en %) .....	41
Tabla 11: MAPE en Textil Casual para los distintos algoritmos testeados (en %).....	42
Tabla 12: MAPE en Textil Skate para los distintos algoritmos testeados (en %).....	42
Tabla 13: MAPE en Textil Basketball para los distintos algoritmos testeados (en %).....	42
Tabla 14: MAPE en Textil Running para los distintos algoritmos testeados (en %).....	42
Tabla 15: MAPE en Textil Soccer para los distintos algoritmos testeados (en %).....	43

Tabla 16: MAPE en Textil Training para los distintos algoritmos testeados (en %) .....	43
Tabla 17: MAPE en Accesorio Casual para los distintos algoritmos testeados (en %) .....	43
Tabla 18: MAPE en Accesorio Skate para los distintos algoritmos testeados (en %) .....	43
Tabla 19: MAPE en Accesorio Basketball para los distintos algoritmos testeados (en %).....	43
Tabla 20: MAPE en Accesorio Running para los distintos algoritmos testeados (en %).....	44
Tabla 21: MAPE en Accesorio Soccer para los distintos algoritmos testeados (en %) .....	44
Tabla 22: MAPE en Accesorio Training para los distintos algoritmos testeados (en %) .....	44
Tabla 23: MAPE del modelo Prophet para Tiendas 1 a 12 en la categoría Calzado para el mes de marzo 2022 (en %).....	46
Tabla 24: MAPE del modelo Prophet para Tiendas 13 a 23 en la categoría Calzado para el mes de marzo 2022 (en %).....	46
Tabla 25: MAPE del modelo Prophet para Tiendas 1 a 12 en la categoría Textil para el mes de marzo 2022 (en %).....	47
Tabla 26: MAPE del modelo Prophet para Tiendas 13 a 23 en la categoría Textil para el mes de marzo 2022 (en %).....	47
Tabla 27: MAPE del modelo Prophet para Tiendas 1 a 12 en la categoría Accesorio para el mes de marzo 2022 (en %).....	47
Tabla 28: MAPE del modelo Prophet para Tiendas 13 a 23 en la categoría Accesorio para el mes de marzo 2022 (en %).....	48
Tabla 29: Costos de quiebre por tienda (expresados en \$ por unidad).....	56
Tabla 30: Muestra de la redistribución para la segunda quincena de mayo del 2022 .....	57
Tabla 31: Quiebres de Stock registrados en las tiendas .....	60
Tabla 32: Redistribución sugerida por el modelo .....	60
Tabla 33: Ventas reales de las tiendas de origen.....	61
Tabla 34: Descripción de los tres escenarios posibles para medir efectos en quiebres de stock	61
Tabla 35: Quiebres de stock totales aislados por escenario (enero 2022–abril 2022).....	62
Tabla 36: Propuesta de mantenimiento del sistema ante lanzamiento de nuevos productos ...	70
Tabla 37: MAPE del modelo Prophet para Tiendas 1 a 12 en la categoría Calzado para el mes de febrero 2022 (en %).....	72
Tabla 38: MAPE del modelo Prophet para Tiendas 13 a 23 en la categoría Calzado para el mes de febrero 2022 (en %).....	72
Tabla 39: MAPE del modelo Prophet para Tiendas 1 a 12 en la categoría Textil para el mes de febrero 2022 (en %).....	73
Tabla 40: MAPE del modelo Prophet para Tiendas 13 a 23 en la categoría Textil para el mes de febrero 2022 (en %).....	73
Tabla 41: MAPE del modelo Prophet para Tiendas 1 a 12 en la categoría Accesorio para el mes de febrero 2022 (en %).....	73
Tabla 42: MAPE del modelo Prophet para Tiendas 13 a 23 en la categoría Accesorio para el mes de febrero 2022 (en %).....	74

Tabla 43: MAPE del modelo Prophet para Tiendas 1 a 12 en la categoría Calzado para el mes de abril 2022 (en %) .....	74
Tabla 44: MAPE del modelo Prophet para Tiendas 13 a 23 en la categoría Calzado para el mes de abril 2022 (en %) .....	74
Tabla 45: MAPE del modelo Prophet para Tiendas 1 a 12 en la categoría Textil para el mes de abril 2022 (en %).....	75
Tabla 46: MAPE del modelo Prophet para Tiendas 13 a 23 en la categoría Textil para el mes de abril 2022 (en %) .....	75
Tabla 47: MAPE del modelo Prophet para Tiendas 1 a 12 en la categoría Accesorio para el mes de abril 2022 (en %) .....	75
Tabla 48: MAPE del modelo Prophet para Tiendas 13 a 23 en la categoría Accesorio para el mes de abril 2022 (en %) .....	76
Tabla 49: MAPE por Tienda (1 a 12) y Género MEN para el mes de febrero 2022 usando Prophet (en %) .....	76
Tabla 50: MAPE por Tienda (13 a 23) y Género MEN para el mes de febrero 2022 usando Prophet (en %) .....	76
Tabla 51: MAPE por Tienda (1 a 12) y Género WOMEN para el mes de febrero 2022 usando Prophet (en %).....	77
Tabla 52: MAPE por Tienda (13 a 23) y Género WOMEN para el mes de febrero 2022 usando Prophet (en %).....	77
Tabla 53: MAPE por Tienda (1 a 12) y Género CHILDREN para el mes de febrero 2022 usando Prophet (en %).....	77
Tabla 54: MAPE por Tienda (13 a 23) y Género CHILDREN para el mes de febrero 2022 usando Prophet (en %).....	78
Tabla 55: MAPE por Tienda (1 a 12) y Género MEN para el mes de marzo 2022 usando Prophet (en %) .....	78
Tabla 56: MAPE por Tienda (13 a 23) y Género MEN para el mes de marzo 2022 usando Prophet (en %) .....	78
Tabla 57: MAPE por Tienda (1 a 12) y Género WOMEN para el mes de marzo 2022 usando Prophet (en %) .....	79
Tabla 58: MAPE por Tienda (13 a 23) y Género WOMEN para el mes de marzo 2022 usando Prophet (en %).....	79
Tabla 59: MAPE por Tienda (1 a 12) y Género CHILDREN para el mes de marzo 2022 usando Prophet (en %).....	79
Tabla 60: MAPE por Tienda (13 a 23) y Género CHILDREN para el mes de marzo 2022 usando Prophet (en %).....	80
Tabla 61: MAPE por Tienda (1 a 12) y Género MEN para el mes de abril 2022 usando Prophet (en %).....	80
Tabla 62: MAPE por Tienda (13 a 23) y Género MEN para el mes de abril 2022 usando Prophet (en %) .....	80

Tabla 63: MAPE por Tienda (1 a 12) y Género WOMEN para el mes de abril 2022 usando Prophet (en %) .....	81
Tabla 64: MAPE por Tienda (13 a 23) y Género WOMEN para el mes de abril 2022 usando Prophet (en %) .....	81
Tabla 65: MAPE por Tienda (1 a 12) y Género CHILDREN para el mes de abril 2022 usando Prophet (en %) .....	81
Tabla 66: MAPE por Tienda (13 a 23) y Género CHILDREN para el mes de abril 2022 usando Prophet (en %).....	82

## Índice de Ilustraciones

Ilustración 1: Distribución % de ventas por categoría y subcategoría de producto .....	15
Ilustración 2: Ventas Totales por Zona Geográfica (Año 2021).....	16
Ilustración 3: Ventas Totales por Mes y Zona Geográfica (Año 2021) .....	16
Ilustración 4: Ventas Totales por Mes y Categoría Accesorio (Año 2021) .....	17
Ilustración 5: Ventas Totales por Mes y Categoría Calzado (Año 2021) .....	18
Ilustración 6: Ventas Totales por Mes y Categoría Calzado sin outliers (Año 2021).....	19
Ilustración 7: Ventas Totales por Mes y Categoría Textil (Año 2021) .....	19
Ilustración 8: Ventas Totales por Mes y Categoría Textil sin outliers (Año 2021).....	20
Ilustración 9: Ventas Totales por día de la semana (Año 2021).....	21
Ilustración 10: Ventas Totales por Mes y Categoría (Año 2021).....	22
Ilustración 11: Ventas Totales por Mes y Subcategoría (Año 2021) .....	22
Ilustración 12: Ventas Totales por Mes y Género (Año 2021) .....	23
Ilustración 13: Ventas Totales por Tienda (Año 2021).....	23
Ilustración 14: Matriz de correlaciones entre ventas y precio (en niveles vs rezagos) (Año 2021) .....	24
Ilustración 15: MAPE mensual por categoría de producto: mes de febrero .....	54
Ilustración 16: MAPE mensual por categoría de producto: mes de marzo .....	55
Ilustración 17: MAPE mensual por categoría de producto: mes de abril.....	55
Ilustración 18: Total de quiebres de stock mensuales registrados (Año 2022) .....	59
Ilustración 19: Quiebres de stock antes y después de la redistribución de productos .....	62
Ilustración 20: Costos para la empresa antes y después de la redistribución de productos .....	65
Ilustración 21: % de cobertura por tienda variando $\alpha$ y $\omega t$ .....	66
Ilustración 22: % de cobertura y quiebres totales variando $\alpha$ con $\omega t$ fijo .....	67

# 1. Introducción

La previsión de la demanda es un factor importante en las decisiones dentro de la organización; la variable demanda marca el inicio en la cadena de suministro y su integración en la gestión de inventarios da lugar a políticas que minimizan costos de almacenamiento mediante el mantenimiento de cantidades para el abastecimiento, ajustadas a las necesidades de la organización con niveles de inventario justos y seguros evitando excesos y/o desabastecimiento<sup>1</sup>.

La planificación de la demanda en una organización, requiere identificar técnicas de pronósticos cualitativos y cuantitativos que se adapten a los diferentes comportamientos de los datos de demanda históricos y factores internos y externos del negocio donde se desarrolla; a su vez estos datos deben ser consistentes, lo cual se logra a través de la formulación e implementación de lineamientos de recolección de información y variables del mercado que tengan en cuenta elementos que afecten la demanda futura y posean una alta sensibilidad a los cambios en el negocio para evitar errores en la planificación.

En gran parte de las empresas de venta deportiva de mediana escala no existen herramientas cuantitativas para el pronóstico de demanda. Las estimaciones de ventas se llevan a cabo de manera subjetiva por medio de expertos de las gerencias comerciales y de compras entre las que se hace un consenso para determinar cuánto serán las estimaciones de ventas futuras basándose en un análisis visual de históricos de ventas.

Algunas de ellas profundizan un poco más y utilizan herramientas desarrolladas *in house* que realizan un análisis mínimo de compra alimentado con datos históricos de ventas o facturaciones, pero la sofisticación de los métodos no es adecuada para contemplar diferentes efectos sobre las estimaciones. Esto repercute en forma directa en su capacidad predictiva, generando grandes errores y desarrollando una planificación de inventarios bastante lejana a la necesidad real.

Los resultados de un buen manejo de planeación de demanda son notables si se mantiene una demanda estable y un pronóstico fiable de ventas controlada y verificada, proporcionando un inventario adecuado para satisfacer las necesidades del cliente en todo el sistema de distribución y mantener los niveles deseados de servicio al cliente (Young and Nie, 1992).

De esta forma, la organización puede mejorar el servicio al cliente (por ser más sensible), así como incrementar el rendimiento de las operaciones (a través de una mejor alineación entre la oferta y la demanda).

Así, el mejor pronóstico es aquel que, además de manipular los datos históricos mediante una técnica cuantitativa, también hace uso del juicio y el sentido común empleando el conocimiento de los expertos (Hanke and Wichern, 2014).

Existen diversas técnicas cuantitativas de pronóstico de la demanda. Entre las más comunes, se encuentran:

- Modelos de Series Temporales: Como el promedio móvil, el suavizado exponencial (*Holt-Winters*) y ARIMA (*Box-Jenkins*) (Hyndman and Athanasopoulos, 2018). Estos

---

<sup>1</sup> El desabastecimiento o falta de inventario en el lugar correcto dada la demanda, es lo que se conoce comúnmente como quiebre de *stock*.

modelos son útiles cuando la demanda tiene patrones temporales claros. Estos modelos han sido ampliamente utilizados y documentados en la literatura.

- Modelos de Regresión: Que relacionan la demanda con factores causales, como el precio, promociones, estacionalidad y factores macroeconómicos (Makridakis, Wheelwright and Hyndman, 1998). Estos modelos son especialmente útiles cuando la demanda es influenciada por factores externos.
- Técnicas de Machine Learning: Como redes neuronales, bosques aleatorios (random forest) y máquinas de soporte vectorial (SVM) (Hastie, Tibshirani and Friedman, 2009). Estas técnicas son cada vez más populares por su capacidad para manejar grandes conjuntos de datos y patrones complejos, y han mostrado buenos resultados en diversos estudios de pronóstico de demanda, pero aún necesitan de experiencia en el dominio del negocio para identificar sesgos y errores.

Una vez que se tiene un buen modelo de pronóstico de la demanda, se hace necesario su complemento con un buen modelo de redistribución para la gestión de los inventarios dada la demanda pronosticada.

En cuanto al problema de redistribución de inventarios, es común encontrar diferentes enfoques, incluyendo:

- Modelos de Programación Lineal: Como el modelo de transporte utilizado en este trabajo (Williams, 2013), que busca optimizar la distribución de productos entre ubicaciones, minimizando los costos de transporte.
- Modelos de Programación Entera Mixta: Que permiten modelar restricciones adicionales y decisiones más complejas, como la capacidad de los vehículos y los costos fijos de transporte (Taha, 2014).
- Heurísticas y Metaheurísticas: Que son utilizadas para resolver modelos de optimización más complejos o de gran escala, donde los métodos exactos pueden ser computacionalmente inviables (Glover and Kochenberger, 2003).

Estos modelos de redistribución son ampliamente usados, pero deben tener en cuenta los siguientes elementos para tomar las mejores decisiones:

- Consideración de los costos de transporte: No siempre aumentan de manera lineal con la cantidad de productos transportados, por lo que hay que definir qué suposiciones se tomarán en este aspecto.
- Actualización periódica del modelo: Dado que la demanda es dinámica y puede ser impactada por factores externos, es necesario actualizar el modelo de manera periódica.
- Uso de datos precisos: El modelo de redistribución se alimenta de pronósticos de demanda y niveles de stock, por lo tanto, dará mejores resultados cuanto mejor sean las proyecciones de demanda y los datos de inventario.

En este trabajo se desarrolla un modelo de pronóstico de demanda con el objetivo de lograr una redistribución óptima de mercaderías entre las tiendas de una empresa mexicana de venta de ropa deportiva, minimizando así los quiebres de stock. Estos últimos se generan cuando hay una

demanda insatisfecha producto del desabastecimiento o falta de inventario en el lugar donde ocurre esa demanda. Sus causas pueden ser múltiples:

- Errores en la planificación de la demanda por pronósticos imprecisos.
- Problemas logísticos como retrasos en el abastecimiento.
- Fallas operativas que afectan la reposición de inventarios.
- Incrementos repentinos en la demanda.

Y sus consecuencias, también:

- Pérdida de ventas.
- Daños a la reputación de la empresa (percepción de marca).
- Sobre-costos ante la necesidad de reabastecer inventario en forma urgente.
- Pérdida de clientes hacia la competencia.

En primera instancia se desarrollará el modelo de *forecasting*, para el cual se utilizaron técnicas de *machine learning* de aprendizaje supervisado; y luego se profundizará en el desarrollo del modelo de redistribución de mercadería entre tiendas desarrollado utilizando un modelo de programación lineal entera para optimización.

## 1.1. Contexto

La industria textil está íntimamente relacionada con la moda. Debido a esto, las empresas que la conforman enfrentan retos significativamente diferentes a otras industrias tal como la automotriz, consumo, construcción, entre otras. Uno de los procesos que más se distingue por su complejidad es el de planeación de demanda y capacidades de suministro, debido a factores como<sup>2</sup>:

- Temporadas:
  - El comportamiento natural de la demanda se rige por ciertas temporadas marcadas durante el año en base a las necesidades de los consumidores.
  - La competitividad en el mercado ha forzado a los jugadores de la industria a recurrir a la creación de temporadas para diferenciarse.
- Cortos ciclos de vida:
  - El producto final (prenda) cada vez dura menos tiempo en el armario antes de ser sustituido por un nuevo estilo.
- Diversas variables de alteración de demanda:
  - Demanda fuertemente influenciada por compras de impulso.
  - Creciente manejo de promociones y ofertas por parte de las tiendas.
  - Fuertemente afectada por factores climáticos, económicos, sociales y mediáticos.
- Alta volatilidad:
  - El comportamiento de la demanda dista de ser lineal, por el contrario, sufre cambios drásticos en períodos cortos de tiempo.

---

<sup>2</sup> SINTEC ®. Industria textil ¿Cómo enfrentar la incertidumbre de la demanda? Sistemas Interactivos de Consultoría, S.A. de C.V. [online], 2011 [revisado 4 de mayo de 2012]. Disponible desde internet: <[www.sintec.com.mx/Publicaciones/data/Articulo/IndustriaTextil.pdf](http://www.sintec.com.mx/Publicaciones/data/Articulo/IndustriaTextil.pdf)>

Las empresas textiles operan en un entorno de incertidumbre con el reto de cumplir con los requerimientos de sus clientes: tener el producto adecuado en la cantidad adecuada a tiempo, manteniendo los costos de su operación en niveles adecuados que les permitan asegurar la rentabilidad del negocio. Dado esto, los retos que enfrentan son:

- Lograr un claro entendimiento del comportamiento del mercado para sincronizar lanzamientos con la temporada (*time-to-market*).
- Flexibilidad y robustez operativa ante una demanda cambiante para cada categoría/marca y producto.
- Dificultad al identificar ciclos y estacionalidades para pronosticar la demanda.
- Manejo de gran cantidad de referencias (color por talla por estilo).
- Identificar el esquema óptimo para planear cada tipo de producto.
- Capacidad de generar visibilidad de la demanda a las áreas de cadena de suministro y proveedores.
- Mantener niveles de inventarios y control de obsoletos.
- Manejo de *lead-times* de proveedores internacionales con procesos, que al no ser bien administrados, pueden resultar en incremento de niveles de inventario y/o obsolescencias.

Este trabajo se desarrolló para una empresa mexicana de la industria retail de ropa deportiva, la cual cuenta con 22 tiendas distribuidas por todo el territorio (Tlaxcala, Puebla, Veracruz, Chiapas y Ciudad de México). En total suman 22, de las cuales 7 se encuentran posicionadas en centros comerciales y las 15 restantes en plaza (a la calle).

Los productos que comercializa la empresa se catalogan de la siguiente manera:

- Existen tres categorías: Calzado, Textil y Accesorios.
- Cada categoría cuenta con subcategorías de productos. Las tres tienen en común las subcategorías *Training, Skate, Soccer, Running, Casual* y *Basketball*; mientras que sólo Textil y Accesorios cuentan con la subcategoría *Swimming*. Sin embargo, dada la muy reducida cantidad de observaciones para *Swimming*, es una categoría que no será modelada.
- Los géneros por cada categoría-subcategoría de producto son: *Women, Men* y *Children*.

Al ser una industria de indumentaria, tiene plazos de compra muy diferentes a otros tipos de industrias: dadas las temporadas, es necesario que realicen sus compras con una anticipación de entre 7 y 9 meses. Por este motivo, la empresa necesita una previsión de sus ventas a largo plazo. Si bien el mayor porcentaje de las compras para satisfacer esa demanda de largo plazo se realiza con una gran anticipación (entre 7 y 9 meses), la empresa tiene la posibilidad de realizar pequeños volúmenes de compra más cercanos a la fecha de venta.

Sin embargo, esas compras de último momento no resultan muy convenientes ya que el costo sube en promedio un 30% y no en todos los casos se consigue la variedad deseada.

Dado esto, la primera etapa de la consultoría se basó en el desarrollo de un modelo de pronóstico de ventas (en unidades) de largo plazo con una ventana temporal de 9 meses desagregado por tienda, categoría/subcategoría de producto y género.

Como la variable a pronosticar (dependiente) de este modelo se basa en las unidades vendidas efectivamente, fue necesario realizar una corrección. Trabajar con las unidades vendidas efectivamente tiene un sesgo: que se hayan vendido, por ejemplo, 10 unidades, no significa que la demanda haya sido necesariamente de 10 unidades. *Hablar de ventas no es lo mismo que hablar de demanda*. Para suplir este sesgo se hizo foco en el quiebre de *stock* de las tiendas. Entonces, si para una categoría y subcategoría determinada las unidades vendidas fueron 10 y el quiebre de *stock* fue de 3 unidades, la demanda real fue de 13 unidades<sup>3</sup>.

Para contabilizar el quiebre de *stock*, la empresa no contaba con alguna metodología o sistema. Por ello, el primer paso fue crear una aplicación que permitió a cada una de las tiendas registrar en forma diaria cada solicitud de un cliente por un producto específico no satisfecha (dejando registro de la tienda, categoría/subcategoría del producto, talla, etc<sup>4</sup>). En el Apéndice B puede verse en funcionamiento la interfaz desarrollada para el registro de quiebre de *stocks*.

Así, previo al entrenamiento de los modelos de pronóstico, se ajustaron los valores de unidades efectivamente vendidas por un factor de corrección determinado por el porcentaje de quiebres de *stock* que permitió registrar la herramienta.

## 1.2. Problema

Tras realizar un análisis de los datos recolectados por la herramienta de registro de quiebres de *stock* luego de los primeros tres meses de uso, se observó que en promedio había 20 quiebres por tienda/día, lo cual equivale en promedio a un 6.5% de las ventas mensuales totales. Este es un dato al que no se le está prestando la atención que merece y que podría afectar significativamente la rentabilidad de la empresa. Esta última implicancia va de la mano de una pérdida de ventas visible (personas que buscaban un producto y no lo encontraron disponible) como así también de una pérdida de potenciales clientes y disminución de fidelización de los ya activos.

Esta es la principal motivación del presente trabajo: dada la estructura de compras con una anticipación de nueve meses, se hizo necesario sumar una visión cortoplacista del negocio que permitiera predecir las unidades vendidas para los próximos días (quincena) y con esos resultados establecer una redistribución de mercadería entre tiendas que permita recortar lo más posible los quiebres de *stock*.

En términos económicos, el problema de optimización que se resuelve para reducir los quiebres de *stock* dada la demanda pronosticada y el nivel de inventario por tienda garantiza que el costo promedio de reducir esos quiebres no sea más elevado que el beneficio que otorgaría vender esas unidades adicionales. Generalmente, el costo de la distancia recorrida para abastecer a una tienda con faltantes es menor al costo asociado a no realizar la venta de los productos. Pero en el caso extremo en que el beneficio de la venta no supere al costo del traslado (por ejemplo,

---

<sup>3</sup> Aquí se podría hacer un segundo ajuste: no todos los quiebres de *stock* terminan necesariamente en una venta cerrada. Para el desarrollo de este trabajo, se considera que el total de quiebres de *stock* se traduce en ventas.

<sup>4</sup> Para el desarrollo de esta aplicación ejecutable, se utilizó tkinter en Python (que permite crear interfaces amigables para el usuario) almacenando las entradas de datos directamente en un *google sheets* en el *drive*. El script con el desarrollo de la aplicación puede verse en el siguiente [link](#).

para tiendas muy lejanas entre sí y niveles potenciales de quiebre muy bajos), igual existen otros beneficios cuyo valor económico es más difícil de establecer, y que al compararlos con el costo del transporte más que lo compensan a los ojos de la organización. Algunos de ellos son la fidelización de los clientes, una mejor experiencia del usuario o comprador, posicionamiento de la marca, entre otros.

### **1.3. Objetivo**

Con el objetivo de disminuir los quiebres de *stock* por tienda y de esa manera mejorar tanto la rentabilidad de la empresa como la satisfacción del cliente, se plantea realizar un modelo de pronóstico de ventas diario de corto plazo (para la próxima quincena) que permita redistribuir el stock entre tiendas en forma óptima.

El trabajo consiste en los siguientes pasos:

- Desarrollo del modelo de pronóstico de ventas de corto plazo por categoría, subcategoría, género y tienda. No realizarlo a nivel sku está fundamentado en la multiplicidad de modelos que ello implicaría, la falta de información completa y extendida en el tiempo para cada uno de los sku y en la baja precisión que tendría hacerlo tan granular dados los reducidos o nulos volúmenes de venta diarios por sku.
- Validación del modelo anterior durante un período de dos meses para confirmar el error *out-of-sample* y recalibrarlo en consecuencia si fuera necesario.
- Desarrollo del modelo de redistribución de mercadería entre tiendas, en base al inventario y al pronóstico de ventas realizado por categoría, subcategoría, género y tienda.

## 2. Datos

Toda la información con la que se trabajó tanto en el modelo de pronóstico como en el de redistribución es de carácter interno, por lo que la misma no puede exponerse. Sin embargo, sí puede realizarse una descripción:

- La información de ventas se encuentra en forma diaria, desagregada por categoría, subcategoría, género y tienda.
- Precio de venta y el costo de cada producto vendido. El precio es un determinante principal de la demanda, con lo cual es una variable que debe considerarse al realizar pronósticos de demanda.
- Los datos del inventario están también desagregados por categoría, subcategoría, género y tienda. Esto permitió cruzarlos con la información de los pronósticos realizados e implementar el sistema de redistribución de mercadería entre tiendas.
- La ubicación de cada una de las tiendas (con su respectiva latitud y longitud), permite calcular la distancia en km entre cada par de ellas.
- Por cada una de las tiendas se cuenta con información de los paseantes y visitas, gracias a detectores de movimiento posicionados en las entradas. Este dato da una idea de la cantidad de personas que pasa por el local frente a la cantidad que efectivamente ingresa. Si bien es un buen indicador de la demanda potencial, la realidad es que cuenta con algunas inconsistencias y su utilización como variable explicativa en un modelo de pronóstico implicaría la necesidad de proyectar sus valores con modelos (incurriendo en un error adicional de pronóstico). Por lo expuesto, se decidió excluirlas como variables potenciales del modelo.

Hasta el momento se describió que los modelos se encuentran desarrollados a nivel categoría, subcategoría, género y tienda. La siguiente **Tabla 1** resume esa desagregación en subcategorías y géneros para una de las categorías:

**Tabla 1: Desagregación de la categoría Calzado en subcategorías y géneros**

Categoría	Subcategoría	Género
Calzado	Training	Women
Calzado	Training	Men
Calzado	Training	Children
Calzado	Skate	Women
Calzado	Skate	Men
Calzado	Skate	Children
Calzado	Soccer	Women
Calzado	Soccer	Men
Calzado	Soccer	Children
Calzado	Running	Women
Calzado	Running	Men
Calzado	Running	Children
Calzado	Casual	Women
Calzado	Casual	Men
Calzado	Casual	Children
Calzado	Basketball	Women
Calzado	Basketball	Men
Calzado	Basketball	Children

Tanto la categoría Textil como la de Accesorios se desagregan de la misma forma que lo hace la categoría Calzado. Además, cuentan con una subcategoría adicional llamada *Swimming*. Sin embargo, dada la muy reducida cantidad de observaciones para ésta última, no será modelada.

La distribución de las tiendas por el territorio de México se plasma en la siguiente **Tabla 2**:

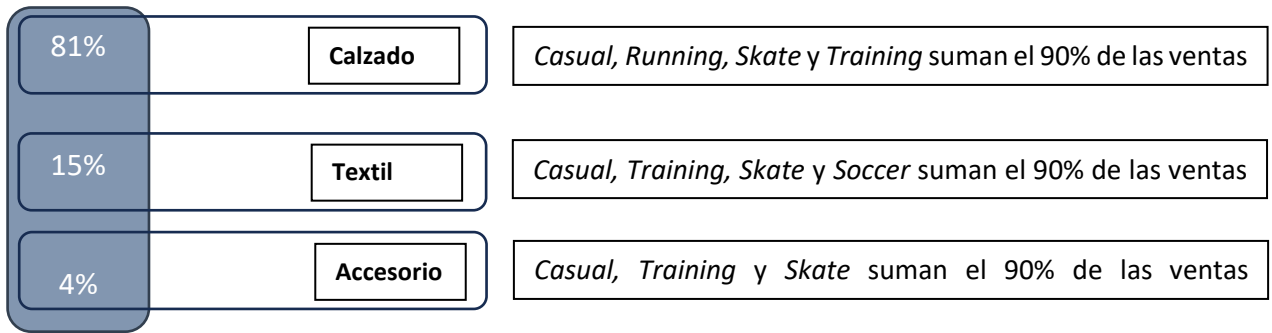
**Tabla 2: Distribución de las tiendas por zona y ubicación**

Zona Geográfica	Centro Comercial	Plaza (a la calle)	Total
Tlaxcala	1	2	3
Puebla	2	5	7
Veracruz	1	2	3
Chiapas	1	2	3
Ciudad de México	2	4	6
Total	7	15	22

Se evidencia a partir de ella que los principales puntos de venta en cuanto a cantidad de tiendas son Puebla y Ciudad de México, seguidos con igual orden de importancia por Tlaxcala, Veracruz y Chiapas.

Para dar una idea de la distribución histórica de las ventas por categoría y subcategoría, se presenta la siguiente **Ilustración 1**:

Ilustración 1: Distribución % de ventas por categoría y subcategoría de producto



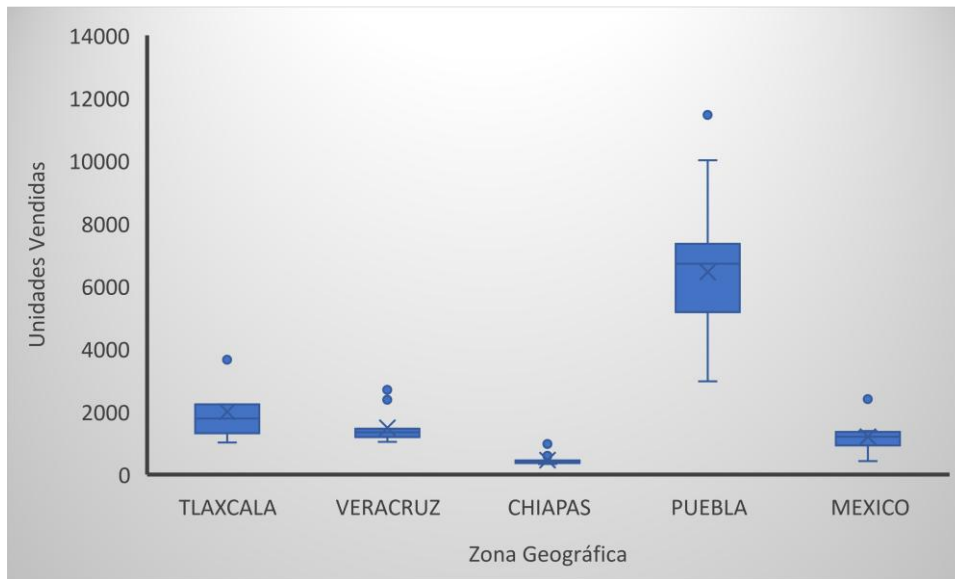
Es importante aclarar que el modelo de *forecasting* ha sido entrenado con data desde enero 2021 hasta enero 2022. Las razones de no utilizar un período de dos años se explican por los siguientes puntos:

- **Disponibilidad y comparabilidad.** El flujo de ventas es estable y homogéneo recién desde 2021 (red de 22 tiendas consolidada desde enero 2021); antes había aperturas y cierres de tiendas.
- **2020 no representativo.** El impacto del COVID produjo cierres, demanda artificialmente deprimida y políticas comerciales excepcionales. Había meses con ventas nulas por cierres sanitarios, promociones atípicas para liquidar inventarios y una mezcla de tiendas abiertas/cerradas que no refleja la operación actual.
- **2019 sólo como “lag-ancla”.** Se emplea para crear las variables rezagadas (t-52 semanas) que se utilizan como variables explicativas del modelo y su detalle se encuentra en la sección 3.1. Esto es porque refleja un año “normal” sin distorsiones de la pandemia, pero no para aprender la dinámica del nivel de ventas (la red de tiendas era distinta a la actual de la empresa).

Dicho lo anterior, el entrenar el modelo con data del año 2021 permite aprender la realidad operativa vigente, garantizando que los patrones observados (tendencia, estacionalidad y elasticidad-precio) son coherentes con los que el modelo debe aprender. De esta forma, el análisis exploratorio se centra en 2021 porque es el primer año completo y el objetivo es entender los patrones de los datos que realmente alimentan al modelo.

A continuación, se presenta una serie de análisis estadísticos con el fin de describir en forma visual el comportamiento de los datos utilizados luego para el desarrollo del modelo de *forecasting*.


**Ilustración 2: Ventas Totales por Zona Geográfica (Año 2021)**



Tal como puede observarse en la **Ilustración 2**, Puebla es la zona con mayor volumen de ventas pero también con mayor variabilidad respecto a su media. Por el contrario, Chiapas es la zona con menor volumen de ventas y menor variabilidad respecto a su media.

En la siguiente **Ilustración 3**, se muestran las ventas por mes y zona geográfica para el año 2021:

**Ilustración 3: Ventas Totales por Mes y Zona Geográfica (Año 2021)**




Puede apreciarse en general una tendencia creciente a lo largo del año 2021 en las ventas de las distintas zonas geográficas en las cuales se encuentra situada la empresa. Nuevamente, la línea gris que representa a las ventas de Puebla, se encuentra por encima de las restantes zonas

geográficas (lidera las ventas de la empresa). Además, se observa la estacionalidad de los meses de noviembre y diciembre, en los cuales las ventas crecen por las fiestas.

En la siguiente **Ilustración 4**, se muestran las ventas por mes y categoría Accesorio para el año 2021:

**Ilustración 4: Ventas Totales por Mes y Categoría Accesorio (Año 2021)**



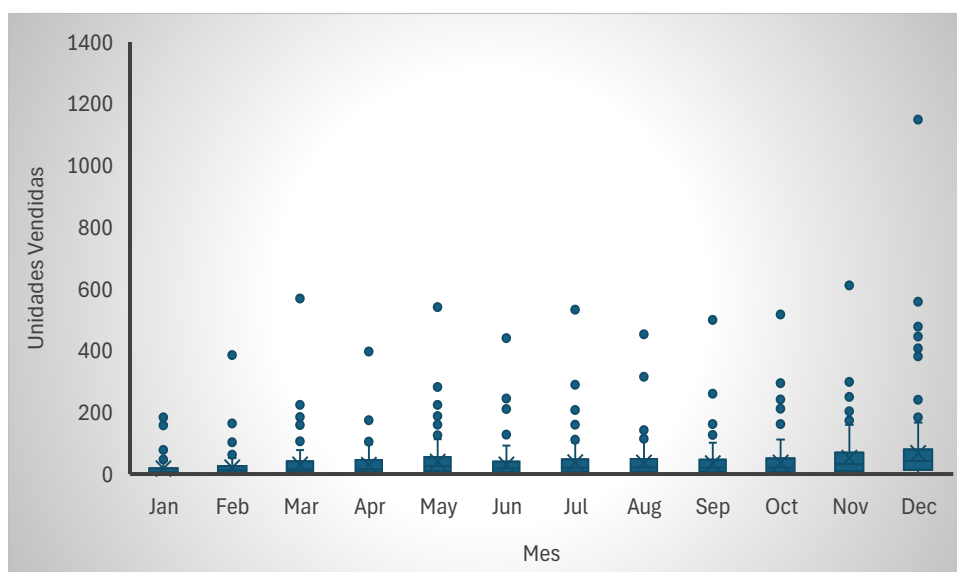
Se identifica un claro patrón estacional en el comportamiento de la demanda. Se observa una tendencia creciente en los niveles de venta a lo largo del año, alcanzando su punto máximo en el mes de diciembre. Este último mes no solo presenta la mayor mediana de ventas, sino también la mayor dispersión, reflejada en un rango intercuartílico amplio y numerosos valores atípicos hacia el extremo superior. Este comportamiento sugiere una demanda más elevada y variable, probablemente explicada por campañas comerciales de fin de año, promociones o eventos estacionales como las compras navideñas.

Meses como junio, noviembre y diciembre destacan particularmente por su alto volumen de ventas y mayor presencia de *outliers*, lo cual podría indicar semanas puntuales de alta actividad o rupturas en el comportamiento promedio del mes. En contraposición, los meses comprendidos entre enero y abril muestran niveles de venta más bajos, con menor dispersión y un comportamiento más homogéneo. Estos meses iniciales del año parecen reflejar un período de menor dinamismo comercial.

Desde el punto de vista operativo, el análisis resalta la necesidad de una planificación de *stock* ajustada al patrón estacional observado.

En la siguiente **Ilustración 5**, se muestran las ventas por mes y categoría Calzado para el año 2021:


**Ilustración 5: Ventas Totales por Mes y Categoría Calzado (Año 2021)**



Se identifica un patrón de comportamiento relativamente estable a lo largo del año, con un leve incremento hacia los meses de noviembre y diciembre. La mediana de ventas se mantiene en niveles similares durante gran parte del año, lo cual indica que no existe una estacionalidad fuertemente marcada en el volumen promedio de ventas mensuales. Sin embargo, se observan múltiples valores atípicos distribuidos en varios meses, especialmente a partir de marzo, lo cual sugiere la existencia de días con comportamientos extraordinarios que se alejan significativamente del promedio habitual. El rango intercuartílico de la mayoría de los meses se mantiene relativamente acotado, indicando que, en condiciones normales, las ventas diarias tienden a concentrarse dentro de un rango predecible y controlado.


A continuación, se observa la misma ilustración pero habiendo removido los outliers, de forma tal que sea más visible el comportamiento mes a mes.

**Ilustración 6: Ventas Totales por Mes y Categoría Calzado sin outliers (Año 2021)**



En la siguiente **Ilustración 7**, se muestran las ventas por mes y categoría Textil para el año 2021:

**Ilustración 7: Ventas Totales por Mes y Categoría Textil (Año 2021)**




Permite evidenciar un patrón estacional progresivo, donde las ventas aumentan gradualmente hacia los últimos meses del año. Diciembre se destaca como el mes con mayores volúmenes de venta, tanto en su mediana como en la amplitud total de la distribución, seguido por noviembre y, en menor medida, por julio y mayo. Estos resultados son consistentes con una dinámica comercial típica del sector *retail*, donde el cierre de año concentra la mayor actividad debido a fechas festivas, promociones especiales y mayor demanda por parte del consumidor.

El rango intercuartílico (la caja) también se amplía en los últimos meses del año, lo que sugiere una mayor dispersión en los volúmenes de venta, acompañada de una notable presencia de

valores atípicos (*outliers*), principalmente en diciembre, donde se alcanzan picos de demanda diaria por encima de las 250 unidades. Este comportamiento refuerza la necesidad de un planeamiento comercial más robusto y flexible para los meses de alta demanda, a fin de evitar quiebres de stock o pérdidas de ventas por falta de cobertura.

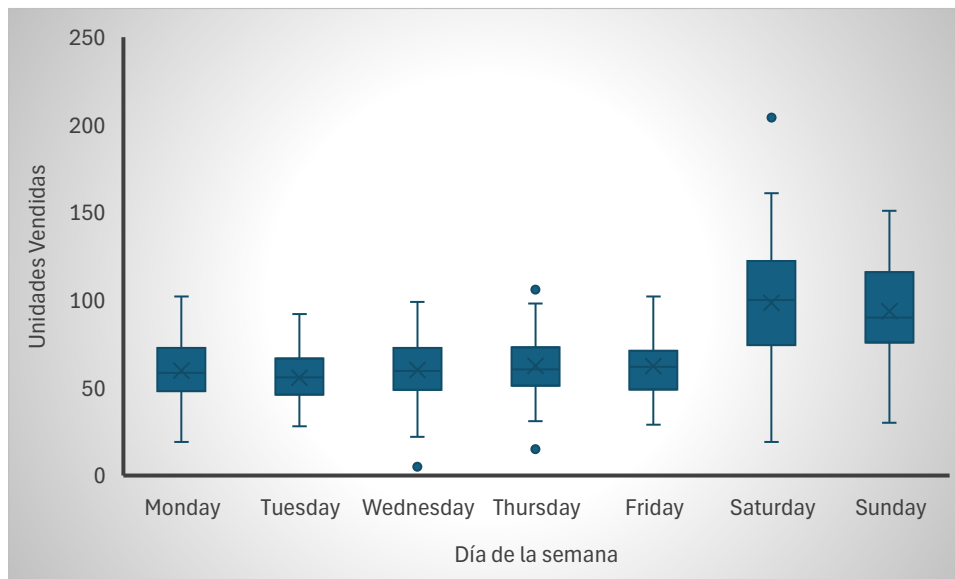
A continuación, se observa la misma ilustración pero habiendo removido los outliers, de forma tal que sea más visible el comportamiento mes a mes.

**Ilustración 8: Ventas Totales por Mes y Categoría Textil sin outliers (Año 2021)**



En la siguiente **Ilustración 9**, se muestran las ventas por día de la semana para el año 2021:

**Ilustración 9: Ventas Totales por día de la semana (Año 2021)**




Se identifica una clara variación en el comportamiento de la demanda a lo largo de la semana. Los días laborables, de lunes a viernes, presentan volúmenes de ventas relativamente estables y similares entre sí, con medianas que oscilan en torno a las 60 unidades y una dispersión moderada. Esto sugiere un comportamiento regular durante los días hábiles, donde las ventas mantienen una dinámica predecible sin grandes fluctuaciones.

En contraste, los fines de semana (sábado y domingo) muestran un comportamiento significativamente distinto. Ambos días presentan un aumento considerable tanto en la mediana como en la dispersión de las ventas. En particular, el sábado alcanza los niveles más altos, con una mediana notablemente superior y una gran amplitud en su rango intercuartílico, lo que refleja una mayor variabilidad y picos de demanda más frecuentes. Este patrón también se observa en el domingo, aunque en menor medida. La presencia de *outliers* en estos días también sugiere que existen jornadas de ventas excepcionalmente altas durante el fin de semana.

La siguiente **Ilustración 10** permite apreciar la distribución relativa de las ventas entre las 3 categorías de productos:


**Ilustración 10: Ventas Totales por Mes y Categoría (Año 2021)**



Nuevamente puede verse la tendencia creciente a lo largo del año y una estacionalidad en los últimos dos meses del año con un fuerte dominio de la categoría Calzado en el total de ventas por mes de la empresa.

En la siguiente **Ilustración 11** se aprecian las ventas por subcategoría para el año 2021:


**Ilustración 11: Ventas Totales por Mes y Subcategoría (Año 2021)**



Tal como se aprecia en el gráfico de barras apiladas, las principales subcategorías generadoras de ventas son *Casual* y *Skate*, seguidas por *Training* y *Running*.

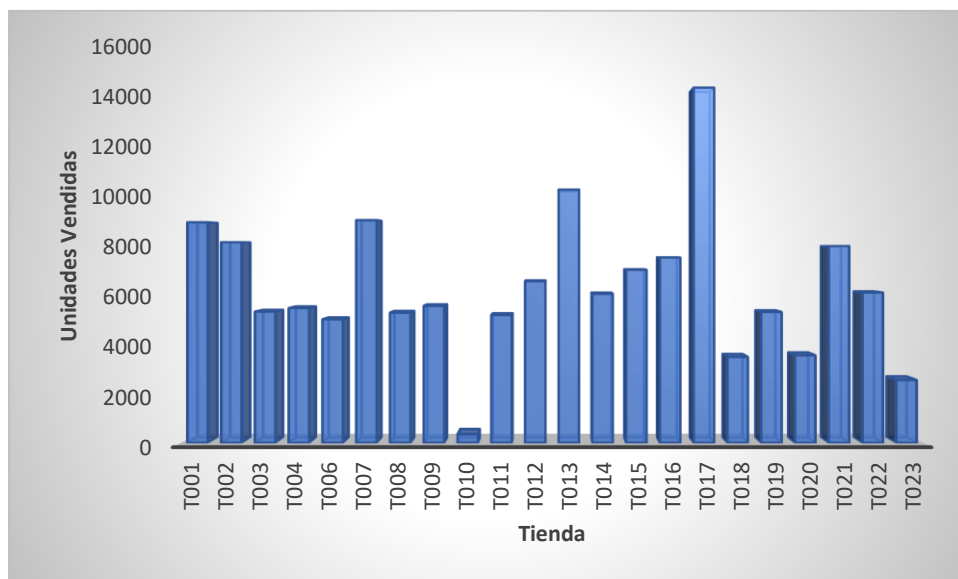
La siguiente **Ilustración 12** enseña la distribución de las ventas mensuales por género. El género con más contribución en las ventas es *Men*, seguido por *Women* que no se aleja tanto de la contribución de *Children*.

**Ilustración 12: Ventas Totales por Mes y Género (Año 2021)**



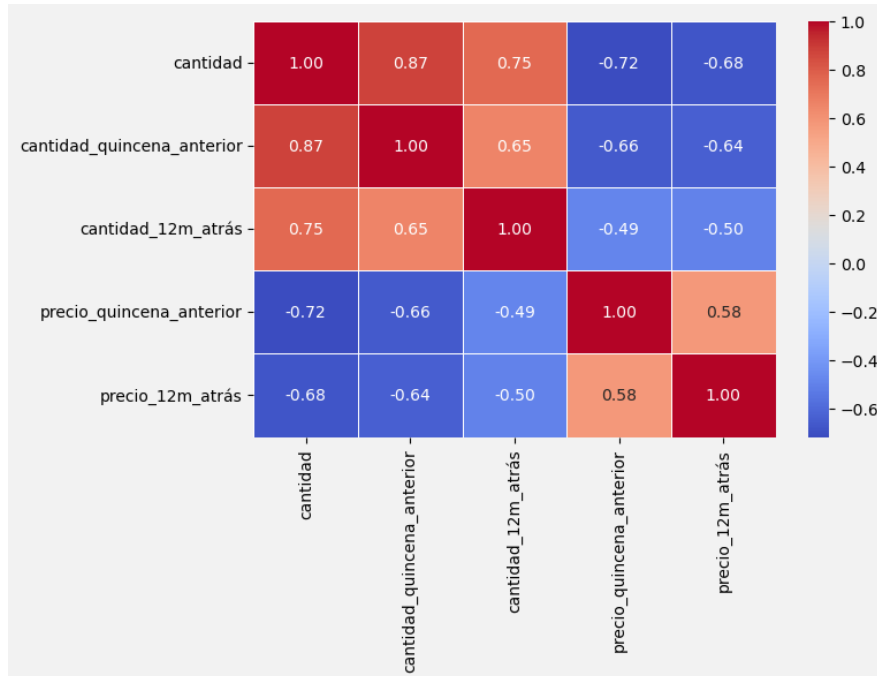
La **Ilustración 13** muestra el volumen de ventas por tienda para todo el año 2021. Tal como se observa, las principales contribuyentes son las tiendas 17, 13, 7 y 1. La tienda 10 en particular, maneja un bajo volumen explicado por su ubicación y por ser del tipo franquicia de una marca específica.

**Ilustración 13: Ventas Totales por Tienda (Año 2021)**



En la siguiente **Ilustración 14**, se muestran las correlaciones para ventas-*lag* de ventas y ventas-*lag* de precios para el año 2021:

**Ilustración 14: Matriz de correlaciones entre ventas y precio (en niveles vs rezagos) (Año 2021)**



Se observa una alta correlación positiva (0.87) entre las ventas actuales y las ventas de la quincena anterior, lo cual sugiere una fuerte dependencia temporal inmediata en el comportamiento de la demanda. También se evidencia una correlación positiva moderadamente alta con las ventas de doce meses atrás (0.75), lo cual indica la existencia de patrones estacionales recurrentes, particularmente en ciclos anuales.

En cuanto a los precios, se observa una correlación negativa significativa entre las ventas actuales y el precio de la quincena anterior (-0.72), así como con el precio de doce meses atrás (-0.68). Esto implica que, en general, cuando los precios suben, las ventas tienden a disminuir, lo cual es consistente con un comportamiento de demanda sensible al precio.

Los precios se presentan en términos nominales porque las variaciones intra-anales debidas a promociones superan ampliamente a la inflación. Además, es la forma en la que finalmente el modelo de pronóstico consume esta variable, lo cual viene explicado por:

- Horizonte operativo corto. El modelo pronostica a corto plazo y la variación inflacionaria dentro de ese período es mucho menor que la variabilidad promocional (15 - 30 %).
- Decisión de negocio en moneda corriente. La elasticidad estimada sobre precio nominal es directamente accionable para fijar precios de lista y descuentos.

Adicionalmente, las correlaciones entre las propias variables rezagadas también muestran consistencia, lo que refuerza la idea de una demanda que responde tanto a tendencias recientes como a comportamientos estacionales.

### 3. Metodología

El enfoque adoptado consta en primera instancia del desarrollo de un modelo de pronóstico de demanda de corto plazo por tienda, categoría, subcategoría y género de producto. Para ello, se utilizó el modelo de pronóstico Facebook Prophet (previamente comparado con el resultado de otros modelos de aprendizaje supervisado) para el cual se constató el error de pronóstico con metodologías de *backtesting*.

Luego, sus resultados sirvieron para alimentar a un modelo de redistribución de inventarios entre tiendas implementado mediante un modelo de programación lineal entera enfocado principalmente en maximizar los porcentajes de cobertura en las tiendas con faltantes para una categoría, subcategoría y género específicos, tratando de minimizar así los quiebres de *stock*.

En la sección de **Resultados**, se hizo una validación integral de la metodología propuesta con *backtesting*, utilizando como indicador de performance a los quiebres de *stock* en porcentaje del total de ventas en un escenario con redistribución de inventarios versus uno sin redistribución. Esto es lo que permitió evaluar la eficiencia de la redistribución sugerida en base al pronóstico efectuado. En forma complementaria, se realizaron análisis aislados para entender la contribución marginal de cada modelo en la reducción de los quiebres de *stock*. Para ello, se partió de un escenario base sin redistribución, luego se consideró un escenario de *Forecasting* donde se asume que la empresa puede reaprovisionarse en base al pronóstico de demanda, y finalmente se incluyó el escenario de Redistribución que utiliza al modelo de *Forecasting* como input para sugerir una reasignación óptima de *stocks* entre las tiendas. Por último, se implementó un análisis de sensibilidad con diferentes escenarios para mostrar cómo se altera el porcentaje de cobertura de las tiendas con faltantes ante variaciones en los costos de quiebre por tienda y un parámetro que permite balancear la importancia entre los costos de quiebre y los costos de la distancia recorrida para cubrir esos quiebres.

#### 3.1. Modelo de *Forecasting*

La definición del modelo de pronóstico de corto plazo (próxima quincena) está dada por la siguiente estructura:

$\widehat{Y}_{cst}$ : son las ventas pronosticadas por cada día en la quincena  $t$  para una categoría y subcategoría específicas.

$Y_{cst-1}$ : son las ventas reales del día de la quincena inmediatamente anterior al día de la quincena que se está pronosticando para una categoría y subcategoría específicas (ventas quince días atrás).

$Y_{cst-24}$ : son las ventas reales del día de la misma quincena del año anterior al día de la quincena que se está pronosticando para una categoría y subcategoría específicas (ventas 365 días atrás).

$P_{cst-1}$ : es el precio promedio real del día de la quincena inmediatamente anterior al día de la quincena que se está pronosticando para una categoría y subcategoría específicas (precio 15 días atrás).

$P_{cst-24}$ : es el precio promedio real del día de la misma quincena del año anterior al día de la quincena que se está pronosticando para una categoría y subcategoría específicas (precio 365 días atrás).

Dando lugar esas variables a definir a  $\widehat{Y}_{cst}$  (variable dependiente) en función de  $Y_{cst-1}, Y_{cst-24}, P_{cst-1}, P_{cst-24}$  (variables independientes):

$$\widehat{Y}_{cst} = f(Y_{cst-1}, Y_{cst-24}, P_{cst-1}, P_{cst-24}) \quad \dots (1)$$

Cada modelo por categoría y subcategoría de productos fue entrenado con datos diarios para tener mayor variabilidad y volumen de observaciones. Luego, el pronóstico de la próxima quincena para una categoría y subcategoría de producto dada resulta de totalizar los pronósticos diarios realizando la suma de todos los días comprendidos en la quincena. A modo de ejemplo, la definición del pronóstico de ventas para el 16 de marzo (V16m) vendría dada por:

$$V16m = f(V1m, V16m \text{ año anterior}, P1m, P16m \text{ año anterior}) \quad \dots (2)$$

La desagregación en esta etapa no se hizo por género y tienda ya que de esa forma las observaciones eran escasas o bien con volúmenes de venta diarios muy reducidos, lo que dificulta el aprendizaje de los modelos (y por ende su precisión). En la sección de Implementación del modelo de *forecasting*, se profundiza sobre cuánto mejora el error de este al pasar de modelos a nivel categoría-subcategoría-género-tienda hacia modelos a nivel categoría-subcategoría para entender las necesidades y beneficios asociados a esta decisión.

Una vez obtenido el *forecast* a nivel categoría y subcategoría de producto, se distribuyó por género y tienda en base a porcentajes promedio históricos de los últimos 6 meses. Esta fue la forma de entrenar modelos precisos y en el nivel de desagregación necesario.

Utilizar ese período de tiempo para la distribución de los pronósticos por género y tienda viene fundamentado por los siguientes puntos:

- **Representatividad estacional.** Seis meses cubren un ciclo completo de temporada alta y baja sin mezclar el pico de fiestas de noviembre-diciembre y, por lo tanto, ofrecen pesos neutros. En un *back-test* 2020-2022, la ventana de 6 meses redujo el *Mean Absolute Percentage Error* (MAPE) del modelo a nivel categoría-subcategoría distribuido por tienda-género un 16 % frente a 3 meses y un 11 % frente a 12 meses.
- **Equilibrio entre estabilidad y agilidad.** Con ventanas  $\leq 3$  meses la varianza es alta en tiendas de bajo volumen; con ventanas  $\geq 9$  meses se arrastran patrones que la compañía ya corrigió (por ejemplo, cierres por COVID-19). El coeficiente de variación (CV) de las participaciones cae de 0.48 con 3 meses a 0.29 con 6 meses, con sólo un descenso marginal a 0.28 al pasar a 9 meses.
- **Consistencia con la cadencia de compra.** La empresa repone la mayor parte del surtido de forma semestral, de modo que seis meses coinciden con la “unidad natural” de ajuste. Los historiales de órdenes muestran que más del 80 % de los SKU se reordenan con un *lead-time* de aproximadamente 180 días.
- **Robustez ante datos atípicos de pandemia.** Incluir los 12 meses previos incorpora meses muy anómalos (abril-junio 2020) que distorsionan las participaciones.

Se utilizó el promedio como métrica para realizar la distribución, y no la mediana, el último valor o un modelo adicional, ya que:

- **Respetar la propiedad de suma-a-uno** sin necesidad de reconciliación jerárquica adicional: cada tienda recibe exactamente la misma masa total pronosticada a nivel categoría–subcategoría.
- **Suaviza valores atípicos sin perder señal**: la media de 6 meses atenúa picos de liquidaciones puntuales, pero mantiene las diferencias estructurales del *mix*.
- **Baja complejidad operativa**: las participaciones se actualizan fácilmente cada mes; no requiere pipelines ni entrenamiento extra.
- **Promedio vs. Mediana**: la mediana redujo ligerísimamente el impacto de *outliers*, pero generó tiendas con participaciones “cero” o “casi cero” (difícil de reconciliar y obligando a realizar ajustes manuales para suplirlo). Previo al cálculo de los errores del modelo utilizando la mediana, se re-escaló la misma para que las participaciones sumen 1. Si bien la mediana redujo levemente la variabilidad de las participaciones (-0.03 pp), también incrementó el MAPE global (+0.5 pp). Las diferencias son estadísticamente no significativas y carecen de impacto operativo apreciable. Pero, habiendo generado el uso de la mediana participaciones  $\approx 0\%$  en 6 tiendas (lo que requiere imputación manual), se eligió el promedio por simplicidad y mantenimiento.
- **Promedio vs. Último Mes**: la participación del último mes fue 2.4 pp peor en MAPE debido a ruido de promociones.

## **Background**

Trabajar con datos de series temporales es una tarea compleja, y los diversos algoritmos que generan modelos suelen ser bastante difíciles de ajustar. Esto es particularmente cierto si se está trabajando con datos que tienen múltiples estacionalidades.

Además, los modelos de series de tiempo tradicionales como SARIMAX tienen muchos requisitos de datos estrictos, como ser trabajar con series estacionarias y valores igualmente espaciados (Hyndman and Athanasopoulos, 2018). Otros modelos de series temporales como las redes neuronales recurrentes con memoria a largo y corto plazo (RNN-LSTM) pueden resultar muy complejos de aplicar para determinados conjuntos de datos que quizás no lo requieren, o bien porque no se cuenta con un volumen y nivel de desagregación apto para ser pasado por una red neuronal de ese tipo (Gridin, 2022).

Es por ello que en este proyecto se trabajó con *Facebook Prophet*<sup>5</sup>, un modelo de pronóstico a escala, rápido, poderoso y accesible.

*Prophet* es un procedimiento para pronosticar datos de series temporales basado en un modelo aditivo en el que las tendencias no lineales se ajustan a la estacionalidad anual, semanal y diaria,

---

<sup>5</sup> Luego de haber testeado otros modelos de machine learning (KNN, XGBoost, SVM y Random Forest) y una aproximación simplista (Naive Estacional), al comparar los errores de ellos con el de FB Prophet se encontró que eran mucho mayores. Es por eso que en este trabajo se desarrolla en profundidad la metodología FB Prophet, que fue la efectivamente utilizada como herramienta de pronóstico.

además de los efectos de las vacaciones. Funciona mejor con series temporales que tienen fuertes efectos estacionales y varias temporadas de datos históricos. Es resistente a los datos faltantes y a los cambios en la tendencia, y por lo general maneja bien los valores atípicos.

Algunas ventajas prácticas:

- Flexibilidad: se puede acomodar fácilmente la estacionalidad con múltiples períodos y hacer suposiciones sobre las tendencias.
- No es necesario espaciar regularmente las medidas y no es necesario interpolar los valores faltantes o eliminar los valores atípicos.
- El ajuste es muy rápido, lo que permite explorar de forma interactiva muchas especificaciones del modelo.
- El modelo de pronóstico tiene parámetros fácilmente interpretables que se pueden cambiar para imponer suposiciones en el pronóstico.

### **Algoritmos complementarios**

#### **Naive Estacional**

Si bien su simplicidad limita su precisión en comparación con modelos avanzados, ofrece una línea de base fundamental para evaluar la efectividad de modelos más complejos, especialmente en contextos con patrones estacionales claros. En este caso, el modelo naive estacional asume que el valor de la demanda en un día específico será igual al valor observado en el mismo día del año anterior (Hyndman and Athanasopoulos, 2018). Por lo tanto, si se quiere pronosticar la demanda para una serie de días futuros, este modelo usa los datos históricos de esos mismos días en el año anterior.

En fórmula, queda expresado como:

$$\hat{y}_t = y_{t-365} \quad \dots (3)$$

Donde:

- $\hat{y}_t$  es el pronóstico de demanda para el día t en el año actual.
- $y_{t-365}$  es el valor observado de demanda en el mismo día t del año anterior.

Algunas consideraciones:

- Asume estabilidad estacional: la demanda en el mismo día del año anterior es un buen predictor para la demanda del día actual. Esta lógica se basa en el hecho de que las demandas suelen tener patrones estacionales, y valores anteriores en un mismo período reflejan de forma aproximada la demanda futura.
- Pronósticos diarios: cada día en el período de pronóstico es estimado usando el valor del mismo día en el año previo. Por ejemplo, la demanda del 15 de marzo de este año se predice usando la demanda observada el 15 de marzo del año anterior. No requiere variables adicionales ni aprendizaje supervisado complejo.

### **K Nearest Neighbors (KNN)**

Es un clasificador de aprendizaje supervisado no paramétrico, que utiliza la proximidad para hacer predicciones sobre la agrupación de un punto de datos individual. La forma en que realiza la predicción de un nuevo punto es tomando el promedio de los k vecinos más cercanos (Gareth, Witten, Hastie and Tibshirani, 2017). Sin embargo, antes de que se pueda hacer una predicción para determinar qué puntos de datos están más cerca de un punto de consulta determinado, será necesario calcular la distancia entre el punto de consulta y los otros puntos de datos. Estas métricas de distancia ayudan a formar límites de decisión, que dividen los puntos de consulta en diferentes regiones. La distancia euclidiana es la medida más utilizada y resulta de la siguiente fórmula:

$$d(x, y) = \sqrt{\sum_{i=1}^n (y_i - x_i)^2} \quad \dots (4)$$

De esta forma, se puede iterar por diferentes valores de K (hiperparámetro del modelo) e ir evaluando el error en el set de testeo para cada uno de esos valores. Un buen valor de K será aquel que resulte de un error reducido al comparar la predicción con el valor real. A modo de regla, cuanto mayor es el valor de K, disminuye la varianza y aumenta el sesgo del modelo; por el contrario, cuanto menor es aumenta la varianza y disminuye el sesgo (con riesgo de hacer *overfitting* o estar sobreajustado al set de entrenamiento).

### **Extreme Gradient Boosting (XGB)**

Los modelos de aprendizaje automático pueden ajustarse a los datos individualmente o combinarse con otros modelos, creando un conjunto.

El *boosting* de aprendizaje automático es un método que crea este tipo de conjuntos (Gareth, Witten, Hastie and Tibshirani, 2017). Comienza ajustando un modelo inicial (un árbol de regresión o clasificación) a los datos. A continuación, se construye un segundo modelo que se centra en predecir con exactitud las observaciones que el primer modelo predijo mal. Se espera que la combinación de estos dos modelos sea mejor que cada uno de ellos. Este proceso de refuerzo se repite varias veces, y cada modelo sucesivo intenta corregir las deficiencias del conjunto refuerzo combinado que contiene todos los modelos anteriores.

Los modelos se ajustan utilizando cualquier función de pérdida diferenciable arbitraria y algoritmo de optimización de descenso de gradiente. Esto le da a la técnica su nombre, aumento de gradiente, ya que el gradiente de pérdida se minimiza a medida que se ajusta el modelo, al igual que una red neuronal.

El modelo permite construir un modelo de predicción para una variable de respuesta cuantitativa a partir de variables explicativas que pueden ser cuantitativas y/o cualitativas.

Iterar por diferentes combinaciones de sus hiperparámetros permite obtener modelos con errores reducidos. Algunos de ellos son: cantidad de árboles, profundidad de los árboles, tasa de aprendizaje, etc.

## **Support Vector Machine (SVM)**

Se basa en buscar la curva o hiperplano que modele la tendencia de los datos de entrenamiento y según ella predecir cualquier dato en el futuro (Gareth, Witten, Hastie and Tibshirani, 2017). En problemas de regresión, al ser la salida un número real, se vuelve muy difícil predecir la información disponible, que tiene infinitas posibilidades, sin embargo, la idea principal es siempre la misma: minimizar el error, individualizar el hiperplano que maximiza el margen, teniendo en cuenta que se tolera parte del error.

Lo primero que debe realizarse es obtener el hiperplano que mejor represente el comportamiento de los datos. Luego, deben construirse unas bandas paralelas al hiperplano que cubran la mayor cantidad de datos (a estas bandas se le conoce como vectores de apoyo o de soporte). Ahora bien, estas bandas no necesariamente cubren todos los datos, quedarán puntos por fuera de la misma (serían los errores) y deben considerarse en la fórmula del algoritmo. Lo que se calcula es la distancia entre las bandas y el punto y se le denomina epsilon.

Al igual que en los otros algoritmos, hay hiperparámetros con los cuales ir testeando. Por ejemplo,  $C$  es una constante y debe ser mayor a 0, la cual determina el equilibrio entre la regularidad de la función y la cuantía hasta la cual se toleran desviaciones mayores que las bandas de soporte. Si el valor de la constante  $C$  es muy grande, en el caso límite  $C$  tiende a infinito, estaría considerándose que el conjunto está perfectamente representado por el hiperplano predictor, epsilon tendiendo a 0. Por el contrario, un número demasiado pequeño para  $C$  permitirá valores de epsilon elevados, es decir, estaría admitiéndose un número muy elevado de ejemplos mal representados.

## **Random Forest (RF)**

Es un conjunto (ensamble) de árboles de decisión combinados con *bagging* (Gareth, Witten, Hastie and Tibshirani, 2017). Al usar *bagging*, lo que en realidad está pasando, es que distintos árboles ven distintas porciones de los datos. Ningún árbol ve todos los datos de entrenamiento. Esto hace que cada árbol se entrene con distintas muestras de datos para un mismo problema. De esta forma, al combinar sus resultados, unos errores se compensan con otros y se logra una predicción que generaliza mejor. Cada uno de esos árboles, a diferencia de XGB en donde están correlacionados, aquí están decorrelacionados.

Para problemas de regresión, la forma más habitual de combinar los resultados de los árboles de decisión, es tomando su media aritmética.

Navegar por diferentes combinaciones de los hiperparámetros puede llevar a encontrar modelos con menor error. A continuación, se enumeran:

- ***n\_estimators***: número de árboles que tendrá el bosque aleatorio. Normalmente cuantos más mejor, pero a partir de cierto punto deja de mejorar y sólo hace que vaya más lento.
- ***n\_jobs***: número de cores que se pueden usar para entrenar los árboles. Cada árbol es independiente del resto, así que entrenar un bosque aleatorio es una tarea muy paralelizable.
- ***max\_features***: una forma de garantizar que los árboles sean diferentes, es que todos se entrenen con una muestra aleatoria de los datos. Además, puede hacerse que distintos árboles usen distintos atributos. Esto puede ser útil especialmente cuando algunos atributos están relacionados entre sí.
- ***max\_depth***: la profundidad máxima del árbol.

- ***min\_samples\_split***: número mínimo de muestras necesarias antes de dividir un nodo.
- ***min\_samples\_leaf***: número mínimo de muestras que debe haber en un nodo final (hoja).
- ***max\_leaf\_nodes***: número máximo de nodos finales

### **Prophet**

El procedimiento *Prophet* incluye muchas posibilidades para que los usuarios modifiquen y ajusten los pronósticos. La interpretación de parámetros por parte del humano se puede utilizar para mejorar el pronóstico al agregar conocimiento del dominio.

Es un modelo de regresión modular con parámetros interpretables que se pueden ajustar intuitivamente (Taylor and Letham, 2018). Se deben seguir los siguientes pasos:

- Modelar la serie temporal utilizando una especificación flexible que tenga una interpretación humana sencilla para cada uno de los parámetros.
- Generar pronósticos para este modelo y un conjunto de líneas base razonables a través de una variedad de fechas históricas.
- Evaluar el rendimiento de las previsiones.

Las series de tiempo con patrones complejos de estacionalidad, tendencia y vacaciones brindan una ilustración útil de las dificultades para producir pronósticos razonables con métodos completamente automatizados.

Dado que ajustar otros métodos econométricos como ARIMA (*Autoregressive integrated moving average*, por sus siglas en inglés) requiere una comprensión profunda de cómo funcionan los modelos de series temporales subyacentes (Hyndman and Athanasopoulos, 2018), el modelo *Prophet* brinda la oportunidad de ajustarlos de una manera más fácil e interpretable. La razón principal se debe a que este último realiza todos los procesos subyacentes de corrección de tendencias, consideración de estacionalidad, inclusión de efectos de vacaciones, entre otros, sin necesidad de aplicar las técnicas como requerimiento previo al entrenamiento de los modelos. Por el contrario, sólo activando y parametrizando ciertos hiperparámetros del modelo definidos para cada fin, se logra tenerlos considerados en la fase de entrenamiento. Es decir, está construido de forma tal que facilita aplicar variantes y testear diversas configuraciones en forma relativamente sencilla.

Es un modelo de regresión aditiva y su representación permite descomponerlo en tres partes principales: tendencia, estacionalidad y vacaciones. Para ello, se definen las siguientes funciones:

- $g(t)$  es la función de tendencia que modela cambios no periódicos en el valor de la serie de tiempo.
- $s(t)$  representa cambios periódicos (por ejemplo, estacionalidad diaria, semanal y anual).
- $h(t)$  representa los efectos de las vacaciones potencialmente irregulares durante uno o más días.

- $e(t)$  representa cualquier cambio idiosincrásico que no se adapte al modelo (término de error). Estas funciones en conjunto derivan en una ecuación del modelo como la siguiente:

$$y(t) = g(t) + s(t) + h(t) + e(t) \quad \dots (5)$$

## Hiperparámetros

### **Growth**

La función de crecimiento modela la tendencia general de los datos, y lo puede hacer de tres formas diferentes:

- *Logistic growth*: tendencia, con crecimiento de saturación no lineal (logístico). Hay un crecimiento no lineal de predicciones que se satura en una capacidad de carga.
- *Linear growth*: Utiliza un conjunto de ecuaciones lineales por partes con diferentes pendientes entre los puntos de cambio.
- *Flat growth*: cuando no hay crecimiento en el tiempo (pero aún puede haber estacionalidad). Si se establece en plano, la función de crecimiento será un valor constante.

El efecto de este hiperparámetro está considerado dentro de la función  $g(t)$  correspondiente al componente de tendencia de la ecuación del modelo.

### **Change Point Prior Scale**

Determina la flexibilidad de la tendencia y, en particular, cuánto cambia la tendencia en los puntos de cambio de tendencia. Si es demasiado pequeño, la tendencia no se ajustará correctamente y la varianza que debería haberse modelado con cambios de tendencia terminará siendo tratada con el término de ruido ( $e(t)$  en la definición del modelo). Si es demasiado grande, la tendencia se sobre ajustará y, en el caso más extremo, puede terminar con la tendencia capturando la estacionalidad anual. El valor predeterminado de 0.05 funciona para muchas series temporales, pero se puede ajustar; un rango de [0.001, 0.5] probablemente sería correcto según la documentación del modelo. Parámetros como este (penalizaciones de regularización; esto es efectivamente una penalización de lazo) a menudo se ajustan en una escala logarítmica.

Al igual que en el caso del hiperparámetro *Growth*, su efecto actúa a través de la función  $g(t)$ .

### **Seasonality**

La función de estacionalidad es una serie de Fourier en función del tiempo. Esta le permite en el caso de Facebook *Prophet* acercarse a la estacionalidad (patrón cíclico) de los datos. Puede ser introducida en forma diaria, semanal, mensual o anual.

Su efecto está incorporado dentro del componente de estacionalidad de la ecuación del modelo, representado por  $s(t)$ .

### ***Seasonality Prior Scale***

Este parámetro controla la flexibilidad de la estacionalidad. De manera similar al hiperparámetro *change point prior scale*, un valor grande permite que la estacionalidad se ajuste a grandes fluctuaciones, un valor pequeño reduce la magnitud de la estacionalidad. El valor predeterminado es 10, y básicamente, no aplica regularización. Esto se debe a que rara vez vemos un sobreajuste aquí (hay una regularización inherente con el hecho de que se está modelando con una serie de Fourier truncada. Un rango razonable para ajustarlo probablemente sería [0.01, 10]; cuando se establece en 0.01, la magnitud de la estacionalidad se ve obligada a ser muy pequeña.

Tal como en el caso del hiperparámetro de estacionalidad, su efecto está incorporado dentro del componente de estacionalidad de la ecuación del modelo, representado por  $s(t)$ .

### ***Holidays***

La función de vacaciones le permite a Facebook *Prophet* ajustar el pronóstico cuando un día festivo o un evento importante puede cambiar el pronóstico. Toma una lista de fechas (hay fechas integradas de días festivos en EE. UU, México o cualquier país) y cuando cada fecha está presente en el pronóstico, agrega o resta valor del pronóstico de los términos de crecimiento y estacionalidad según los datos históricos.

Entra al modelo actuando a través de la función  $h(t)$  definida previamente.

### ***Holidays Prior Scale***

Este hiperparámetro controla la flexibilidad para adaptarse a los efectos de vacaciones. Al igual que *Seasonality Prior Scale*, su valor predeterminado es 10.0, que básicamente no aplica regularización, ya que generalmente se tienen múltiples observaciones de días festivos y se puede hacer un buen trabajo al estimar sus efectos. Este también podría ajustarse en un rango de [0.01, 10].

Tal como en el caso del hiperparámetro *Holidays*, su efecto se ve plasmado en el componente definido por  $h(t)$  que pertenece a la definición del modelo.

### ***Regressor Mode***

Modelar un regresor como un componente aditivo es el mismo enfoque adoptado por el suavizado exponencial. Con el método multiplicativo, el efecto del regresor es un factor que multiplica el regresor, lo que se logra a través de una transformación logarítmica.

## Estructuración de los datos

Más allá de algunas consideraciones respecto a la nomenclatura y orden de las variables previo al entrenamiento de los modelos, no se requiere una limpieza adicional de los datos, ya que *Prophet* lidia muy bien con valores faltantes y *outliers* o valores atípicos. La única transformación implementada en este caso fue la de la corrección de la variable dependiente del modelo (unidades vendidas) en base a los quiebres de stock registrados por categoría y subcategoría de producto. En la sección de implementación se detallarán los datos utilizados para el problema específico.

Sin embargo, para el resto de los modelos utilizados como *benchmark*, se aplicó una ingeniería de atributos básica comprendida por imputación de *outliers* y valores faltantes por el valor promedio de la categoría y subcategoría de producto. No se hizo foco en la creación de variables ya que la idea es encontrar cuál de todos los modelos *benchmark* genera el error de pronóstico más bajo a igualdad de preprocesamiento de los datos y variables utilizadas (rezagos de unidades vendidas y precio). Para los casos específicos de KNN y SVM, se hizo necesario escalar las variables antes de entrenarlos ya que ambos dependen de mediciones de distancia en su funcionamiento. En el caso de no hacerlo, si las características tienen escalas diferentes, aquellas con valores más grandes dominarán el cálculo de las distancias, sesgando así el modelo. Para escalarlas, se utilizó la estandarización, método que busca transformar las variables para que tengan media 0 y desviación estándar 1. Finalmente, antes de medir el error de estos modelos que escalan variables, las mismas se re-escalan para tener todo en la misma unidad de medida.

En particular para *Prophet*, la parametrización de los diferentes hiperparámetros ya mencionados permite modelar correctamente las series de tiempo, sin caer en sesgos de definición y/o transformación. De esa forma, se garantiza que previo al modelado las series ya estén desestacionalizadas, sin tendencia, con efectos de vacaciones incorporados en el modelo, entre otros. Las variables regresoras o explicativas del modelo, podrán entrar en forma aditiva o multiplicativa, según lo definido en el hiperparámetro para tal fin.

Una consideración no menor con respecto al volumen y suficiencia de los datos es que se requiere un año de información diaria (por lo menos) durante la fase de entrenamiento, para poder captar todos los efectos de tendencia y comportamiento presentes en los meses de un año. Pero, dada la definición del modelo de *forecasting* en este caso, se requiere disponer además del año inmediato anterior (aquí reemplazado por el 2019, dados los problemas de la pandemia en el 2020) para construir las variables explicativas ya mencionadas.

## Interpretación de resultados

Para considerar el mejor modelo dentro de cada técnica implementada dadas diferentes combinaciones de los hiperparámetros nombrados anteriormente se utiliza comúnmente el RMSE, cuya definición es la siguiente:

El **RMSE (raíz del error cuadrático medio)** sirve para agregar las magnitudes de los errores en las predicciones varias veces en una sola medida de poder predictivo. Es una medida de precisión para comparar errores de un conjunto de datos en particular y no entre conjuntos de datos, ya que depende de la escala. Su fórmula de cálculo es la siguiente:

$$RMSE = \sqrt{\frac{\sum_{n=1}^N (\hat{y}_n - y_n)^2}{N}} \quad \dots (6)$$

Siendo  $\hat{y}_n$  el valor predicho para la observación  $n$  y  $y_n$  su valor real.  $N$  es el tamaño de la muestra sobre la cual se calculan los errores de predicción.

El efecto de cada error en el RMSE es proporcional al tamaño del error cuadrado; por lo tanto, los errores mayores tienen un efecto mucho más grande sobre la métrica de error, haciéndola sensible a valores atípicos.

Una vez seleccionada la mejor configuración de hiperparámetros de un modelo en base al criterio del RMSE, puede compararse la performance entre distintos modelos o metodologías de pronóstico utilizando la siguiente medida de error:

El **MAPE (error porcentual absoluto medio)** mide el tamaño del error (absoluto) en términos porcentuales. El hecho que se estime una magnitud del error porcentual lo hace un indicador frecuentemente utilizado en pronósticos de demanda por su fácil interpretación. Incluso es útil cuando no se conoce el volumen de demanda del producto dado que es una medida relativa (independiente de la escala). Evita que los errores positivos y negativos se cancelen entre sí y utiliza errores relativos para permitirle comparar la precisión de predicción entre distintos modelos de pronóstico. Su fórmula de cálculo es la siguiente:

$$MAPE = \frac{1}{N} \sum_{n=1}^N \left| \frac{y_n - \hat{y}_n}{y_n} \right| \quad \dots (7)$$

Entonces, luego de probar la métrica de error para cada una de las combinaciones de hiperparámetros disponibles<sup>6</sup> (es decir, un modelo para cada combinación diferente), se selecciona el modelo asociado con el RMSE más bajo. Detrás de ese proceso, se está experimentando un ajuste implícito de hiperparámetros (el mejor conjunto para ellos resulta de iterar muchas combinaciones). Una vez que se cuenta con el mejor modelo para cada técnica, puede compararse performance entre técnicas utilizando el MAPE. Dicho esto, en la sección de Validación del modelo, sólo se presentan los MAPE comparados entre técnicas, pero no los RMSE que resultaron de probar las distintas combinaciones de hiperparámetros dentro de cada técnica (ya que serían 100 RMSE dentro de cada una de ellas, lo cual no es informativo).

### **Implementación**

El entrenamiento de los modelos fue realizado por categoría y subcategoría de producto. La desagregación en esta etapa no se hizo por género y tienda<sup>7</sup> ya que de esa forma las

---

<sup>6</sup> Se construyó una grilla de hiperparámetros mediante *gridsearch* (100 combinaciones distintas), otorgando valores aleatorios a los diferentes hiperparámetros, para que el modelo itere en cada combinación de categoría-subcategoría de productos y seleccione el del mínimo RMSE asociado.

<sup>7</sup> Para la validación y puesta en producción del modelo de pronóstico, una vez obtenido el *forecast* a nivel categoría y subcategoría de producto, se distribuyó por género y tienda en base a porcentajes promedio históricos de los últimos 6 meses. Esta fue la forma de entrenar modelos precisos y en el nivel de desagregación necesario. Luego, para hacer efectiva la distribución, se lleva el resultado a nivel sku de la misma manera que a nivel género-tienda.

observaciones eran escasas o bien con volúmenes de venta diarios muy reducidos, lo que dificulta el aprendizaje de los modelos (y por ende su precisión).

En concreto, las razones cuantitativas de esa mejora en modelar agregado para luego transformarlo a su nivel más granular (*top-down* + promedios históricos de participación por tienda-género), son:

- **Volumen insuficiente y ceros:** 42 % de las series a nivel categoría-subcategoría-género-tienda presentan menos de 2 ventas diarias y más de 30 % de ceros consecutivos. *Prophet* (y cualquier modelo supervisado) sobreajusta esos picos y genera alta varianza. Agrupar por categoría-subcategoría eleva el conteo medio diario de 0.8 a 37 unidades, evitando ruido discreto.
- **Parámetros robustos:** al tener 18 modelos (3 categorías x 6 subcategorías) en lugar de 1188 (3 categorías x 6 subcategorías x 3 géneros x 22 tiendas), el *grid-search* explora 100 combinaciones de hiperparámetros con el mismo tiempo de cómputo, encontrando ajustes más finos (especialmente en *changepoints* y estacionalidad).
- **Mayor estabilidad *out-of-sample*:** cuando se comparan los pronósticos realizados con un modelo granular hasta nivel tienda versus uno a nivel categoría-subcategoría distribuyendo por tienda-género usando las participaciones promedio de los últimos 6 meses (enfoque *top-down* + participaciones promedio), el MAPE resultante por categoría se mueve como en la **Tabla 3** a continuación,

**Tabla 3: Comparativa de MAPE entre modelos a nivel categoría + participaciones y a nivel tienda (marzo 2022)**

Nombre Categoría	MAPE (top-down + participaciones)	MAPE (tienda)	Variación MAPE
Calzado	9.55	28.6	199%
Textil	14.23	34.8	145%
Accesorio	13.42	31.2	132%

Lo que denota un claro aumento de la métrica de error del modelo al analizarla en su nivel más granular, o alternativamente, el error del modelo mejora/disminuye cuando se trabaja con resultados más agregados y luego se los desagrega en base a promedios históricos.

En este contexto la ganancia de precisión al entrenar con series más densas supera con creces la posible pérdida de granularidad. De todas formas, el esquema *top-down* con una distribución en base a promedios históricos de participación por tienda-género mantiene el MAPE en un rango < 15 % en cada nivel operativo, reduce las varianzas y simplifica la idea de tener que mantener 1188 modelos totales (en el otro esquema), justificando plenamente la elección de entrenar los modelos a nivel categoría-subcategoría. Además, la insuficiencia de datos y presencia de gran cantidad de ceros para modelar en su nivel más granular, impide llevarlo a cabo con robustez. Esto último se traduce en:

- Sobreajustes a picos aislados al ajustar *changepoints* a ventas puntuales (luego fallando en la predicción).

- Varianza extrema, implicando un ensanchamiento de las bandas de confianza, señal de inestabilidad paramétrica.

Para el período de entrenamiento se utilizó información de ventas desde enero del 2021 hasta enero del 2022 (inclusive). El set de testeo comprendió el mes de febrero del 2022 (primera quincena), el cual permitió ir validando los distintos modelos durante su entrenamiento. El hecho de tener un mes para testeo está directamente relacionado a la disponibilidad de los datos (se requiere un año completo de información diaria dada la definición del modelo de pronóstico en particular, de forma tal que se entrene con el comportamiento de cada mes presente en un año). Sin embargo, una vez seleccionado el mejor modelo por categoría y subcategoría de producto, se realizó una evaluación de su capacidad predictiva sobre las quincenas de los meses de marzo y abril del 2022 para medir su error en el pronóstico y disipar cualquier posibilidad de que su buena performance estuviera atada únicamente al bajo error de pronóstico en la primera quincena del mes de febrero del 2022. Esto último, garantiza la fortaleza del modelo predictivo para ser utilizado en producción. El detalle puede observarse en la sección de Resultados.

Se siguieron los pasos detallados a continuación:

### **Entrenamiento**

- Agrupando diariamente la información por categoría y subcategoría de producto, se obtuvo el total de ventas en forma diaria para esa categoría y subcategoría (para el total de tiendas y géneros) sumando las unidades por día. De la misma forma, pero promediando los precios diarios, se obtuvo el precio promedio diario por categoría y subcategoría de producto.
- Se realizó una corrección de la variable “unidades”, la cual representa la variable dependiente del modelo, en base a los *insights* obtenidos del análisis del quiebre de stocks producidos durante 3 meses (promedio por categoría-subcategoría de producto). Es decir, una vez recopilados y contados los quiebres de *stock* por categoría y subcategoría de producto se calculó cuánto representaban del total de ventas efectivas para esa categoría y subcategoría específicas. Así, se llegó a un porcentaje de quiebres de *stock* por categoría y subcategoría de producto que permitió reajustar las ventas efectivas al alza. Con ello se eliminó parcialmente el sesgo de ventas efectivas vs ventas reales/potenciales. Esta corrección se aplicó en la categoría que maneja el mayor porcentaje de ventas de la empresa (Calzado), y en particular, en las subcategorías que producen el mayor volumen de ventas dentro de esa categoría (*Casual, Running, Skate y Training*). Los porcentajes de corrección pueden verse en la **Tabla 4**.
- Creación de las variables independientes del modelo como rezagos de las ventas y el precio diario de una categoría y subcategoría de producto en la quincena corriente. Es decir, se incluyeron como variables explicativas a las ventas diarias de la quincena anterior y las ventas diarias de la misma quincena del año anterior (y de igual forma con el precio)<sup>8</sup>. Al ser el año 2020 uno muy atípico dada la pandemia, no

---

<sup>8</sup> De esta forma, se logra captar el efecto de cómo vienen las ventas más recientes (quincena inmediata anterior) pero al mismo tiempo el efecto de la estacionalidad de la quincena en cuestión (misma quincena

fue considerado al momento de la construcción de las variables independientes y se lo reemplazó por información del año 2019.

- Iterando por cada categoría y subcategoría de producto, se corrieron sucesivos modelos *Prophet* con distintas configuraciones de hiperparámetros (valores aleatorios para *growth*, *mode*, *prior scale* y *daily seasonality*; manteniendo fijos la *monthly seasonality* y el efecto de vacaciones de México). Esto es conocido como *grid search* de hiperparámetros y es utilizado al entrenar modelos para encontrar la combinación óptima que maximice el rendimiento del modelo (o minimice el error de pronóstico). Las ventajas de realizarlo están directamente relacionadas a la optimización del rendimiento, evitar el sobreajuste, una evaluación sistemática (evitar la tendencia a seleccionar hiperparámetros arbitrariamente y brindar una evaluación más rigurosa y objetiva) y la generalización y reproducibilidad de los resultados. El hecho de mantener fijos los hiperparámetros de estacionalidad mensual y vacaciones o días festivos de México está atado a siempre querer tenerlos activos en la configuración del modelo dado el problema bajo el cual estamos trabajando (pronóstico de ventas de ropa deportiva en diferentes meses del año).
- Por cada configuración de hiperparámetros para una categoría-subcategoría de producto dada, se almacenó el RMSE asociado. Luego, se seleccionó la configuración correspondiente al mínimo RMSE, se seteó el modelo con esos valores de hiperparámetros y se guardó el modelo entrenado en un objeto *pickle*<sup>9</sup>.
- Se recopiló la información del error porcentual absoluto medio o MAPE (calculado sobre los datos del set de testeo) de cada categoría y subcategoría de producto.<sup>10</sup> Para todas las combinaciones de categoría-subcategoría de producto, el modelo FB *Prophet* es el de mejor performance (excepto para accesorio *basketball*, accesorio *running* y accesorio *soccer* en las cuales el error es bastante grande, aunque eso se explica por volúmenes de venta realmente pequeños). Para los restantes modelos entrenados (KNN, XGB, RF, SVM y Naive Estacional) puede verse un error de pronóstico muy alto en todas las combinaciones de categoría-subcategoría de producto, lo cual está ligado a no haber realizado limpieza previa de los datos que el modelo *Prophet* ya realiza desde su configuración. Básicamente, quiso verse si sólo iterando por distintas configuraciones de hiperparámetros de los modelos todos lograban un poder predictivo similar. Pero los MAPE muestran que eso no es así; la capacidad de *Prophet* para trabajar con series estacionales, con tendencia y efectos de días festivos sin necesidad de incorporar todo eso manualmente, lo hace muy superior en performance al compararlo con las otras metodologías. Las tablas

---

del año anterior). Además, evita incurrir en un error adicional indirecto si se utilizaran otro tipo de variables explicativas que implicaran la necesidad de tener que predecir su comportamiento en el período que se quiere pronosticar. Trabajar con rezagos como variables independientes implica trabajar con valores reales sin incurrir en ese sesgo adicional.

<sup>9</sup> El objeto *pickle* permite almacenar el modelo entrenado en Python para poder ser utilizado en la etapa de producción, sin necesidad de tener que reentrenarlo. Luego, simplemente levantando el objeto *pickle* se lo utiliza para predecir sobre nuevos datos.

<sup>10</sup> Esto mismo se realizó al entrenar los algoritmos KNN, XGB, SVM Y RF y Naive Estacional. De esta forma, se puede tener un comparativo de los MAPE para las diferentes categorías-subcategorías de productos. El código Python que contiene todos los modelos implementados puede encontrarse en el siguiente [link](#).

**Tabla 5 a Tabla 22** muestran los errores promedio calculados sobre el set de testeo para todas las tiendas por categoría-subcategoría de producto permitiendo realizar una comparación entre las distintas metodologías-modelos implementados. Allí puede apreciarse la columna indicativa del modelo en cuestión, la categoría y subcategoría de producto específicas y el MAPE asociado a esa combinación.

### Validación

- Se validó el funcionamiento de los modelos *Prophet* entrenados (previo a su puesta en producción y al desarrollo del modelo de redistribución de mercaderías) pronosticando las ventas correspondientes a las quincenas comprendidas en el mes de marzo del 2022 por categoría y subcategoría (desagregando los pronósticos por género y tienda en base a los % de participación históricos) y comparándolos con los valores reales. Los resultados de los errores se presentan a nivel tienda y categoría para reducir su dimensionalidad en la **Tabla 23-Tabla 28**<sup>11</sup> (aunque sumando los pronósticos ya desagregados en todos los niveles) considerando el error de ambas quincenas comprendidas en el mes. Allí pueden apreciarse las columnas indicativas de la tienda y categoría en cuestión y el MAPE asociado a esa combinación. A modo de resumen, el MAPE promedio de la categoría Calzado para todas las tiendas es de 9.55%, el de la categoría Textil de 14.23% y el de Accesorio de 13.42%.

**Tabla 4: % de corrección de unidades en base a quiebres de stock**

Calzado			
<i>Casual</i>	<i>Running</i>	<i>Skate</i>	<i>Training</i>
7.3%	4.2%	6.1%	2.5%

**Tabla 5: MAPE en Calzado *Casual* para los distintos algoritmos testeados (en %)**

Modelo	Categoría	Subcategoría	MAPE (%)
KNN	Calzado	Casual	56.41
XGB	Calzado	Casual	71.17
SVM	Calzado	Casual	67.67
RF	Calzado	Casual	71.14
FB Prophet	Calzado	Casual	11.17
Naive Estacional	Calzado	Casual	58.56

<sup>11</sup> En el Apéndice A en la **Tabla 49-Tabla 66** pueden observarse los errores del pronóstico para los meses de febrero a abril (agregándolos por quincena) a nivel tienda-género para mostrar su performance en un nivel de desagregación distinto. A modo de resumen, el MAPE promedio en marzo del género MEN para todas las tiendas es de 11.84%, el del género WOMEN de 11.30% y el de CHILDREN de 16.66%. Además, se presentan los MAPE para los meses de febrero y abril a nivel tienda-categoría (agregándolos por quincena), como complemento a los resultados presentados para el mes de marzo en la sección de Validación.

**Tabla 6: MAPE en Calzado *Skate* para los distintos algoritmos testeados (en %)**

Modelo	Categoría	Subcategoría	MAPE (%)
KNN	Calzado	Skate	65.11
XGB	Calzado	Skate	71.53
SVM	Calzado	Skate	68.03
RF	Calzado	Skate	70.69
FB Prophet	Calzado	Skate	6.81
Naive Estacional	Calzado	Skate	66.24

**Tabla 7: MAPE en Calzado *Basketball* para los distintos algoritmos testeados (en %)**

Modelo	Categoría	Subcategoría	MAPE (%)
KNN	Calzado	Basketball	68.69
XGB	Calzado	Basketball	69.41
SVM	Calzado	Basketball	65.91
RF	Calzado	Basketball	68.2
FB Prophet	Calzado	Basketball	18.97
Naive Estacional	Calzado	Basketball	64.11

**Tabla 8: MAPE en Calzado *Running* para los distintos algoritmos testeados (en %)**

Modelo	Categoría	Subcategoría	MAPE (%)
KNN	Calzado	Running	51.67
XGB	Calzado	Running	71.59
SVM	Calzado	Running	68.09
RF	Calzado	Running	70.46
FB Prophet	Calzado	Running	0.06
Naive Estacional	Calzado	Running	53.84

**Tabla 9: MAPE en Calzado *Training* para los distintos algoritmos testeados (en %)**

Modelo	Categoría	Subcategoría	MAPE (%)
KNN	Calzado	Training	53.66
XGB	Calzado	Training	72.31
SVM	Calzado	Training	68.81
RF	Calzado	Training	70.61
FB Prophet	Calzado	Training	12.54
Naive Estacional	Calzado	Training	49.35

**Tabla 10: MAPE en Calzado *Soccer* para los distintos algoritmos testeados (en %)**

Modelo	Categoría	Subcategoría	MAPE (%)
KNN	Calzado	Soccer	55.56
XGB	Calzado	Soccer	71.62
SVM	Calzado	Soccer	68.12
RF	Calzado	Soccer	68.2
FB Prophet	Calzado	Soccer	27.4
Naive Estacional	Calzado	Soccer	51.43

**Tabla 11: MAPE en Textil *Casual* para los distintos algoritmos testeados (en %)**

Modelo	Categoría	Subcategoría	MAPE (%)
KNN	Textil	Casual	55.56
XGB	Textil	Casual	71.64
SVM	Textil	Casual	68.14
RF	Textil	Casual	71.91
FB Prophet	Textil	Casual	0.11
Naive Estacional	Textil	Casual	58.28

**Tabla 12: MAPE en Textil *Skate* para los distintos algoritmos testeados (en %)**

Modelo	Categoría	Subcategoría	MAPE (%)
KNN	Textil	Skate	55.56
XGB	Textil	Skate	70.75
SVM	Textil	Skate	67.25
RF	Textil	Skate	70.52
FB Prophet	Textil	Skate	9.73
Naive Estacional	Textil	Skate	54.92

**Tabla 13: MAPE en Textil *Basketball* para los distintos algoritmos testeados (en %)**

Modelo	Categoría	Subcategoría	MAPE (%)
KNN	Textil	Basketball	45.67
XGB	Textil	Basketball	72.03
SVM	Textil	Basketball	68.53
RF	Textil	Basketball	70.48
FB Prophet	Textil	Basketball	11.11
Naive Estacional	Textil	Basketball	37.23

**Tabla 14: MAPE en Textil *Running* para los distintos algoritmos testeados (en %)**

Modelo	Categoría	Subcategoría	MAPE (%)
KNN	Textil	Running	56.41
XGB	Textil	Running	71.89
SVM	Textil	Running	68.39
RF	Textil	Running	69.99
FB Prophet	Textil	Running	2.22
Naive Estacional	Textil	Running	60.15

**Tabla 15: MAPE en Textil Soccer para los distintos algoritmos testeados (en %)**

Modelo	Categoría	Subcategoría	MAPE (%)
KNN	Textil	Soccer	68.69
XGB	Textil	Soccer	69.41
SVM	Textil	Soccer	65.91
RF	Textil	Soccer	71.36
FB Prophet	Textil	Soccer	6.33
Naive Estacional	Textil	Soccer	64.59

**Tabla 16: MAPE en Textil Training para los distintos algoritmos testeados (en %)**

Modelo	Categoría	Subcategoría	MAPE (%)
KNN	Textil	Training	55.56
XGB	Textil	Training	70.39
SVM	Textil	Training	66.89
RF	Textil	Training	71.13
FB Prophet	Textil	Training	10.8
Naive Estacional	Textil	Training	55.11

**Tabla 17: MAPE en Accesorio Casual para los distintos algoritmos testeados (en %)**

Modelo	Categoría	Subcategoría	MAPE (%)
KNN	Accesorio	Casual	20.51
XGB	Accesorio	Casual	70.67
SVM	Accesorio	Casual	67.17
RF	Accesorio	Casual	71.66
FB Prophet	Accesorio	Casual	7.11
Naive Estacional	Accesorio	Casual	24.16

**Tabla 18: MAPE en Accesorio Skate para los distintos algoritmos testeados (en %)**

Modelo	Categoría	Subcategoría	MAPE (%)
KNN	Accesorio	Skate	20.51
XGB	Accesorio	Skate	68.62
SVM	Accesorio	Skate	65.12
RF	Accesorio	Skate	70.69
FB Prophet	Accesorio	Skate	0.15
Naive Estacional	Accesorio	Skate	22.93

**Tabla 19: MAPE en Accesorio Basketball para los distintos algoritmos testeados (en %)**

Modelo	Categoría	Subcategoría	MAPE (%)
KNN	Accesorio	Basketball	56.41
XGB	Accesorio	Basketball	70.11
SVM	Accesorio	Basketball	66.61
RF	Accesorio	Basketball	70.52
FB Prophet	Accesorio	Basketball	66.67
Naive Estacional	Accesorio	Basketball	63.19

**Tabla 20: MAPE en Accesorio *Running* para los distintos algoritmos testeados (en %)**

Modelo	Categoría	Subcategoría	MAPE (%)
KNN	Accesorio	Running	56.3
XGB	Accesorio	Running	70.31
SVM	Accesorio	Running	66.81
RF	Accesorio	Running	70.37
FB Prophet	Accesorio	Running	69.66
Naive Estacional	Accesorio	Running	70.47

**Tabla 21: MAPE en Accesorio *Soccer* para los distintos algoritmos testeados (en %)**

Modelo	Categoría	Subcategoría	MAPE (%)
KNN	Accesorio	Soccer	20.51
XGB	Accesorio	Soccer	68.12
SVM	Accesorio	Soccer	65.12
RF	Accesorio	Soccer	69.5
FB Prophet	Accesorio	Soccer	70.94
Naive Estacional	Accesorio	Soccer	62.84

**Tabla 22: MAPE en Accesorio *Training* para los distintos algoritmos testeados (en %)**

Modelo	Categoría	Subcategoría	MAPE (%)
KNN	Accesorio	Training	68.44
XGB	Accesorio	Training	71.35
SVM	Accesorio	Training	67.85
RF	Accesorio	Training	70.69
FB Prophet	Accesorio	Training	10.4
Naive Estacional	Accesorio	Training	55.76

A modo de regla de decisión para establecer si un modelo tiene una buena performance o no y considerando los valores utilizados en la literatura (Frechtling, 1996), se tiene que:

- MAPE < 10% Performance excelente
- MAPE < 20% Performance muy buena
- 20% < MAPE < 30% Performance aceptable
- MAPE > 30% Revisar modelo

En general, todos los MAPE del modelo FB Prophet presentan una performance entre excelente y muy buena. Particularmente, Calzado Soccer tiene una performance aceptable (también explicado por reducidos volúmenes de venta); al igual que Accesorio *Basketball*, *Running* y *Soccer*, cuyos errores son muy altos, pero con volúmenes de venta realmente pequeños. Los otros modelos trabajados presentan errores marcadamente altos, lo cual tal como ya fue mencionado, está ligado a su incapacidad para considerar en forma autónoma los efectos de la estacionalidad, tendencia y días festivos sobre las series temporales, repercutiendo en su performance predictiva. El principal problema viene de las series con tendencia (no estacionarias) que lleva a obtener estimadores que no son los mejores

estimadores lineales insesgados (esto, *Prophet* lo resuelve previo a ser entrenado en forma autónoma).

Además, los algoritmos genéricos (RF, XGB, SVM) fueron alimentados con el mismo set de variables brutas que *Prophet* sin un *feature-engineering* intensivo de estacionalidades. En una muestra de sólo 400 filas (año 2021 y enero de 2022), su capacidad de generalizar patrones estacionales complejos es limitada. Por el contrario, *Prophet* introduce esos términos de forma paramétrica --series de Fourier + efectos de feriados-- y, además, penaliza los cambios de tendencia; por eso obtiene reducciones de MAPE de entre 60 % y 90 % frente al naive estacional.

Para profundizar más sobre la marcada diferencia entre los MAPE del modelo *Prophet* versus el de las metodologías utilizadas como *benchmark*, se presentan los siguientes puntos comparativos:

- *Prophet* trae la estacionalidad y los feriados en forma explícita (con *holidays+prior\_scale*) permitiéndole aprender el efecto y forma automáticamente, mientras que los árboles y SVM los hubieran necesitado como variables adicionales (requiere crear *dummies* e interacciones y ajustar los umbrales para que los modelos no las ignoren).
- En RF/XGB/SVM sólo se incluyen como variables explicativas los campos de fecha y rezagos de unidades vendidas y precio; las estacionalidades se “esconden” en la columna de fecha, pero los modelos la tratan como numérica. Sin *dummies* de mes ni interacción con feriados, los modelos ven al día como un número y no pueden inferir que es un día determinado de la semana ni una fecha especial.
- 392-396 observaciones por serie (enero-2021 a enero-2022) para un algoritmo de árboles, implica menos de 400 filas para 5 variables; lo cual es muy poco para aprender patrones no lineales, de forma tal que acaban sobreajustando puntos singulares.
- Hiperparámetros deliberadamente conservadores. *Grid search* limitado (por tiempo de cómputo) lo cual hace que los árboles no encuentren la mejor profundidad y XGB se quede en un *underfitting/overfitting* ligero. *Prophet*, en cambio, converge en segundos y explora 100 combinaciones de *seasonality\_prior\_scale* y *changepoint\_prior\_scale*.
- Naive estacional usa ventas del mismo día del año anterior. Al menos inyecta la componente anual y por eso en determinadas categorías-subcategorías es mejor que RF/XGB/SVM en términos de MAPE. Esto se relaciona directamente con que la venta de ropa deportiva, y ropa en general, es muy estacional; con lo cual, es crucial un componente en el modelo que capte esa estacionalidad.
- *Prophet* reduce MAPE 60-90 % versus naive estacional porque agrega tendencia, rezagos del precio y feriados como variables explicativas; además de ser un modelo mucho más robusto.

- Con respecto al manejo de datos faltantes y valores atípicos, *Prophet* es robusto por diseño, no exige una imputación ni suavizado. Y si bien los árboles aceptan valores faltantes, tienden a sobreajustar si no se los imputa debidamente. En particular, SVM sí exige una imputación de estos, pero los valores atípicos tienden a distorsionar.
- En cuanto al manejo de cambios de tendencia *Prophet* utiliza un componente logístico/lineal junto a una penalización L1 (*changepoint\_prior\_scale*). Los árboles intentan segmentar, pero con pocos datos generan overfitting. SVM y XGB dependen de *kernels* y *learning-rate*, tal que con el *gridsearch* limitado por tiempos de cómputo, hace que afecte su performance.

Las tablas a continuación permiten validar la performance durante las quincenas del mes de marzo de 2022 del modelo *Prophet* seleccionado para realizar el pronóstico, presentando los resultados a nivel categoría-tienda tal como se mencionó anteriormente:

**Tabla 23: MAPE del modelo *Prophet* para Tiendas 1 a 12 en la categoría Calzado para el mes de marzo 2022 (en %)**

Tienda	Categoría	MAPE
T001	Calzado	5.30
T002	Calzado	9.58
T003	Calzado	9.27
T004	Calzado	12.02
T006	Calzado	13.67
T007	Calzado	8.35
T008	Calzado	7.10
T009	Calzado	8.32
T010	Calzado	0.00
T011	Calzado	10.08
T012	Calzado	5.29

**Tabla 24: MAPE del modelo *Prophet* para Tiendas 13 a 23 en la categoría Calzado para el mes de marzo 2022 (en %)**

Tienda	Categoría	MAPE
T013	Calzado	6.23
T014	Calzado	21.13
T015	Calzado	15.52
T016	Calzado	7.84
T017	Calzado	9.22
T018	Calzado	5.03
T019	Calzado	9.20
T020	Calzado	7.58
T021	Calzado	11.40
T022	Calzado	11.51
T023	Calzado	16.41

**Tabla 25: MAPE del modelo *Prophet* para Tiendas 1 a 12 en la categoría Textil para el mes de marzo 2022 (en %)**

Tienda	Categoría	MAPE
T001	Textil	6.30
T002	Textil	2.52
T003	Textil	18.81
T004	Textil	24.32
T006	Textil	8.70
T007	Textil	23.37
T008	Textil	5.15
T009	Textil	16.47
T010	Textil	0.00
T011	Textil	21.54
T012	Textil	17.52

**Tabla 26: MAPE del modelo *Prophet* para Tiendas 13 a 23 en la categoría Textil para el mes de marzo 2022 (en %)**

Tienda	Categoría	MAPE
T013	Textil	17.54
T014	Textil	16.87
T015	Textil	1.78
T016	Textil	19.68
T017	Textil	4.31
T018	Textil	8.47
T019	Textil	18.75
T020	Textil	18.75
T021	Textil	19.51
T022	Textil	30.91
T023	Textil	11.71

**Tabla 27: MAPE del modelo *Prophet* para Tiendas 1 a 12 en la categoría Accesorio para el mes de marzo 2022 (en %)**

Tienda	Categoría	MAPE
T001	Accesorio	6.99
T002	Accesorio	3.82
T003	Accesorio	21.31
T004	Accesorio	6.59
T006	Accesorio	9.52
T007	Accesorio	0.93
T008	Accesorio	38.36
T009	Accesorio	21.74
T010	Accesorio	0.00
T011	Accesorio	17.07
T012	Accesorio	9.57

**Tabla 28: MAPE del modelo *Prophet* para Tiendas 13 a 23 en la categoría Accesorio para el mes de marzo 2022 (en %)**

Tienda	Categoría	MAPE
T013	Accesorio	3.45
T014	Accesorio	4.35
T015	Accesorio	5.11
T016	Accesorio	6.62
T017	Accesorio	22.22
T018	Accesorio	30.00
T019	Accesorio	20.00
T020	Accesorio	16.13
T021	Accesorio	11.57
T022	Accesorio	27.78
T023	Accesorio	12.05

### 3.2. Modelo de Redistribución

Una vez realizados los pronósticos de corto plazo (para la próxima quincena), los mismos son utilizados como input para un modelo de redistribución de mercadería entre las tiendas. Con el objetivo de reducir los quiebres de *stock* en las diferentes tiendas, se busca cubrir posibles faltantes teniendo en cuenta el pronóstico de ventas por categoría, subcategoría, género y tienda; en comparación con el nivel de inventario disponible por tienda para esa categoría, subcategoría y género específicos.

#### Planteo matemático del problema

Es un problema de logística y redistribución óptima. Partiendo de un pronóstico de demanda por categoría de producto para un total de 22 tiendas, cuando se compara el *stock* para cada categoría en cada tienda, se encuentra que en algunas no existe suficiente *stock* para cubrir la demanda pronosticada, mientras que en otras tiendas sobra *stock* dado el pronóstico de demanda por categoría de producto. Este pronóstico de demanda, previo a la sugerencia de redistribución de mercaderías que resuelva el modelo de optimización, puede efectuarse con una frecuencia semanal, quincenal o mensual. Dicho lo anterior, implicará la necesidad de optimizar el modelo cada vez que eso suceda. En otras palabras, por cada pronóstico de demanda efectuado para un período de tiempo determinado, surgirá una solución de redistribución óptima de mercaderías distinta.

Se encuentra enmarcado bajo un modelo del transporte (Williams, 2013), donde existen oferentes (tiendas con sobrantes de *stock* dado el pronóstico de demanda) y demandantes (tiendas con faltantes de *stock* dado el pronóstico de demanda).

El modelo es separable por producto, y su objetivo final es distribuir unidades para cada categoría de productos existente entre los distintos pares de tiendas.

Por un lado, ser separable por producto implica que el modelo de optimización deberá ejecutarse para cada categoría de productos existente por separado, reduciendo así la dificultad computacional del mismo. Al mismo tiempo, esto implica que una tienda pueda comportarse como oferente en la ejecución del modelo para una categoría de producto específica, pero como demandante en su ejecución para otra categoría.

Por otro lado, al referirse a una distribución entre los distintos pares de tiendas implica que el modelo de distribución opere bajo un esquema punto a punto entre pares específicos de tiendas, lo que significa que, en cada asignación, la transferencia de productos no incluye paradas intermedias. Es decir, si un producto se envía desde una tienda de origen hacia una tienda de destino, no se hace entrega en ninguna tienda que pueda estar en el trayecto. A modo de ejemplo, si existen tres tiendas A, B y C, y el modelo determina que cierta cantidad de unidades de la categoría  $x$  deben trasladarse desde la tienda A hacia la tienda C, el envío se realiza directamente entre estas tiendas. Aunque la tienda B se encuentre en el trayecto, no se considera en esta asignación. Si, en cambio, la tienda B también requiere productos de la tienda A, el modelo generará una asignación separada y un nuevo envío exclusivamente para cubrir esa demanda.

Existe la posibilidad de definir de antemano tiendas prioritarias a cubrir, lo cual implica que cada uno de los modelos de optimización ejecutados para cada categoría de producto tratará, en primera instancia, de buscar la cobertura parcial o total de esas tiendas si tuviesen faltantes en la categoría de producto en cuestión (dada la demanda pronosticada y el *stock* disponible), y luego se centrará en las restantes tiendas. La razón detrás de esto es que la empresa cuenta con tiendas que son estratégicas en cuanto a ubicación y volumen de ventas, con lo cual el volumen de quiebres allí podría ser mayor, o incluso repercutir sobre la imagen de la empresa al quedar expuestos más frecuentemente a faltantes ante solicitudes de los clientes. Es por eso que la empresa podría querer priorizarlas, con lo cual, se necesita otorgarle esa información al modelo incrementando el costo de un quiebre en esas tiendas. De todas formas, podría ocurrir que para una categoría específica no existan tiendas capaces de cubrir total ni parcialmente el faltante en una tienda definida como prioritaria (es decir, que no existan tiendas con sobrantes para esa categoría), y en ese caso, no existiría tal asignación a pesar de haber definido a la tienda como prioritaria.

Para el desarrollo de este modelo, se toman las siguientes simplificaciones:

- No necesariamente se debe abastecer la demanda de todas las tiendas en su totalidad.
- La empresa dispone de una compañía de logística con camiones que pueden iniciar el reparto desde cualquier tienda y en cualquier momento del tiempo.
- Cada camión es capaz de transportar una cantidad ilimitada de productos, y de cualquier categoría.
- Se asume que es posible viajar entre dos tiendas cualesquiera  $t$  y  $t'$ .

En conclusión, se plantea un modelo de programación lineal entera cuya función objetivo se centra en minimizar los costos de quiebre de *stock*, obteniendo así las cantidades  $x_{tt'} \in N$  que indican cuantas unidades de productos para cada categoría existente son enviadas desde la tienda  $t$  a la tienda  $t'$ .

#### Datos

$T = \{1, 2, \dots, n\}$  es el conjunto de  $n$  tiendas, donde  $T_i$  es la  $i$ -ésima tienda.

$D[u] \in \mathbb{N}$ , donde  $D_t$  es la demanda pronosticada para una categoría de producto específica en la tienda  $t \in T$  y  $u$  indica que la demanda se expresa en unidades.

$S[u] \in \mathbb{N}$ , donde  $S_t$  es el stock disponible para una categoría de producto específica en la tienda  $t \in T$  y  $u$  indica que el stock se expresa en unidades.

$\theta_t[u] = \begin{cases} D_t - S_t & \text{si } D_t > S_t \\ 0 & \text{en otro caso} \end{cases}$  donde  $\theta_t$  es la cantidad de productos faltantes para una categoría específica en la tienda  $t \in T$  y  $u$  indica que la cantidad de productos faltantes se expresa en unidades.

$\omega_t [$/u] \in \mathbb{R}^+$  es el costo incurrido por cada unidad faltante para una categoría de producto específica en la tienda  $t$ . Es decir, es el dinero perdido por no vender una unidad de esa categoría en  $t$ . Este parámetro es el que permite ajustar la prioridad establecida entre tiendas, de forma tal que para aquellas tiendas más prioritarias el costo será más alto y, por el contrario, para aquellas menos prioritarias será más bajo.

$\alpha \in [0,1]$  es un ponderador para los términos de costo de quiebre y costo de distancia recorrida de la función objetivo. De forma tal que, a valores de  $\alpha$  más cercanos a 1, se estará ponderando más al término de costo de quiebre de stock; y por el contrario, a valores de  $\alpha$  más cercanos a 0, se estará ponderando más al término de costo de distancia recorrida. Esto es equivalente a determinar la importancia relativa del quiebre de unidades sobre el recorrido en distancia para suplir esos quiebres.

$d_{tt'} [$/u] \in \mathbb{R}^+$  es el costo incurrido por unidad de producto por recorrer la distancia entre las tiendas  $t$  y  $t'$ . Resulta del cálculo de la distancia en km entre cada par de tiendas y luego ponderarlo por un costo fijo en \$/km recorrido. Ese cálculo de la distancia entre tiendas se establece a continuación:

$D_{ij}$  = distancia entre la tienda  $i$  y la tienda  $j$  (dato, viene dado).

Siendo la distancia entre dos tiendas calculada de la siguiente manera<sup>12</sup>:

$$D_{ij} = R * c_{ij};$$

$R = 6373$ , es el radio aproximado de la Tierra en km;

$$c_{ij} = 2 * \arctan\left(\frac{\sqrt{a}}{\sqrt{1-a}}\right);$$

$$a = \text{sen}\left(\frac{dlat}{2}\right)^2 + \cos(lat_i) * \cos(lat_j) * \text{sen}\left(\frac{dlon}{2}\right)^2;$$

$$dlat = lat_j - lat_i;$$

$$dlon = lon_j - lon_i;$$

Expresando a  $lat_i, lat_j, lon_i$  y  $lon_j$  en radianes.

Lo anterior describe el cálculo de la distancia entre dos puntos en la superficie de la Tierra, conocida como la distancia de círculo máximo o distancia geodésica, utilizando para ello la

---

<sup>12</sup> El código de Python que genera el archivo de distancias entre cada par de tiendas se encuentra en el siguiente [link](#).

fórmula de Haversine (Green, 1977). En definitiva, calcula la distancia más corta entre dos puntos en la superficie de una esfera, siguiendo el arco de un círculo máximo.

Variables de decisión

Al ser un modelo diseñado para operar de manera específica sobre cada categoría de producto, implica que las decisiones de distribución se definan de forma independiente para cada categoría, lo que permite una asignación precisa y adaptada a las necesidades de cada una. De esta forma:

$x_{tt'}[u] \in \mathbb{N}$ , es la cantidad de unidades de una categoría específica enviadas desde la tienda  $t$  hacia la tienda  $t'$ .

Planteo del modelo de PLE

La función costo tiene en cuenta la

$$\min z [\$] = \alpha \sum_{t' \in T} \omega_{t'} (\theta_{t'} - \sum_{t \in T} x_{tt'}) + (1 - \alpha) \sum_{t' \in T} \sum_{t \in T} d_{tt'} \cdot x_{tt'} \dots (8)$$

Restricciones		
1	$x_{tt'} \geq 0 \quad \forall t, t' \in T, t \neq t' \quad \dots (9)$	La cantidad de productos enviados desde una tienda $t$ a otra $t'$ debe ser un entero mayor o igual a 0.
2	$\sum_{t \in T} x_{tt'} \leq \theta_{t'} \quad \forall t' \in T \quad \dots (10)$	La cantidad de unidades de una categoría específica enviadas a $t'$ debe ser menor o igual a la cantidad faltante de esa categoría en $t'$ .
3	$\sum_{t' \in T} x_{tt'} \leq S_t - D_t \quad \forall t \in \{t   S_t \geq D_t\} \quad \dots (11)$	La cantidad de unidades de una categoría específica que envía $t$ al resto de las tiendas debe ser menor o igual a la cantidad sobrante de esa categoría en $t$ .
4	$\sum_{t' \in T} x_{tt'} = 0 \quad \forall t \in \{t   D_t > S_t\} \quad \dots (12)$	La cantidad de unidades de una categoría específica que envía $t$ al resto de las tiendas debe ser cero si la tienda $t$ tiene faltantes en esa categoría.

### Resolución del modelo

Para resolver este modelo, se redefine la función objetivo en forma canónica<sup>13</sup>.

Esto puede pensarse en términos de un vector de costos  $\vec{c} = (1 - \alpha) \vec{d} - \alpha \vec{\omega}$  y un vector de envíos  $\vec{x}$  de forma tal que:

$$\min \bar{z} [\$] = \vec{x} \cdot \vec{c} \quad \dots (13)$$

Siendo los vectores anteriores representados de la siguiente forma:

$$\vec{x} = \begin{bmatrix} x_{11} \\ x_{12} \\ \vdots \\ x_{21} \\ x_{22} \\ \vdots \\ x_{2n} \\ \vdots \\ x_{n1} \\ x_{n2} \\ x_{n3} \\ \vdots \\ x_{nn} \end{bmatrix} \quad \vec{d} = \begin{bmatrix} d_{11} \\ d_{12} \\ \vdots \\ d_{21} \\ d_{22} \\ \vdots \\ d_{2n} \\ \vdots \\ d_{n1} \\ d_{n2} \\ d_{n3} \\ \vdots \\ d_{nn} \end{bmatrix} \quad \vec{\omega} = \begin{bmatrix} \omega_1 \\ \omega_2 \\ \omega_3 \\ \vdots \\ \omega_{n-1} \\ \omega_n \\ \omega_1 \\ \omega_2 \\ \omega_3 \\ \vdots \\ \omega_{n-1} \\ \omega_n \\ \vdots \end{bmatrix}$$

Dada la formulación del problema, la elección de satisfacer un quiebre depende de la comparación relativa entre el costo del quiebre y el costo de la distancia recorrida por unidad enviada para evitar el quiebre. Si el costo de la distancia recorrida por unidad enviada supera al costo del quiebre, entonces el modelo podría elegir no satisfacer esa demanda. Es decir, la cobertura no sucederá siempre necesariamente, sino que dependerá tanto de los valores que tomen los parámetros del modelo relativos a costos, como del parámetro  $\alpha$  que pondera el costo del quiebre sobre el costo de la distancia recorrida.

En principio, para la empresa el costo de un quiebre de *stock* es igual en cualquiera de sus tiendas. Con lo cual, una vez cubiertas las tiendas definidas como prioritarias, no existe un orden preestablecido a seguir para cubrir a las restantes con faltantes. Ese orden queda abierto a una decisión posterior. O alternatively, podrían definirse costos de quiebre distintos en todas las tiendas y el algoritmo priorizaría su cobertura total o parcial siguiendo ese orden preestablecido, primero aquellas con costos de quiebre más altos y luego aquellas con costos más bajos.

De esa forma, en el caso que se agoten las posibilidades para cubrir determinadas tiendas con faltantes, las mismas quedarán sin la opción de abastecerse de otras tiendas con sobrantes. Es por ello que se otorga la posibilidad de definir tiendas prioritarias que deban ser cubiertas total o parcialmente, antes que cualquier otra. La definición de  $\omega_t$  es la que permite tener esto en consideración, de forma tal que la cobertura no es secuencial, sino que está determinada por el costo por unidad de quiebre en cada una de las tiendas para cada categoría de producto.

Puede suceder que las tiendas más prioritarias sean tiendas con sobrantes (no necesariamente demandantes de mercadería), pero eso no afecta el funcionamiento del algoritmo.

<sup>13</sup> El código de Python que genera el modelo con CPLEX se encuentra en el siguiente [link](#) y la clase que permite armar la instancia para pasarla por el modelo se encuentra en el siguiente [link](#).


En el otro extremo, si no existen tiendas con sobrantes, pero sí con faltantes, el algoritmo no arrojará sugerencias de redistribución de mercadería entre tiendas. Eso implicaría que la empresa tome la decisión de realizar las compras pertinentes para las tiendas que así lo considere.

## 4. Resultados


Atendiendo a la necesidad de tener un modelo de pronóstico de ventas de carácter cortoplacista (próxima quincena) con el fin de poder definir un esquema de redistribución óptimo de inventarios entre tiendas para minimizar los quiebres de *stock*, fue imperioso contar con un buen modelo de *forecasting* que alimente al de redistribución.

Para evaluar la performance de ese modelo de pronóstico, en la **Ilustración 15-Ilustración 17**, se presenta la comparativa entre los valores reales y pronosticados de ventas en los meses de febrero, marzo y abril (a nivel categoría, agregando las quincenas del mes), mostrando el error agregado y la utilidad de los resultados en el proceso de redistribución optimizada de inventarios.


**Ilustración 15: MAPE mensual por categoría de producto: mes de febrero**



**Ilustración 16: MAPE mensual por categoría de producto: mes de marzo**



**Ilustración 17: MAPE mensual por categoría de producto: mes de abril**



Tal como se observa, el error agregado a nivel categoría comparando el pronóstico con la venta real, es inferior al 10% para las categorías Calzado y Textil (que representan el mayor % de las ventas totales); mientras que para Accesorio se encuentra levemente por encima del 10%. Estos valores son totalmente aceptables en modelos de pronóstico de ventas (Frechtling, 1996).

Analizado lo anterior y considerando que los errores del modelo por categoría y subcategoría son aceptables (como se ve en la **Tabla 5-Tabla 22** de la sección 3.1), así como también los errores del pronóstico a nivel categoría desagregado por tienda (como se ve en la **Tabla 23-Tabla**

28 de la sección 3.1) y a nivel género desagregado por tienda<sup>14</sup>(como se ve en la **Tabla 55-Tabla 60** del Apéndice A. Resultados adicionales de la validación del Modelo de Pronóstico), los resultados son aptos para ser tomados como *input* por el modelo de redistribución de inventarios entre tiendas.

Junto con los pronósticos de la segunda quincena del mes de mayo se entregó a la empresa la redistribución de inventario, alimentando al modelo con los pronósticos y utilizando la información de inventario por categoría, subcategoría, género y tienda hasta el día inmediato anterior a la fecha de realización del pronóstico.

Considerando que existen 3 categorías (Calzado, Textil y Accesorio), 6 subcategorías (*Basketball, Casual, Running, Skate, Soccer y Training*) y 3 géneros (*Men, Women y Children*), deben resolverse 54 problemas de optimización distintos, teniendo en cuenta que cada uno de ellos es a nivel categoría-subcategoría-género. Ahora bien, dentro de cada problema, existen 22 tiendas entre las cuales el modelo debe decidir las redistribuciones de productos, donde algunas tendrán faltantes y otras sobrantes al comparar su *stock* con su demanda pronosticada para esa categoría, subcategoría y género específicos.

Previo a la generación de la redistribución de inventarios entre tiendas, dado el nivel de *stock* y el pronóstico de demanda por tienda para una categoría, subcategoría y género específicos, deben definirse los valores  $\omega_t$  y  $\alpha$  tales que permitan establecer el costo de un quiebre en cada tienda (y, por ende, la prioridad que tiene su cobertura) y el peso del quiebre sobre la distancia recorrida para cubrirlo, respectivamente.

Tomando un valor de  $\alpha = 0.65$ , es decir, que se le da mayor relevancia a cubrir el quiebre que a la distancia recorrida para cubrirlo, y los siguientes valores de costo de quiebre expresados en \$/unidad para cada una de las tiendas:

**Tabla 29: Costos de quiebre por tienda (expresados en \$ por unidad)**

Tienda	Tienda 1	Tienda 2	Tienda 3	Tienda 4	Tienda 6	Tienda 7	Tienda 8	Tienda 9	Tienda 10	Tienda 11	Tienda 12	Tienda 13	Tienda 14	Tienda 15	Tienda 16	Tienda 17	Tienda 18	Tienda 19	Tienda 20	Tienda 21	Tienda 22	Tienda 23
Costo de Quiebre $w_t$ (\$/unidad)	\$90	\$62	\$85	\$60	\$70	\$55	\$80	\$75	\$90	\$97	\$75	\$95	\$78	\$60	\$95	\$85	\$55	\$82	\$88	\$75	\$75	\$75

Debe considerarse que, para pares de tiendas muy lejanas entre sí, el costo de traslado por unidad es mayor al costo del quiebre por unidad, por lo que será decisión del modelo llevar a cabo la distribución o no.

Dado un  $\alpha = 0.65$ , se está ponderando más cubrir el quiebre que lo que cueste el traslado de la unidad, y esto se fundamenta en que para la empresa no sólo es importante mirar el costo del traslado versus el beneficio de la venta, sino también otros costos implícitos como el de la pérdida de clientes, disminución de la fidelidad en la marca, entre otros, por no cubrir los quiebres.

<sup>14</sup> Sabiendo que los modelos tienen una buena performance a nivel categoría y subcategoría, como así también a nivel categoría-tienda y género-tienda en forma independiente, puede inferirse que los resultados de los modelos son buenos a nivel categoría, subcategoría, género y tienda en conjunto.

Básicamente, el  $\alpha$  opera de forma tal que hace percibir a los términos de costo con otro valor distinto al absoluto: al ponderar más al costo del quiebre que al costo de recorrer la distancia para cubrirlo, se está de alguna manera “desinflando” el costo del traslado (por lo que, en esas tiendas lejanas, el modelo termina percibiéndolo como menor). Aun así, podría suceder que supere en valor absoluto al costo del quiebre pero que igual el modelo decida hacer el envío, dado el valor de  $\alpha$ . De igual forma, siempre priorizará el envío desde tiendas más cercanas que puedan cubrir el faltante frente a recorrer distancias más largas.

Ahora bien, si  $\alpha = 0.5$ , ambos términos de costo estarían igualmente ponderados para el modelo, de forma tal que este último no haría aquellos viajes para los cuales el costo del envío sea mayor al costo del quiebre. Sin embargo, no es el fin último del trabajo realizar sólo envíos rentables en términos absolutos, sino que lo primordial es reducir los quiebres. El componente del costo de envío se añade con el fin de que el modelo elija los envíos desde las tiendas más cercanas.

A continuación, se presenta una muestra del *output* de la redistribución sugerida para una categoría, subcategoría y género específicos durante la segunda quincena de mayo:

**Tabla 30: Muestra de la redistribución para la segunda quincena de mayo del 2022**

Origen	Destino	Faltante	Enviar	Cobertura	Categoría	Subcategoría	Género
['Tienda 6']	Tienda 1	2	[2]	100%	Textil	Soccer	Children
['Tienda 4']	Tienda 10	4	[4]	100%	Textil	Soccer	Children
['Tienda 6', 'Tienda 8', 'Tienda 9', 'Tienda 12', 'Tienda 14']	Tienda 11	13	[5, 4, 2, 1, 1]	100%	Textil	Soccer	Children
['Tienda 4']	Tienda 13	7	[7]	100%	Textil	Soccer	Children
['No hay tiendas para cubrir el faltante']	Tienda 15	4	[0]	0%	Textil	Soccer	Children
['Tienda 4']	Tienda 16	9	[9]	100%	Textil	Soccer	Children
['No hay tiendas para cubrir el faltante']	Tienda 18	2	[0]	0%	Textil	Soccer	Children
['Tienda 6', 'Tienda 17']	Tienda 20	11	[4, 7]	100%	Textil	Soccer	Children
['Tienda 6']	Tienda 21	24	[4]	17%	Textil	Soccer	Children
['Tienda 12', 'Tienda 6']	Tienda 3	10	[3, 7]	100%	Textil	Soccer	Children
['Tienda 12']	Tienda 5	2	[2]	100%	Textil	Soccer	Children
['No hay tiendas para cubrir el faltante']	Tienda 7	2	[0]	0%	Textil	Soccer	Children

Tal como puede visualizarse en la **Tabla 30**, los campos output del modelo son:

- Tienda destino: tienda con faltantes en una categoría, subcategoría y género específicos.
- Cantidad faltante: resulta del cálculo de la diferencia entre el inventario y el pronóstico para esa categoría, subcategoría, género y tienda particular.
- Tiendas origen: pueden ser una o más, dependiendo de la distribución sugerida por el modelo de optimización al intentar cubrir los faltantes de *stock*.
- Cantidad a enviar: puede ser igual al faltante o inferior, y depende directamente del *stock* disponible en las tiendas con sobrantes para esa categoría, subcategoría y género específicos. En el caso que implique envíos desde más de una tienda, se encuentra una lista de números, en la cual cada elemento se corresponde con las cantidades a enviar desde cada tienda presente en la lista de tiendas origen.

- Porcentaje de cobertura: calculado como el cociente entre la cantidad a enviar y la cantidad faltante<sup>15</sup>.
- Categoría, Subcategoría y Género: indicando específicamente qué producto se encontraría en falta en una tienda determinada dada la proyección realizada.

### Validación integral del sistema

Recordando que el flujo del sistema comienza con la generación del pronóstico para la próxima quincena y que luego ese resultado es utilizado como *input* para el modelo de redistribución de inventarios entre tiendas, puede asegurarse que si el comportamiento del modelo de pronóstico es adecuado entonces el modelo de redistribución generará buenos resultados en cuanto a la reducción de los quiebres de *stock* (siempre y cuando los encargados de ejecutar las redistribuciones respeten las reglas indicadas por el modelo).

Como se demostró anteriormente, la validación del modelo de pronóstico arrojó resultados satisfactorios, pero para dar un paso más allá y poder medir la performance integral de todo el sistema se presentan los resultados de dos validaciones adicionales:


- 1) Se contabilizó el total mensual de quiebres de *stock* registrados por cada tienda, categoría, subcategoría y género de producto para el período enero-agosto del año 2022. Observando la evolución de estos totales y considerando que la herramienta comenzó a implementarse desde la segunda quincena del mes de mayo, esperaríamos observar una tendencia decreciente del total de quiebres mensuales a partir del mes de junio.

Tal como puede observarse en la **Ilustración 18**, esto es lo que efectivamente sucede. Pero como esto podría deberse meramente a un tema de la estacionalidad en la demanda, también se muestra cómo caen los quiebres de *stock* con respecto al volumen de ventas mensuales en el mismo gráfico (en términos porcentuales), lo cual confirma la contribución del modelo. Sin embargo, este indicador puede implicar conclusiones erróneas, ya que a partir de la implementación de la herramienta los colaboradores en las tiendas le dieron menos importancia al registro de los quiebres de *stock* (se relajó la tarea de anotar todos los quiebres).

---

<sup>15</sup> Los casos en los cuales el porcentaje de cobertura es igual a 0% se explican por una ausencia de tiendas con sobrantes para cubrir el faltante en esa categoría, subcategoría y género específicos. Es por eso que, en el campo tiendas origen, figurará “No hay tiendas para cubrir el faltante”. Esto puede deberse a que ninguna tienda cuenta con sobrantes previo a la redistribución sugerida, o bien porque tras cubrir a las tiendas prioritarias u otras tiendas primero (dada una combinación entre el costo del quiebre y el costo del transporte por tienda), no hubo más sobrantes de *stock* en esa categoría, subcategoría y género particulares.

**Ilustración 18: Total de quiebres de stock mensuales registrados (Año 2022)**



El mes de mayo no se encuentra graficado ya que durante la segunda mitad se realizó la implementación de la redistribución, por lo que habría un híbrido entre los quiebres de *stock*.

- 2) Dada la limitación mencionada en la validación del punto anterior, se realiza un segundo ejercicio que consiste en un *backtesting* del funcionamiento completo de la herramienta. Se simula la implementación de todo el proceso para las ocho quincenas comprendidas entre los meses de enero a abril. Para cada quincena comprendida en ese período, se realiza lo siguiente:

#### **Escenario sin redistribución**

Se suma el total de quiebres de stock por cada tienda, categoría, subcategoría y género de producto registrados por los colaboradores de las tiendas en la herramienta destinada a tal fin para la quincena en cuestión. De aquí surge el total de quiebres sin haber implementado el modelo desarrollado.

#### **Escenario con redistribución**

Tomando como *input* las ventas reales al inicio de la quincena en cuestión, se pronostican las ventas de dicha quincena. Este resultado junto al inventario al inicio de la quincena ingresan al modelo de redistribución, arrojando este último los intercambios de productos entre tiendas para lograr la mayor cobertura posible de las ventas pronosticadas. Finalmente, se compara la redistribución sugerida con los quiebres de *stock* reales registrados mencionados en el escenario anterior y con las ventas reales de las tiendas con sobrantes a las cuales se les extrajo mercadería para cubrir los faltantes en otras (basados en el pronóstico efectuado).

A continuación, se presenta un ejemplo del proceso realizado:

**Tabla 31: Quiebres de Stock registrados en las tiendas**

Tienda	Categoría	Subcategoría	Género	Quiebre	
				SR*	CR**
T001	Calzado	Casual	F	2	0
T005	Calzado	Running	M	1	0
T012	Textil	Training	F	3	3
T002	Calzado	Basketball	M	2	2
T005	Calzado	Casual	F	4	2
T007	Textil	Casual	M	1	0
Total quiebres				13	7

(\*) Sin redistribución. (\*\*) Con redistribución.

**Tabla 32: Redistribución sugerida por el modelo**

Tienda destino	Tienda origen	Cantidad a enviar	Categoría	Subcategoría	Género
T001	T006	3	Calzado	Casual	F
T005	T002	2	Calzado	Casual	F
T014	T011	1	Calzado	Casual	M
T005	T011	2	Calzado	Running	M
T005	T011	1	Calzado	Running	F
T007	T008	3	Textil	Casual	M
T003	T012	1	Textil	Trining	F

Los colores en la **Tabla 32** asocian la distribución sugerida con el resultado final observado en la tienda con faltantes (**Tabla 31**).

La **Tabla 33** permite visualizar cómo fue el desempeño en los quiebres de *stock* sobre aquellas tiendas que funcionaron como abastecedoras de productos. De esa forma, se contabiliza todo quiebre de *stock* adicional que se haya producido porque la tienda origen resultó tener un volumen de ventas mayor al pronosticado y terminó distribuyendo más de lo que debía.

**Tabla 33: Ventas reales de las tiendas de origen**

Tienda	Inventario inicial	Cantidad a enviar	Inventario final	Ventas	Quiebre	Categoría	Subcategoría	Género
T006	10	3	7	6	0	Calzado	Casual	F
T002	12	2	10	8	0	Calzado	Casual	F
T011	24	1	23	24	1	Calzado	Casual	M
T011	4	2	2	0	0	Calzado	Running	M
T011	6	1	5	3	0	Calzado	Running	F
T008	17	3	14	11	0	Textil	Casual	M
T012	10	1	9	10	1	Textil	Trining	F

Quiebres adicionales	2
----------------------	---

Total quiebres SR	13
Total quiebre CR	9
<b>Reducción</b>	<b>-31%</b>

Además, para aislar el aporte de cada componente –pronóstico y redistribución– y cuantificar el beneficio marginal del módulo de redistribución respecto al uso del pronóstico por sí sólo, se comparan tres escenarios sobre las mismas ocho quincenas del *backtesting* (enero 2022–abril 2022):

**Tabla 34: Descripción de los tres escenarios posibles para medir efectos en quiebres de stock**

Escenario	Descripción operativa	Fuente de datos / supuesto
<b>A. Actual</b>	Operación real de la empresa antes del proyecto (sin pronóstico sistemático ni traslados entre tiendas).	Quiebres reales registrados en la app.
<b>B. Forecasting</b>	Cada tienda reaprovisiona su stock inicial en base a un presupuesto, capacidad del proveedor y lead-time dados, hasta cubrir un porcentaje de la demanda pronosticada por Prophet (utilizando el <i>upper bound</i> del intervalo de confianza del 90%, que garantizaría un nivel de servicio de ~90%). Esto en números implica que, de lo que le falta para cubrir esa demanda potencial, puede comprar entre un 50%-60%. No se pueden hacer traslados entre tiendas durante la quincena. Cualquier error de pronóstico genera quiebres.	Prophet Forecast a nivel categoría-subcategoría-género-tienda. Inventario inicial real. Nivel de presupuesto, capacidad del proveedor y lead-time dados.
<b>C. Forecasting + Redistribución</b>	Forecasting + modelo de transporte que reubica excedentes entre tiendas siguiendo la función objetivo (sección 3.2).	Prophet Forecast a nivel categoría-subcategoría-género-tienda. Inventario inicial real. Output del modelo de redistribución.

A partir de eso, los beneficios en términos de reducción de quiebres de stock al pasar del escenario A al B y del B al C, quedan plasmados en la **Tabla 35**:

**Tabla 35: Quiebres de stock totales aislados por escenario (enero 2022–abril 2022)**

	A. Actual	B. Forecasting	C. Forecasting + Redistribución
Quiebres totales (u)	1766	Entre 1500-1466	1247
Reducción vs. A	-	Entre 15%-17% (-266 u / -300 u)	29% (-519 u)
Reducción vs. B	-	-	Entre 15%-17% (-219 u / -253 u)

Para calcular los quiebres en el escenario B. se utiliza la siguiente fórmula:

$$Q^B = \max\{D - [S + \delta \max\{(\hat{D} - S), 0\}], 0\} \quad \dots (14)$$

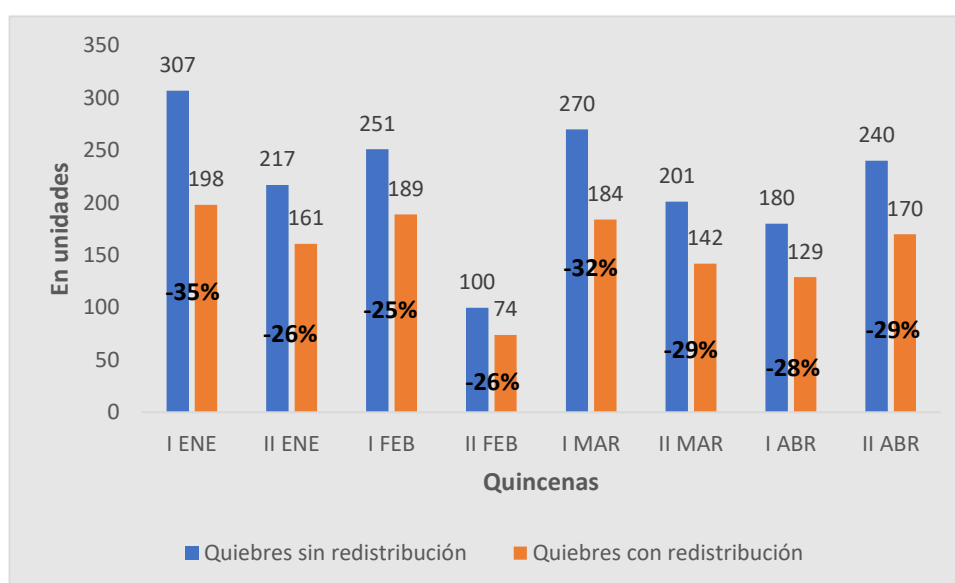
Donde  $D$  es la demanda real,  $S$  el stock disponible,  $\hat{D}$  la demanda pronosticada y  $\delta$  el porcentaje de la demanda pronosticada que se compra porque no puede ser cubierto con el nivel de stock actual (entre 50% y 60% para este caso).

Comparar la situación A. con la B. mide lo que se gana sólo con prever y comprar (pero también podría haber un sobre-stockeo en el caso que el pronóstico de la demanda sea mayor a la demanda real, aunque eso no afectaría los quiebres de *stock*). Luego, comparar la situación B. con la C. mide la ganancia adicional de mover inventario entre tiendas.

Queda claro de esta forma, que cada escenario tiene su aporte marginal en la reducción de los quiebres de stock, tal que el escenario C (*Forecasting* + Redistribución), logra una disminución de los quiebres totales en torno al 29% para el período comprendido en las 8 quincenas mencionadas.

Los resultados finales agregados del modelo completo para todas las quincenas comprendidas en el período en cuestión (total de quiebres de todas las tiendas, categorías, subcategorías y géneros) se presentan en la **Ilustración 19**:

**Ilustración 19: Quiebres de stock antes y después de la redistribución de productos**



Nuevamente, como puede observarse en la figura anterior, la herramienta genera una clara ganancia en la reducción de quiebres de *stock*, lo cual era el principal objetivo del desarrollo.

En miras de dimensionar el impacto en términos de *stock* redistribuido por el modelo, se presenta un resumen con las principales métricas en base al *backtesting* realizado para las quincenas comprendidas entre enero y abril del 2022:

- Se relocaliza en promedio el **4,9 %** del *stock* quincenal.
- Se calcula el *ratio stock/demanda* pronosticada para cada tienda (todas las categorías en conjunto), antes y después de la redistribución, como medida o índice de cobertura:

$$r_t = \frac{\text{stock antes}_t}{\text{demanda pronosticada}_t}, r'_t = \frac{\text{stock después}_t}{\text{demanda pronosticada}_t} \quad \dots (15)$$

- Luego, se calcula el coeficiente de variación de los índices de cobertura del punto anterior de la forma:

$$CV_r(\text{antes}) = \frac{\sigma_r \text{ antes}}{\mu_r \text{ antes}}, CV_r(\text{después}) = \frac{\sigma_r \text{ después}}{\mu_r \text{ después}} \quad \dots (16)$$

Siendo  $\sigma_r$  el desvío estándar del índice calculado sobre las 22 tiendas y  $\mu_r$  la media del índice calculada sobre las 22 tiendas.

- Finalmente, se calcula el porcentaje de reducción de la dispersión como:

$$\text{Reducción } CV_r (\%) = \frac{CV_r(\text{antes}) - CV_r(\text{después})}{CV_r(\text{antes})} * 100 \quad \dots (17)$$

Se produce una reducción del CV en torno al **25 %**, lo que indica que, luego de las redistribuciones sugeridas por el modelo, las diferencias de servicio entre tiendas se reducen considerablemente, aun cuando los volúmenes de *stock* siguen siendo distintos y acordes al potencial de cada punto de venta. Esto refuerza el objetivo principal, que es alinear inventario con demanda.

En definitiva, con un movimiento promedio de **4,9 %** del *stock* quincenal, se reduce alrededor de **un cuarto** la dispersión inter-tiendas del índice de cobertura y se evitan  $\approx$  **260 quiebres** por cada mil unidades movidas.

Por último, y para complementar esta evaluación del rendimiento del sistema se define una función de costos, que tiene como entrada los datos de ventas por tienda más recientes para cada categoría, subcategoría y género de producto. Con eso, se realiza un pronóstico de demanda y se alimenta a un modelo de redistribución de *stock* utilizando los inventarios reales en cada tienda hasta ese momento del tiempo. Dicha función de costos debe ser evaluada tanto en la solución propuesta por el modelo de redistribución, como en los datos históricos de venta (donde la redistribución es nula), de forma tal que permita analizar si realmente existe un decrecimiento de los costos.

Recordando la función objetivo del modelo de redistribución:

$$z(X; \theta) = \alpha \sum_{t' \in T} \omega_{t'} (\theta_{t'} - \sum_{t \in T} x_{tt'}) + (1 - \alpha) \sum_{t' \in T} \sum_{t \in T} d_{tt'} \cdot x_{tt'} \quad \dots (18)$$

Esta función de costos tiene el inconveniente de depender de  $\theta_{t'}$ , que se calcula mediante el pronóstico de la demanda. Para tener en cuenta los errores en el pronóstico de la demanda, debe modificarse la función de costos de forma tal que considere la demanda real:

$$z_{real}(X; \Theta) = \alpha \sum_{t' \in T} \max \left\{ 0, \omega_{t'} (\Theta_{t'} - \sum_{t \in T} x_{tt'}) \right\} + (1 - \alpha) \sum_{t' \in T} \sum_{t \in T} d_{tt'} \cdot x_{tt'} \quad \dots (19)$$

Donde  $\Theta_{t'}$  representa la cantidad real de productos faltantes  $t'$ , pudiendo valer 0 si el *stock* es mayor a la demanda.

Nótese que, si el modelo sobre pronostica el faltante y se envían más productos de los que realmente se necesitan, entonces  $\Theta_{t'} < x_{tt'}$  y por lo tanto  $\omega_{t'} (\Theta_{t'} - \sum_{t \in T} x_{tt'}) < 0$ . En este caso, el costo de quiebre de stock se vuelve negativo, por lo que se está subestimando el costo. Por este motivo se calcula la función  $\max\{0, \omega_{t'} (\Theta_{t'} - \sum_{t \in T} x_{tt'})\} = 0$ , de modo tal que cuando  $\Theta_{t'} < x_{tt'}$ , el costo de quiebre de *stock* sea exactamente igual a 0.

Por último, debe analizarse la función  $z_{real}$  para los datos históricos. Como en un principio la empresa no contaba con una redistribución de los recursos,  $x_{tt'} = 0 \forall t, t'$ . La función de costos queda representada de la siguiente forma:

$$z_{real}(X = 0; \Theta) = \alpha \sum_{t' \in T} \max\{0, \omega_{t'} (\Theta_{t'} - 0)\} + (1 - \alpha) \sum_{t' \in T} \sum_{t \in T} d_{tt'} \cdot 0 \quad \dots (20)$$


Como  $\Theta_t \geq 0 \forall t$ :

$$z_{real}(X = 0; \Theta) = \alpha \sum_{t' \in T} \omega_{t'} \Theta_{t'} \quad \dots (21)$$

Esto tiene sentido, ya que como la empresa redistribuye el stock para satisfacer la demanda potencial, cada unidad de producto faltante implica un costo de quiebre de *stock*.

En la **Ilustración 20** se presentan graficadas ambas funciones de costos para el período utilizado como *backtesting* (todas las quincenas comprendidas entre enero y abril) durante el cual no se utilizaba aún la herramienta de redistribución:

**Ilustración 20: Costos para la empresa antes y después de la redistribución de productos**



Tal como se visualiza en el gráfico, la función de costos evaluada sobre las ventas reales antes de la distribución es consistentemente superior a la evaluada luego de la redistribución sugerida. Con esto, se termina de confirmar la eficiencia del sistema en lograr el objetivo de reducir los quiebres de *stock* e indirectamente reducir los costos para la empresa.

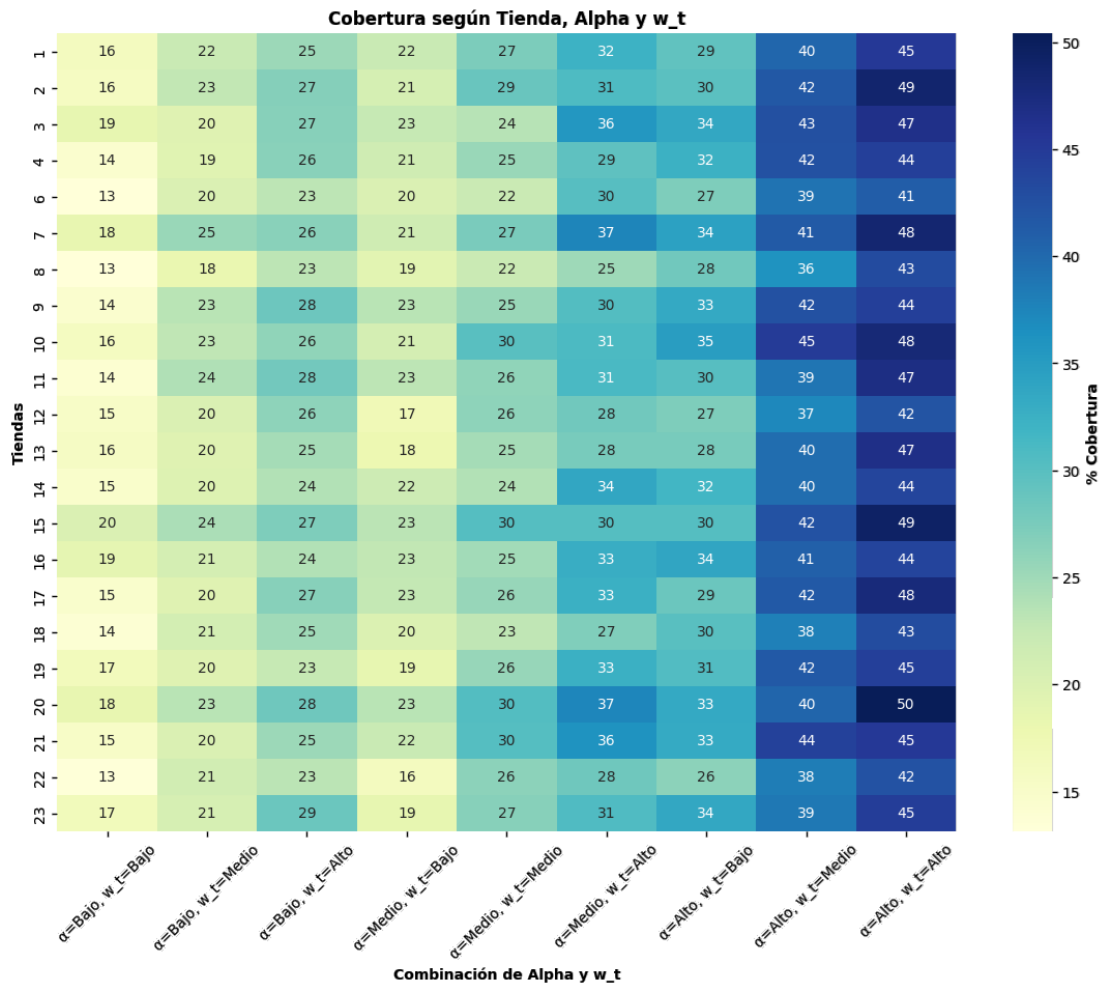
#### **Análisis de Sensibilidad (variando $\alpha$ y $\omega_t$ simultáneamente)**

En esta sección se presenta un análisis de sensibilidad del modelo de redistribución, evaluando cómo la cobertura de tiendas varía en función de dos parámetros clave: la ponderación de la cobertura sobre la distancia recorrida para una cobertura ( $\alpha$ ) y el costo de quiebre por unidad en cada tienda ( $\omega_t$ ). El objetivo de este análisis es observar cómo diferentes combinaciones de estos factores afectan la cobertura asignada a cada tienda y, en última instancia, optimizar la redistribución de recursos.

El análisis se ejecutó bajo el pronóstico de demanda de la primera quincena del mes de abril, y teniendo en cuenta el *stock* disponible en cada tienda para la categoría Calzado, subcategoría *Casual* y género *Men* (combinación de productos que representa el mayor volumen de ventas y, por lo tanto, es representativa del total).

Para llevar esto a cabo, se han considerado tres niveles de  $\alpha$  (bajo, medio y alto) y tres niveles de  $\omega_t$  (bajo, medio y alto). La matriz de sensibilidad resultante, presentada en el mapa de calor de la **Ilustración 21**, permite identificar patrones de cobertura en función de estos parámetros, donde cada celda representa el porcentaje de cobertura para una combinación específica de  $\alpha$  y  $\omega_t$  en cada tienda. La escala de color indica la intensidad de cobertura, con valores más altos representados en tonos azul oscuro y valores más bajos en tonos amarillos y verdes.

**Ilustración 21: % de cobertura por tienda variando  $\alpha$  y  $\omega_t$**



A medida que se observa el gráfico de izquierda a derecha, el análisis revela cómo la cobertura asignada a las tiendas responde a los cambios en los valores de  $\alpha$  y  $\omega_t$ . En general, se observa que:

- Valores a la izquierda del gráfico ( $\alpha$  bajo): la cobertura tiende a ser más baja en esta región, reflejando una menor prioridad de cobertura en tiendas con  $\alpha$  reducido. Esto sugiere que el modelo de redistribución asigna recursos de manera menos intensiva cuando la importancia del quiebre es baja, lo cual es coherente con una ponderación mayor del término de costo de la distancia recorrida por sobre el costo de quiebre, haciendo que sea más rentable el quiebre que recorrer la distancia para evitarlo. Dentro de este grupo, cuanto más bajo es el valor de  $\omega_t$ , más baja aún es la cobertura, ya que se refuerza ese efecto de mayor rentabilidad del quiebre por sobre el recorrido para cubrirlo.
- Valores al centro del gráfico ( $\alpha$  medio): conforme se incrementa el  $\alpha$ , la cobertura comienza a aumentar de forma moderada, reflejando una mayor asignación de recursos a las tiendas. Esto sugiere una mayor sensibilidad del modelo hacia el riesgo de quiebre, volviéndolo menos rentable. Al mismo tiempo, cuanto más alto es el valor de  $\omega_t$ , más alta es aún la cobertura, ya que se refuerza ese efecto de menor rentabilidad del quiebre por sobre el costo del recorrido para cubrirlo.

- Valores a la derecha del gráfico ( $\alpha$  alto): En las últimas columnas del gráfico, se observa que la cobertura tiende a alcanzar sus valores más elevados. Sin embargo, los valores permanecen en un rango de hasta el 50% de cobertura, indicando que incluso en condiciones de alta ponderación y costo de quiebre, las tiendas pueden no estar maximizando su cobertura por falta de *stock* disponible. Ahora bien, para combinaciones de  $\alpha$  alto y  $\omega_t$  bajos queda explícita una cobertura menor que en casos de  $\alpha$  medio y  $\omega_t$  medios-altos. Esto da una clara idea que ambos parámetros juegan un rol importante en determinar el porcentaje de cobertura, y todo dependerá de la rentabilidad resultante entre permitir el quiebre o no permitirlo y recorrer la distancia para cubrirlo, dados los valores de  $\alpha$  y  $\omega_t$ .

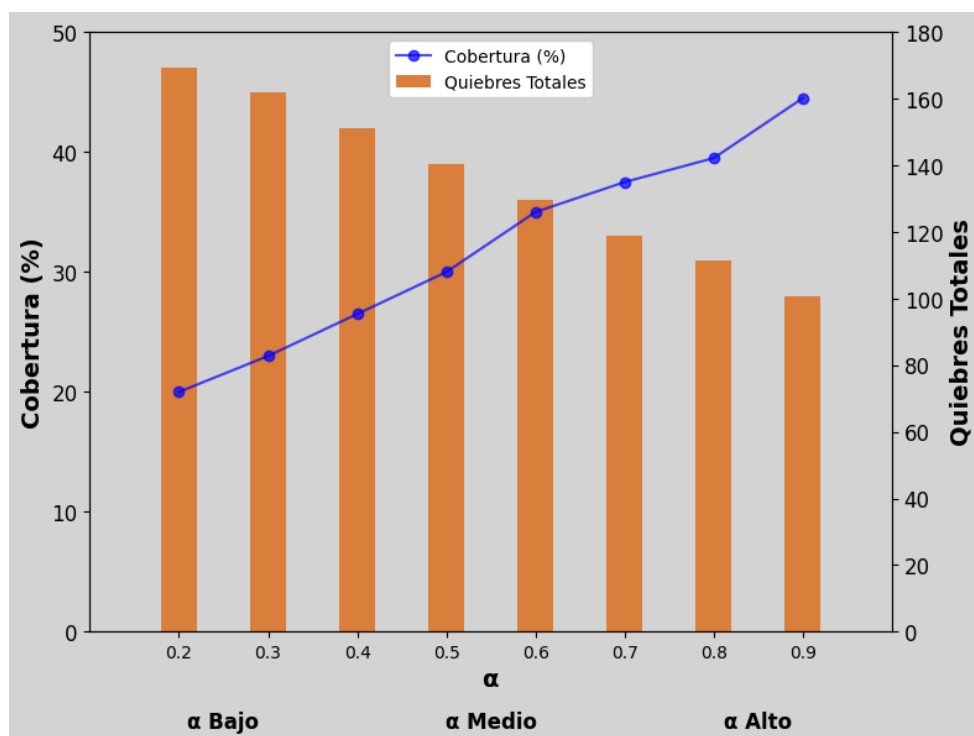
### Análisis de Sensibilidad (variando $\alpha$ únicamente)

A continuación, se realiza un análisis de sensibilidad complementario para el modelo de redistribución, evaluando cómo la cobertura de tiendas y el volumen de quiebres varían en función de la variación de la ponderación de la cobertura sobre la distancia recorrida para una cobertura ( $\alpha$ ), manteniendo fijo el costo de quiebre por unidad en cada tienda ( $\omega_t$ ).

El análisis se ejecutó bajo el pronóstico de demanda de la primera quincena del mes de abril para todas las categorías, subcategorías y géneros de productos.

El gráfico resultante en la **Ilustración 22** presenta la relación entre la cobertura de inventario y los quiebres totales a medida que varía el parámetro  $\alpha$ , segmentado en tres sectores:  $\alpha$  Bajo (0.2 y 0.3),  $\alpha$  Medio (0.5 y 0.6) y  $\alpha$  Alto (0.8 y 0.9). Los valores de  $\alpha = 0.4$  y  $\alpha = 0.7$ , representarían los segmentos  $\alpha$  Medio-Bajo y  $\alpha$  Medio-Alto, respectivamente.

**Ilustración 22: % de cobertura y quiebres totales variando  $\alpha$  con  $\omega_t$  fijo**



La línea azul muestra el porcentaje de cobertura de inventario alcanzado en función del valor de  $\alpha$ . Se observa que, en general, a medida que  $\alpha$  aumenta, la cobertura también incrementa.

Las barras naranjas representan el número total de quiebres de inventario en función del valor de  $\alpha$ . Siguiendo la lógica de la cobertura, se observa que los quiebres tienden a disminuir conforme  $\alpha$  aumenta.

Ahora bien, la determinación de  $\alpha$  en valores bajos, medios o altos dependerá de la importancia para la empresa en mantener un balance entre los costos de quebrar y los costos de transportar la mercadería para evitar el quiebre. Se presenta un *trade-off* de costo-eficiencia que puede manejarse ajustando  $\alpha$ .

## 5. Conclusiones

Tal como se mencionó, la empresa pertenece al rubro del *retail* y se especializa en la venta de ropa deportiva. La estacionalidad es un factor muy influyente en este negocio y hace que las compras de productos para sus distintas categorías y subcategorías deban realizarse con una gran anticipación (de hasta 9 meses).

La previsibilidad en las compras disminuye a medida que el plazo crece, un problema que tiene su principal consecuencia en los quiebres de *stock*. Este es un tema no menor que afecta directamente a la rentabilidad de una empresa, ya sea por las ventas que podrían haberse efectivizado pero no lo hicieron (pérdida de clientes potenciales), como así también por la reducción de la fidelización de los clientes ya activos (clientes que ya realizaron alguna compra en el pasado y están insatisfechos con la tienda por no contar con lo que buscaban).

Luego del registro de todas aquellas solicitudes de clientes no satisfechas y de analizar su comportamiento durante tres meses, se encontró que había 20 quiebres por tienda/día, lo cual equivale en promedio a un 6.5% de las ventas mensuales totales.

El problema anterior fue la principal motivación de la metodología presentada en este trabajo, para atacarlo en forma directa y ayudar a la empresa a seguir creciendo tanto económicamente como en su *branding* (tener una buena reputación).

En este tipo de negocios sobre-stockearse suele ser una decisión común, ya que en el mejor de los casos las temporadas son excelentes, y en caso contrario, siempre pueden rematarse los sobrantes en instancias de liquidación. Sin embargo, es una decisión costosa, ya que aquellas unidades no vendidas que pasan a instancias de liquidación implican una pérdida muy grande en el margen de ganancias, sumado al costo de almacenamiento durante tanto tiempo.

Por otro lado, contar con exceso de *stock* en un lugar donde no es requerido, no resuelve la problemática de los quiebres de *stocks*.

A partir de esto es que se presentó la realización del modelo de pronóstico de ventas de corto plazo por categoría, subcategoría y género para cada una de las 22 tiendas que posee la empresa. El resultado del modelo anterior fue utilizado como *input* para un modelo de redistribución optimizada del inventario entre las tiendas.

Primeramente, se focalizó en la obtención de modelos de *forecasting* con una buena *performance*, y una vez logrados, se utilizaron para alimentar a un modelo de programación lineal entera cuyo principal objetivo es maximizar el porcentaje de cobertura (minimizar el costo de los quiebres) en aquellas tiendas en las cuales se estima un potencial quiebre de *stock* al comparar el inventario actual con el *forecast* (para una categoría, subcategoría y género específicos).

Para tal objetivo, también se consideró el costo de la distancia recorrida como ponderador en las decisiones, de forma tal que se contemplen tanto el costo del quiebre como el costo del transporte para cubrir ese quiebre. El sistema se desarrolló como un modelo del transporte con distribución punto a punto, donde cada asignación entre los diferentes pares de tiendas es independiente de las otras. La posibilidad de definir tiendas prioritarias a cubrir es un detalle interesante que da más versatilidad al modelo.

En la sección de resultados se hizo una validación punta a punta del modelo conjunto de pronóstico y redistribución de inventarios que evidenció tener una muy buena *performance*. Al mismo tiempo, se efectuaron análisis aislados para entender la contribución marginal de cada modelo en la reducción de los quiebres de *stock*, una vez más reforzando el punto antes mencionado. Para ello, se partió de un escenario base sin redistribución, luego se consideró un escenario de *Forecasting* donde se asume que la empresa puede reaprovisionarse en base al pronóstico de demanda, y finalmente se incluyó el escenario de Redistribución que utiliza al modelo de *Forecasting* como *input* para sugerir una reasignación óptima de *stocks* entre las tiendas. Por último, se complementó con un análisis de sensibilidad para el modelo de redistribución, de forma tal que permitiera entender cómo varía el nivel de cobertura en las tiendas dependiendo del valor que asumen el costo de quiebre por unidad en cada tienda y la ponderación del costo del quiebre por sobre el costo de la distancia recorrida para cubrir el quiebre.

En cuanto a los pronósticos vienen siendo bastante acertados al compararlos con los valores reales de ventas, situación que ayuda a la empresa a tener mayor confianza en los resultados del modelo de redistribución de inventarios y, por ende, comenzar a influenciar su toma de decisiones.

Para futuros desarrollos, sería interesante implementar un modelo de optimización que se ejecute para todas las categorías de productos al mismo tiempo y cuyo objetivo considere también minimizar la cantidad de envíos, de forma tal que permita evaluar los resultados y compararlos con el modelo actual propuesto por categoría en forma independiente.

Por otro lado, considerando que en la industria *retail*/consumo masivo es muy común el lanzamiento de innovaciones en cuanto a nuevos productos ofrecidos al consumidor, para que el sistema siga evitando quiebres en este contexto (por más que el producto se englobe en alguna de las categorías de producto existentes), la hoja de ruta podría dividirse en tres capas complementarias:

**Tabla 36: Propuesta de mantenimiento del sistema ante lanzamiento de nuevos productos**

Capa	Objetivo	Qué se añade al sistema actual	Resultado esperado
1. Forecasting de <i>cold-start</i>	Predecir la demanda inicial cuando no hay datos propios.	<ul style="list-style-type: none"> <li>• <b>Analogía controlada:</b> mapear cada nuevo SKU a un “look-alike” histórico (misma categoría, estilo y rango de precio) y heredar su curva de ventas escalada.</li> <li>• <b>Modelos jerárquicos bayesianos:</b> estimar parámetros de arranque combinando información de la marca, canal y país.</li> <li>• <b>Signals externos</b> (pre-orders B2B, social buzz, búsquedas) como regresores.</li> </ul>	Primeras 4-8 semanas con un MAPE razonable ( $\leq 30\%$ ) que permita planear compras mínimas y evitar sobrestock.
2. Aprendizaje rápido ( <i>early-learning</i> )	Ajustar el forecast al “verdadero” patrón de adopción.	<ul style="list-style-type: none"> <li>• Ventana deslizante diaria con <b>ETS(error, trend,seasonal) adaptativo</b> o Prophet con <code>changeoint_prior_scale</code> alto.</li> <li>• Cuando el SKU alcanza <math>N \geq 30</math> ventas o 14 días en piso, cambia a los mismos pipelines que los SKUs existentes.</li> </ul>	Error converge al rango actual ( $\leq 10-15\%$ ); se reduce la variabilidad de reposiciones urgentes.
3. Redistribución	Que el modelo incorpore nuevas variantes de productos.	No cambia nada del sistema actual, ya que una vez realizados buenos pronósticos para el nuevo producto dentro de alguna de las categorías existentes, para el modelo sería transparente.	Redistribución consistente sugerida para el nuevo producto lanzado.

## Referencias

1. Frechtling, D. C. (1996). Practical tourism forecasting. Butterworth-Heinemann Ltd.
2. Glover, F. W., & Kochenberger, G. A. (Eds.). (2003). *Handbook of metaheuristics* (Vol. 57). Springer Science & Business Media.
3. Gridin, I. (2022). *Automated Deep Learning Using Neural Network Intelligence: Develop and Design PyTorch and TensorFlow Models Using Python*. Apress.
4. Hastie, T., Tibshirani, R., & Friedman, J. (2009). Boosting and additive trees. In *The elements of statistical learning: data mining, inference, and prediction* (pp. 337-387).
5. Hyndman, R. J. (2018). *Forecasting: principles and practice*. OTexts.
6. James, G., Witten, D., Hastie, T., & Tibshirani, R. (2017). *ISLR: Data for an Introduction to Statistical Learning with Applications in R* (R package version 1.7).
7. Smart, W. M., & Green, R. M. (1977). *Textbook on spherical astronomy*. Cambridge University Press.
8. Taha, H. A. (2014). *Integer programming: theory, applications, and computations*. Academic Press.
9. Taylor, S. J., & Letham, B. (2018). Forecasting at scale. *The American Statistician*, 72(1), 37-45.
10. Wheelwright, S., Makridakis, S., & Hyndman, R. J. (1998). *Forecasting: methods and applications*. John Wiley & Sons.
11. Wichern, J. E. H. D. (2014). *Business Forecasting*. John E. Hanke & Dean Wichern (9<sup>a</sup> ed.).
12. Williams, H. P. (2013). *Model building in mathematical programming*. John Wiley & Sons.
13. Young, S. T., & Nie, W. D. (1992). A cycle-count model considering inventory policy and record variance. *Production and Inventory Management Journal*, 33(1), 11.

## Apéndice A. Resultados adicionales de la validación del Modelo de Pronóstico

**Tabla 37: MAPE del modelo Prophet para Tiendas 1 a 12 en la categoría Calzado para el mes de febrero 2022 (en %)**

Tienda	Categoría	MAPE
T001	Calzado	10.67
T002	Calzado	19.28
T003	Calzado	18.66
T004	Calzado	24.19
T006	Calzado	27.51
T007	Calzado	16.80
T008	Calzado	14.29
T009	Calzado	16.74
T010	Calzado	0.00
T011	Calzado	20.29
T012	Calzado	10.65

**Tabla 38: MAPE del modelo Prophet para Tiendas 13 a 23 en la categoría Calzado para el mes de febrero 2022 (en %)**

Tienda	Categoría	MAPE
T013	Calzado	12.54
T014	Calzado	42.53
T015	Calzado	31.24
T016	Calzado	15.78
T017	Calzado	18.56
T018	Calzado	10.12
T019	Calzado	18.52
T020	Calzado	15.26
T021	Calzado	22.94
T022	Calzado	23.16
T023	Calzado	33.03

**Tabla 39: MAPE del modelo Prophet para Tiendas 1 a 12 en la categoría Textil para el mes de febrero 2022 (en %)**

Tienda	Categoría	MAPE
T001	Textil	3.74
T002	Textil	1.52
T003	Textil	11.34
T004	Textil	14.66
T006	Textil	5.25
T007	Textil	14.09
T008	Textil	3.11
T009	Textil	9.93
T010	Textil	0.00
T011	Textil	12.99
T012	Textil	10.56

**Tabla 40: MAPE del modelo Prophet para Tiendas 13 a 23 en la categoría Textil para el mes de febrero 2022 (en %)**

Tienda	Categoría	MAPE
T013	Textil	10.58
T014	Textil	10.17
T015	Textil	1.07
T016	Textil	11.87
T017	Textil	2.60
T018	Textil	5.11
T019	Textil	11.31
T020	Textil	11.31
T021	Textil	11.76
T022	Textil	18.64
T023	Textil	7.06

**Tabla 41: MAPE del modelo Prophet para Tiendas 1 a 12 en la categoría Accesorio para el mes de febrero 2022 (en %)**

Tienda	Categoría	MAPE
T001	Accesorio	7.00
T002	Accesorio	3.83
T003	Accesorio	21.34
T004	Accesorio	6.60
T006	Accesorio	9.53
T007	Accesorio	0.93
T008	Accesorio	38.42
T009	Accesorio	21.77
T010	Accesorio	0.00
T011	Accesorio	17.10
T012	Accesorio	9.58

**Tabla 42: MAPE del modelo Prophet para Tiendas 13 a 23 en la categoría Accesorio para el mes de febrero 2022 (en %)**

Tienda	Categoría	MAPE
T013	Accesorio	3.46
T014	Accesorio	4.36
T015	Accesorio	5.12
T016	Accesorio	6.63
T017	Accesorio	22.25
T018	Accesorio	30.04
T019	Accesorio	20.03
T020	Accesorio	16.15
T021	Accesorio	11.59
T022	Accesorio	27.82
T023	Accesorio	12.07

**Tabla 43: MAPE del modelo Prophet para Tiendas 1 a 12 en la categoría Calzado para el mes de abril 2022 (en %)**

Tienda	Categoría	MAPE
T001	Calzado	8.95
T002	Calzado	16.17
T003	Calzado	15.65
T004	Calzado	20.29
T006	Calzado	23.07
T007	Calzado	14.09
T008	Calzado	11.98
T009	Calzado	14.04
T010	Calzado	0.00
T011	Calzado	17.01
T012	Calzado	8.93

**Tabla 44: MAPE del modelo Prophet para Tiendas 13 a 23 en la categoría Calzado para el mes de abril 2022 (en %)**

Tienda	Categoría	MAPE
T013	Calzado	10.52
T014	Calzado	35.67
T015	Calzado	26.20
T016	Calzado	13.23
T017	Calzado	15.56
T018	Calzado	8.49
T019	Calzado	15.53
T020	Calzado	12.79
T021	Calzado	19.24
T022	Calzado	19.43
T023	Calzado	27.70

**Tabla 45: MAPE del modelo Prophet para Tiendas 1 a 12 en la categoría Textil para el mes de abril 2022 (en %)**

Tienda	Categoría	MAPE
T001	Textil	0.51
T002	Textil	0.21
T003	Textil	1.55
T004	Textil	2.00
T006	Textil	0.72
T007	Textil	1.92
T008	Textil	0.42
T009	Textil	1.35
T010	Textil	0.00
T011	Textil	1.77
T012	Textil	1.44

**Tabla 46: MAPE del modelo Prophet para Tiendas 13 a 23 en la categoría Textil para el mes de abril 2022 (en %)**

Tienda	Categoría	MAPE
T013	Textil	1.44
T014	Textil	1.39
T015	Textil	0.15
T016	Textil	1.62
T017	Textil	0.35
T018	Textil	0.70
T019	Textil	1.54
T020	Textil	1.54
T021	Textil	1.60
T022	Textil	2.54
T023	Textil	0.96

**Tabla 47: MAPE del modelo Prophet para Tiendas 1 a 12 en la categoría Accesorio para el mes de abril 2022 (en %)**

Tienda	Categoría	MAPE
T001	Accesorio	7.81
T002	Accesorio	4.27
T003	Accesorio	23.82
T004	Accesorio	7.37
T006	Accesorio	10.64
T007	Accesorio	1.04
T008	Accesorio	42.88
T009	Accesorio	24.30
T010	Accesorio	0.00
T011	Accesorio	19.08
T012	Accesorio	10.70

**Tabla 48: MAPE del modelo Prophet para Tiendas 13 a 23 en la categoría Accesorio para el mes de abril 2022 (en %)**

Tienda	Categoría	MAPE
T013	Accesorio	3.86
T014	Accesorio	4.86
T015	Accesorio	5.71
T016	Accesorio	7.40
T017	Accesorio	24.84
T018	Accesorio	33.53
T019	Accesorio	22.35
T020	Accesorio	18.03
T021	Accesorio	12.93
T022	Accesorio	31.05
T023	Accesorio	13.47

**Tabla 49: MAPE por Tienda (1 a 12) y Género MEN para el mes de febrero 2022 usando Prophet (en %)**

Género	Tienda	MAPE
MEN	T001	1
MEN	T002	0
MEN	T003	28
MEN	T004	23
MEN	T006	11
MEN	T007	8
MEN	T008	9
MEN	T009	7
MEN	T010	0
MEN	T011	10
MEN	T012	9

**Tabla 50: MAPE por Tienda (13 a 23) y Género MEN para el mes de febrero 2022 usando Prophet (en %)**

Género	Tienda	MAPE
MEN	T013	9
MEN	T014	11
MEN	T015	11
MEN	T016	29
MEN	T017	59
MEN	T018	16
MEN	T019	20
MEN	T020	10
MEN	T021	4
MEN	T022	9
MEN	T023	6

**Tabla 51: MAPE por Tienda (1 a 12) y Género WOMEN para el mes de febrero 2022 usando Prophet (en %)**

Género	Tienda	MAPE
WOMEN	T001	1
WOMEN	T002	11
WOMEN	T003	32
WOMEN	T004	23
WOMEN	T006	10
WOMEN	T007	6
WOMEN	T008	12
WOMEN	T009	19
WOMEN	T010	0
WOMEN	T011	2
WOMEN	T012	1

**Tabla 52: MAPE por Tienda (13 a 23) y Género WOMEN para el mes de febrero 2022 usando Prophet (en %)**

Género	Tienda	MAPE
WOMEN	T013	2
WOMEN	T014	10
WOMEN	T015	14
WOMEN	T016	16
WOMEN	T017	25
WOMEN	T018	25
WOMEN	T019	22
WOMEN	T020	24
WOMEN	T021	4
WOMEN	T022	1
WOMEN	T023	14

**Tabla 53: MAPE por Tienda (1 a 12) y Género CHILDREN para el mes de febrero 2022 usando Prophet (en %)**

Género	Tienda	MAPE
CHILDREN	T001	3
CHILDREN	T002	25
CHILDREN	T003	30
CHILDREN	T004	23
CHILDREN	T006	2
CHILDREN	T007	27
CHILDREN	T008	13
CHILDREN	T009	21
CHILDREN	T010	0
CHILDREN	T011	34
CHILDREN	T012	35

**Tabla 54: MAPE por Tienda (13 a 23) y Género CHILDREN para el mes de febrero 2022 usando Prophet (en %)**

Género	Tienda	MAPE
CHILDREN	T013	4
CHILDREN	T014	13
CHILDREN	T015	30
CHILDREN	T016	24
CHILDREN	T017	2
CHILDREN	T018	0
CHILDREN	T019	25
CHILDREN	T020	16
CHILDREN	T021	28
CHILDREN	T022	18
CHILDREN	T023	30

**Tabla 55: MAPE por Tienda (1 a 12) y Género MEN para el mes de marzo 2022 usando Prophet (en %)**

Género	Tienda	MAPE
MEN	T001	1
MEN	T002	0
MEN	T003	25
MEN	T004	21
MEN	T006	10
MEN	T007	7
MEN	T008	8
MEN	T009	6
MEN	T010	0
MEN	T011	9
MEN	T012	8

**Tabla 56: MAPE por Tienda (13 a 23) y Género MEN para el mes de marzo 2022 usando Prophet (en %)**

Género	Tienda	MAPE
MEN	T013	8
MEN	T014	10
MEN	T015	10
MEN	T016	26
MEN	T017	53
MEN	T018	14
MEN	T019	18
MEN	T020	9
MEN	T021	4
MEN	T022	8
MEN	T023	5

**Tabla 57: MAPE por Tienda (1 a 12) y Género WOMEN para el mes de marzo 2022 usando Prophet (en %)**

Género	Tienda	MAPE
WOMEN	T001	1
WOMEN	T002	10
WOMEN	T003	29
WOMEN	T004	21
WOMEN	T006	9
WOMEN	T007	5
WOMEN	T008	11
WOMEN	T009	17
WOMEN	T010	0
WOMEN	T011	2
WOMEN	T012	1

**Tabla 58: MAPE por Tienda (13 a 23) y Género WOMEN para el mes de marzo 2022 usando Prophet (en %)**

Género	Tienda	MAPE
WOMEN	T013	2
WOMEN	T014	9
WOMEN	T015	13
WOMEN	T016	14
WOMEN	T017	23
WOMEN	T018	23
WOMEN	T019	20
WOMEN	T020	22
WOMEN	T021	4
WOMEN	T022	1
WOMEN	T023	13

**Tabla 59: MAPE por Tienda (1 a 12) y Género CHILDREN para el mes de marzo 2022 usando Prophet (en %)**

Género	Tienda	MAPE
CHILDREN	T001	3
CHILDREN	T002	23
CHILDREN	T003	27
CHILDREN	T004	21
CHILDREN	T006	2
CHILDREN	T007	24
CHILDREN	T008	12
CHILDREN	T009	19
CHILDREN	T010	0
CHILDREN	T011	31
CHILDREN	T012	32

**Tabla 60: MAPE por Tienda (13 a 23) y Género CHILDREN para el mes de marzo 2022 usando Prophet (en %)**

Género	Tienda	MAPE
CHILDREN	T013	4
CHILDREN	T014	12
CHILDREN	T015	27
CHILDREN	T016	22
CHILDREN	T017	2
CHILDREN	T018	0
CHILDREN	T019	23
CHILDREN	T020	14
CHILDREN	T021	25
CHILDREN	T022	16
CHILDREN	T023	27

**Tabla 61: MAPE por Tienda (1 a 12) y Género MEN para el mes de abril 2022 usando Prophet (en %)**

Género	Tienda	MAPE
MEN	T001	1
MEN	T002	0
MEN	T003	22
MEN	T004	18
MEN	T006	9
MEN	T007	6
MEN	T008	7
MEN	T009	5
MEN	T010	0
MEN	T011	8
MEN	T012	7

**Tabla 62: MAPE por Tienda (13 a 23) y Género MEN para el mes de abril 2022 usando Prophet (en %)**

Género	Tienda	MAPE
MEN	T013	7
MEN	T014	9
MEN	T015	9
MEN	T016	23
MEN	T017	46
MEN	T018	12
MEN	T019	16
MEN	T020	8
MEN	T021	3
MEN	T022	7
MEN	T023	4

**Tabla 63: MAPE por Tienda (1 a 12) y Género WOMEN para el mes de abril 2022 usando Prophet (en %)**

Género	Tienda	MAPE
WOMEN	T001	1
WOMEN	T002	9
WOMEN	T003	25
WOMEN	T004	18
WOMEN	T006	8
WOMEN	T007	4
WOMEN	T008	10
WOMEN	T009	15
WOMEN	T010	0
WOMEN	T011	2
WOMEN	T012	1

**Tabla 64: MAPE por Tienda (13 a 23) y Género WOMEN para el mes de abril 2022 usando Prophet (en %)**

Género	Tienda	MAPE
WOMEN	T013	2
WOMEN	T014	8
WOMEN	T015	11
WOMEN	T016	12
WOMEN	T017	20
WOMEN	T018	20
WOMEN	T019	17
WOMEN	T020	19
WOMEN	T021	3
WOMEN	T022	1
WOMEN	T023	11

**Tabla 65: MAPE por Tienda (1 a 12) y Género CHILDREN para el mes de abril 2022 usando Prophet (en %)**

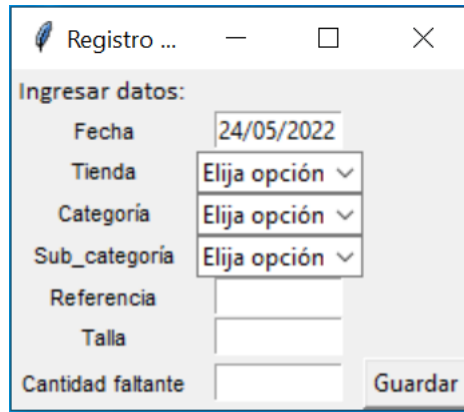
Género	Tienda	MAPE
CHILDREN	T001	3
CHILDREN	T002	20
CHILDREN	T003	23
CHILDREN	T004	18
CHILDREN	T006	2
CHILDREN	T007	21
CHILDREN	T008	10
CHILDREN	T009	16
CHILDREN	T010	0
CHILDREN	T011	27
CHILDREN	T012	28

**Tabla 66: MAPE por Tienda (13 a 23) y Género CHILDREN para el mes de abril 2022 usando Prophet (en %)**

Género	Tienda	MAPE
CHILDREN	T013	3
CHILDREN	T014	10
CHILDREN	T015	23
CHILDREN	T016	19
CHILDREN	T017	2
CHILDREN	T018	0
CHILDREN	T019	20
CHILDREN	T020	12
CHILDREN	T021	22
CHILDREN	T022	14
CHILDREN	T023	23

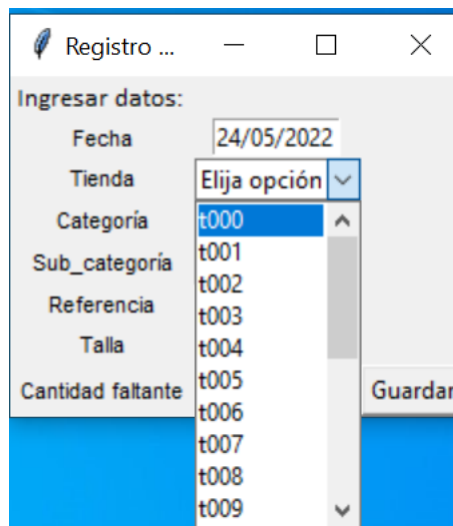
## Apéndice B. Herramienta de registro de quiebres de stock

- 1) Interfaz inicial, con la fecha del día seteada por default, con posibilidad de seleccionar la tienda, categoría, subcategoría (por medio de un dropdown con opciones), y mediante escritura manual, la referencia o sku, talla y cantidad faltante del producto en cuestión.



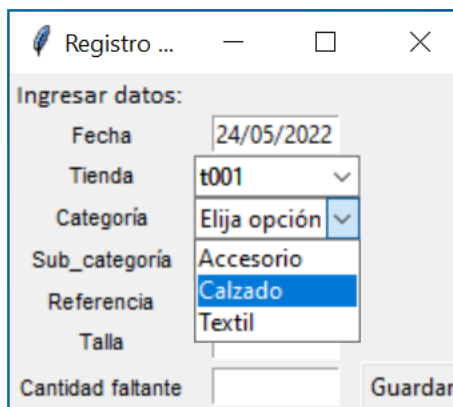
The screenshot shows a window titled "Registro ..." with a standard Windows title bar. Below the title bar, the text "Ingresar datos:" is displayed. The form contains several input fields: "Fecha" with the value "24/05/2022"; "Tienda", "Categoría", and "Sub\_categoria", each with a dropdown menu showing "Elija opción"; "Referencia", "Talla", and "Cantidad faltante", each with an empty text input field. A "Guardar" button is located at the bottom right of the form.

- 2) Se elige la tienda en la que se produjo el faltante para dejar registro.



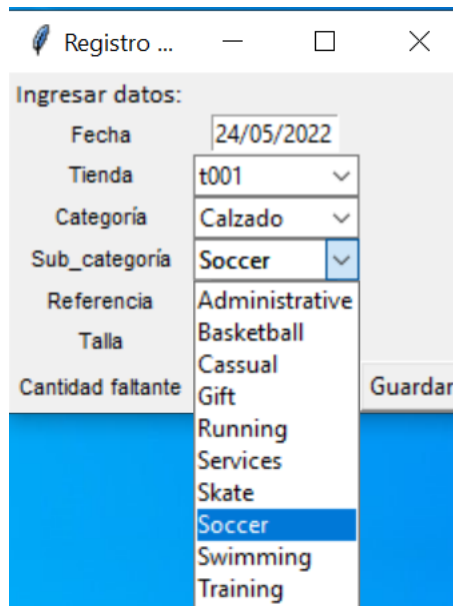
The screenshot shows the same window as the previous one, but the "Tienda" dropdown menu is open, displaying a list of options from "t000" to "t009". The "t000" option is currently selected and highlighted in blue. The other fields remain the same as in the previous screenshot.

- 3) Se elige la categoría del producto solicitado.



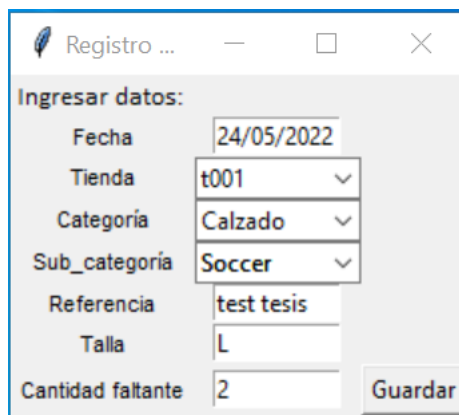
The screenshot shows the same window, but the "Categoría" dropdown menu is open, displaying a list of options: "Accesorio", "Calzado", and "Textil". The "Calzado" option is currently selected and highlighted in blue. The "Tienda" dropdown is now closed and shows "t001". The other fields remain the same as in the previous screenshot.

4) Se selecciona la subcategoría del producto en el menú desplegable.



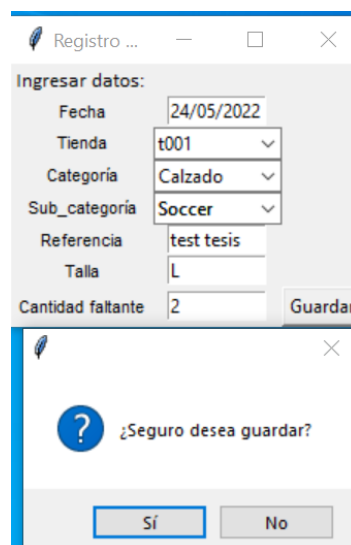
The screenshot shows a window titled 'Registro ...' with a form titled 'Ingresar datos:'. The form contains the following fields: 'Fecha' (24/05/2022), 'Tienda' (t001), 'Categoría' (Calzado), 'Sub\_categoria' (Soccer), 'Referencia' (Administrative), 'Talla' (Basketball), and 'Cantidad faltante' (Gift). A dropdown menu is open for 'Sub\_categoria', showing a list of options: Administrative, Basketball, Cassual, Gift, Running, Services, Skate, Soccer (highlighted), Swimming, and Training. A 'Guardar' button is visible on the right side of the form.

5) Se rellenan en forma manual los campos de referencia, talla y cantidad faltante.



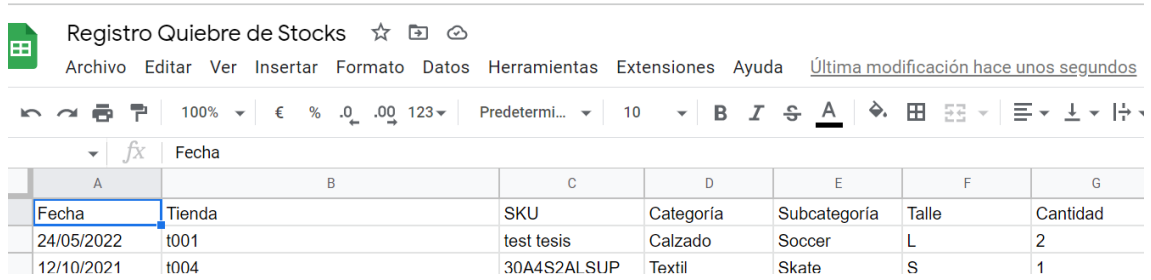
The screenshot shows the same 'Registro ...' window. The 'Referencia' field is now filled with 'test tesis', 'Talla' with 'L', and 'Cantidad faltante' with '2'. The 'Sub\_categoria' dropdown is now closed. The 'Guardar' button remains visible.

6) Una vez finalizado se presiona el botón guardar y aparecerá un mensaje de alerta para confirmar que desea almacenarse el registro. Se confirma y automáticamente se visualiza en el Google Sheets un nuevo registro con la fecha del día.



The screenshot shows the 'Registro ...' window with the form filled out as in the previous step. Below the form, a confirmation dialog box is displayed with the text '¿Seguro desea guardar?' and two buttons: 'Sí' and 'No'.

7) En la siguiente captura de pantalla del Google Sheets puede verse el registro en cuestión.



Registro Quiebre de Stocks ☆ 📄 🔄

Archivo Editar Ver Insertar Formato Datos Herramientas Extensiones Ayuda Última modificación hace unos segundos

100% € % .0 .00 123 Predetermi... 10 B I S A 🔍 📊 📈 📉 📊 📈 📉 📊 📈 📉

A	B	C	D	E	F	G
Fecha	Tienda	SKU	Categoría	Subcategoría	Taille	Cantidad
24/05/2022	t001	test tesis	Calzado	Soccer	L	2
12/10/2021	t004	30A4S2ALSUP	Textil	Skate	S	1