

**UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA**

**DEPARTAMENTO DE INDUSTRIAS**



**CUANTIFICACIÓN DEL IMPACTO ECONÓMICO DE LA AUDITORÍA  
DE CARTELERÍA PROMOCIONAL INACTIVA EN RETAIL DE  
MEJORAMIENTO DEL HOGAR.**

**MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL INDUSTRIAL**

**AUTOR**

**CARLOS SERVANDO LLANO TRECÁN**

**PROFESOR GUÍA**

**MARÍA PILAR GÁRATE**

**SANTIAGO, OCTUBRE DE 2025**



## CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

### 1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

**Tipo de monografía (marcar una opción):**  Memoria o trabajo de título  Tesis de Postgrado

**Título del trabajo:** Cuantificación del impacto económico de la auditoría de cartelería promocional inactiva en retail de mejoramiento del hogar.

**Nombre del candidato(a):** Carlos Servando Llano Trecán

**Carrera / Grado:** Ingeniería Civil Industrial

**Campus:** Santiago Vitacura **Departamento:** Industrias

### 2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, María Pilar Gárate Chateau, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución.

### 3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL (marcar una opción)

El trabajo **NO contiene** información que amerite confidencialidad y puede ser publicado de inmediato en repositorio con acceso abierto.

El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (**embargo**) por (**marcar una opción**):

6 meses  12 meses  2 años  3 años  5 años  10 años

**Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):**

---

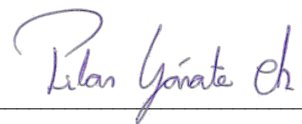
---

---

### 4.- FIRMAS

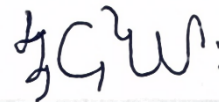
**Profesor(a) guía o director(a) de memoria o tesis:**

**Fecha:** 10.11.2025 **Firma:**



**Estudiante o Candidato(a):**

**Fecha:** 10.11.2025 **Firma:**



*Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.*

## RESUMEN EJECUTIVO

**Contexto y objetivo.** En el retail de mejoramiento del hogar, la cartelería fuera de vigencia genera fricción y riesgo de precio informado. Este estudio cuantifica el valor económico de auditarla robóticamente en una tienda (julio-2025), separando riesgo y eficiencia operativa.

**Método.** Integración de maestras de promociones, alertas del robot y saldos de stock en un panel SKU-tienda-día (regla  $D \rightarrow D+1$ ); modelos de riesgo ( $\Delta \text{precio} \times \text{venta\_proxy} \times p$ ) y eficiencia (HH ahorradas); sensibilidad en  $p$  (0,25/0,35/0,50).

**Resultados.** Se levantaron 1.381 alertas ( $\approx 48,6/\text{día}$ ). El riesgo mensual fue \$411.675 CLP ( $p=0,35$ ; rango \$294.054–\$588.108). La eficiencia alcanzó  $\sim 427$  HH (\$4.272.417 CLP a \$10.000/HH). Un barrido manual teórico demanda  $\sim 16,25$  h/día; la gestión por alertas reduce a  $\sim 24$  min/día y logra cierre total.

**Implicancias.** El caso se sostiene por una relación  $\approx 10:1$  (eficiencia  $\gg$  riesgo): la robótica libera HH para tareas que elevan experiencia y cumplimiento.

**Recomendaciones y alcances.** Implementar ritual  $D \rightarrow D+1$  (ejecutar alertas al día operativo posterior a detección), Top-10 ( $\Delta \text{precio} \times \text{venta\_proxy}$ ), y KPIs

**Limitaciones:** una tienda/un mes,  $\text{venta\_proxy}$  por baja de stock,  $p$  por escenarios.

**Futuro:** integrar POS, medir  $p$  por tipologías, escalar multi-tienda/mes.

Agradezco profundamente a mi madre y a mi abuela  
por estar siempre presentes durante este largo camino.

De igual manera, mi gratitud a Marlene Aravena,  
por su invaluable compañía y apoyo incondicional en todo el proceso.

## CONTENIDOS

RESUMEN EJECUTIVO.....	3
1. INTRODUCCIÓN .....	8
1.1. Contexto General.....	8
2. PROBLEMA DE INVESTIGACIÓN Y OBJETIVOS .....	11
2.1. Formulación del problema.....	11
2.2. Objetivo General.....	11
2.3. Objetivos específicos.....	11
2.4. Alcances.....	12
3. MARCO TEÓRICO Y CONCEPTUAL.....	13
3.1. Antecedentes.....	13
3.2. Promociones en retail .....	14
3.3. Excelencia operacional.....	20
3.4. Cartelería promocional .....	22
3.5. Modelos de medición de impacto y eficiencia .....	26
4. FUENTES E INTEGRACIÓN DEL PANEL.....	30
4.1. Inventario de fuentes .....	30
4.2. Esquema de joins y keys.....	32
4.3. Reglas de limpieza y exclusiones.....	33
4.4. Diccionario de variables .....	34

5.	METODOLOGÍA DE ANÁLISIS.....	36
5.1.	Construcción del panel SKU–tienda–día.....	37
5.2.	KPIs operativos.....	38
5.3.	Estimación de ventas .....	39
5.4.	Modelos de impacto.....	40
6.	RESULTADOS.....	44
6.1.	Principales resultados .....	44
6.2.	Serie diaria de riesgo .....	45
6.3.	Concentración por SKU.....	46
6.4.	Eficiencia operativa .....	47
6.5.	Hallazgos y oportunidades.....	50
7.	DISCUSIÓN.....	51
7.1.	Lectura integrada de resultados .....	51
7.2.	Patrones observados .....	52
7.3.	Implicancias para la operación .....	52
7.4.	Alcance y extrapolación .....	53
8.	CONCLUSIONES .....	54
9.	LIMITACIONES .....	55
9.1.	Limitaciones .....	55
9.2.	Líneas de trabajo futuro.....	55

10.	REFERENCIAS .....	57
11.	ANEXOS .....	59
11.1.	Anexo A. Código – Pipeline de datos y gráficos.....	59

# 1. INTRODUCCIÓN

## 1.1. Contexto General

El retail chileno cumple un rol económico y social de primera línea. Además de su peso macroeconómico —diversas fuentes estiman que el comercio minorista y actividades asociadas explican del orden de una quinta parte del PIB en años recientes—, es un gran empleador y un termómetro del ánimo de los hogares. Tras el ajuste post-pandemia, los indicadores oficiales muestran una recuperación del dinamismo: el Índice de Actividad del Comercio creció en torno a 5% interanual en agosto de 2025 (Instituto Nacional de Estadísticas (INE), 2025), y en paralelo, el canal digital retoma una senda de expansión durante 2025, retomó una senda de expansión de dos dígitos, reflejando una competencia intensa por precio, servicio y experiencia (Cámara de Comercio de Santiago (CCS), 2025).

El segmento de mejoramiento del hogar opera a gran escala. Una cadena líder de la región mantiene presencia con más de 260 tiendas en siete países. En Chile, su red supera las 80 tiendas (incluyendo formatos orientados a profesionales), mientras que Perú, Brasil, Colombia, México, Argentina y Uruguay completan la cobertura regional. Este nivel de operación exige procesos estables, medibles y repetibles para ejecutar correctamente promociones en piso de venta.

En ese escenario, la ejecución en sala dejó de ser una tarea de “buena práctica” para transformarse en una ventaja competitiva. Las tiendas de mejoramiento del hogar administran catálogos extensos, del orden de decenas de miles de SKU por local, con promociones que

cambian semana a semana y montajes físicos que requieren precisión: un cartel en la góndola en la fecha correcta, al precio correcto y en el lugar correcto. Cualquier desalineación entre lo planificado por marketing y lo que el cliente ve en tienda se traduce en fricción: ventas que no ocurren, márgenes que se erosionan o, peor aún, inconsistencias de precio exhibido versus cobrado que afectan la confianza y exponen a contingencias regulatorias (marco Ley 19.496 y obligaciones de información de precios y condiciones; BCN y SERNAC).

La transformación digital en tienda ha buscado precisamente cerrar esa brecha entre estrategia y ejecución. Al mismo tiempo, el auge del canal online impone un estándar más alto al mundo físico. La trazabilidad, la consistencia de la información y la velocidad de reacción que ya son habituales en e-commerce elevan la vara para la sala de ventas: si en digital el precio y la vigencia de una oferta se actualizan en minutos, el cliente espera una experiencia comparable en la góndola física. De ahí que la auditoría sistemática de cartelería promocional cobre relevancia no sólo como herramienta de eficiencia, sino como resguardo de la promesa al consumidor.

Las promociones son una palanca central de la propuesta comercial: acercan precio, aceleran rotación y atraen tráfico. Pero su último metro ocurre en la góndola, donde la señalización materializa la oferta para el cliente. Un cartel vencido no solo erosiona el beneficio esperado de la promoción, también puede generar costos operativos (correcciones, devoluciones, ajustes) y exponer a riesgos reputacionales por la inconsistencia de precios y riesgos regulatorios (Servicio Nacional del Consumidor (SERNAC), s.f.). Por eso, medir y mejorar

la ejecución en sala no es accesorio, si no que impacta directamente en ventas, costos y experiencia de cliente.

Con lo anterior, esta memoria aborda una pregunta simple y a la vez central para el negocio: ¿cuánto valor económico genera, para una cadena de mejoramiento del hogar en Chile, la auditoría robótica de la cartelería promocional, con foco en las promociones inactivas?

## **2. PROBLEMA DE INVESTIGACIÓN Y OBJETIVOS**

### **2.1. Formulación del problema**

A partir de lo anterior, el problema que aborda esta memoria es: ¿cuánto valor económico genera la auditoría robótica de cartelería promocional inactiva?

- Mitigación de riesgo por cartelería inactiva (diferencia de precio  $\times$  unidades potencialmente expuestas  $\times$  fracción de exposición).
- Eficiencia operativa (horas-hombre ahorradas por sustituir/dirigir auditorías manuales).

### **2.2. Objetivo General**

Diseñar y aplicar una metodología reproducible, basada en datos, para cuantificar el valor económico de auditar robóticamente la cartelería promocional inactiva, integrando lecturas robóticas diarias con maestros de promociones y stock, construyendo un panel SKU–tienda–día, aplicando modelos de riesgo y de eficiencia, a fin de medir desempeño y optimizar la gestión operativa en tienda.

### **2.3. Objetivos específicos**

1. Recopilar y documentar las fuentes (APIs y datasets) de promociones, stock y alertas, y tiempos de trabajo en tienda.
2. Tratar y unificar los datos para construir un panel SKU–tienda–día con reglas y exclusiones definidas.

3. Establecer e implementar los modelos de riesgo por cartelería inactiva ( $\Delta\text{precio} \times \text{venta\_proxy} \times p$ ) y eficiencia operativa (HH ahorradas).
4. Evaluar el impacto económico.
5. Generar una metodología reproducible, que permita escalar a otras tiendas/periodos.

#### 2.4. Alcances

- Se consideran descuentos directos ( $\text{precio}_{oferta} < \text{precio}_{normal}$ ). Otras mecánicas (p. ej., 2×1, paquetes promocionales, cupones) quedan fuera del alcance al no contar con reglas homogéneas en los datasets disponibles.
- Horizonte: tienda ubicada en Osorno durante julio de 2025, tienda con datos más estables y reproducibles. La metodología es escalable a otros periodos y tiendas cuando se disponga de datos equivalentes.
- Regla D→D+1: la lectura nocturna del robot del día D se contrasta con la maestra de promociones cargada esa misma noche D; las alertas generadas se gestionan y analizan en el día operativo D+1.
- No se cuenta con datos de venta, la demanda diaria se aproxima mediante la baja de stock entre  $t$  y  $t + 1$ . Aumentos de saldo por reposición o ajustes se excluyen para evitar sobreestimar ventas.
- Domingos: se excluyen por cobertura de navegación y para mantener consistencia en la comparabilidad diaria.

### 3. MARCO TEÓRICO Y CONCEPTUAL

#### 3.1. Antecedentes

Este proyecto nace de la operación diaria de una solución robótica en una cadena de mejoramiento del hogar en Chile. Cada noche, un robot recorre los pasillos, captura imágenes y transforma lo observado en registros estructurados sobre el estado de góndola; esa información queda disponible a primera hora del día siguiente para que los equipos de tienda actúen. En paralelo a otros frentes ya auditados: diferencias de precio, quiebres y HUAs (etiquetas de posición), en 2025 se incorporó la auditoría de cartelería promocional como un nuevo flujo de trabajo, con foco en detectar carteles promocionales inactivos (vigencias vencidas).

La necesidad es práctica: en tiendas que albergan del orden de 20 mil SKUs por local, y la cartelería promocional se encuentra en el orden de las mil promociones, y asegurar a diario que toda la cartelería promocional esté correctamente implementada y vigente resulta, en la práctica, inviable de cubrir de forma manual y sostenida. La automatización de la observación en sala permite pasar de muestreos puntuales a una digitalización diaria, con cobertura amplia y trazabilidad por SKU, pasillo y fecha. Ese cambio de escala habilita no solo mejorar la ejecución en góndola, sino también medirla con consistencia y aprender de sus patrones.

En términos simples, el servicio de robótica funciona así: cada local dispone de un robot que combina una base móvil con una torre de cámaras y cómputo embarcado; durante la noche recorre los pasillos, captura imágenes y extrae datos estructurados de quiebres, precios,

ubicaciones, entre otros. Esa información se procesa en la nube y, a la mañana siguiente, alimenta dashboards y alertas accionables para el equipo de tienda. La digitalización de la góndola habilita observación diaria y trazable, reduciendo ceguera operativa y priorizando correcciones (Clase Ejecutiva UC (Pontificia Universidad Católica de Chile), s.f.).

### **3.2. Promociones en retail**

Las promociones son una herramienta táctica que, bien diseñada y ejecutada, conecta la intención comercial con la experiencia real del cliente en la góndola. No se limitan a “bajar un precio por unos días”: involucran una mecánica, una vigencia, condiciones explícitas y, sobre todo, una comunicación clara en el punto de venta.

#### **3.2.1. Definiciones.**

Se sintetizan definiciones. (Blattberg & Neslin, Sales Promotion: Concepts, Methods, and Strategies, 1990)

- Promociones: es la componente de marketing mix que usa materiales y técnicas diseñadas para acelerar las funciones de venta y compra a lo largo de la cadena.
- Precio: valor habitual de transacción del SKU (sin oferta).

- Oferta: beneficio temporal (por ejemplo, descuento porcentual o monto fijo). Para efectos de este proyecto, sólo se consideran promociones que aplican un descuento directo al precio normal (porcentaje o monto fijo); no se incluyen, en esta fase, otras mecánicas como 2x1, paquetes, regalos con compra o *gift with purchase*, cupones o cuotas sin interés. Esta delimitación refleja cómo están estructuradas nuestras maestras y podría ampliarse en trabajos futuros a otros formatos.
- Publicidad: comunicación para informar/atraer; puede apoyar a la promoción, pero no la sustituye en la góndola.
- Vigencia y condiciones: periodo “desde–hasta”, cobertura (tienda/sitio), exclusiones, stock sujeto a disponibilidad, elegibilidad.
- Señalización: material en sala (flejes, colgantes, carteles) y su correspondencia con el SKU exacto y el precio comunicado.

Delimitación de este proyecto: sólo se consideran promociones efectivamente señalizadas mediante cartel en góndola; promociones sin cartel físico visible (p. ej., anunciadas solo en canales digitales u otras mecánicas) quedan fuera del alcance.

### 3.2.2. Objetivos de una promoción.

Más allá de “vender más”, las promociones cumplen propósitos distintos según la categoría, la estacionalidad y la estrategia comercial. En términos simples, buscan acercar una propuesta de valor clara al cliente en el momento y lugar de la decisión de compra (Blattberg & Neslin, Sales Promotion: Concepts, Methods, and Strategies, 1990).

- Generar tráfico y/o convertir. Atraer visitas a la tienda y facilitar que la compra se concrete en góndola. En categorías de reposición frecuente, pequeñas diferencias en precio visible suelen inclinar la decisión. *Ejemplo:* cabecera con -15% en brocas SDS+ por 7 días, destacada con cartel y precio final.
- Liquidar inventario y liberar espacio. Reducir saldos estacionales o de baja rotación para dar cabida a surtidos nuevos o de mayor contribución (Blattberg, Briesch, & Fox, How Promotions Work, 1995). *Ejemplo:* -40% en ventiladores la última semana de verano para rotar remanentes y recibir calefactores.
- Ganar participación y penetración. Aumentar el *share* de marca/categoría y llegar a más hogares; en muchos casos, la promoción actúa como puerta de entrada para probar un SKU. *Ejemplo:* -20% en pintura látex marca propia (1 galón) con isla secundaria para captar clientes que antes elegían marcas líderes.

- Acompañar lanzamientos y prueba. Disminuir la barrera de adopción inicial, reforzando la señal de novedad en el punto de venta. *Ejemplo:* -10% primeras 2 semanas en taladro brushless recién lanzado, con demo de producto en horario punta.
- Mejorar la percepción de precio (price image). Sostener una imagen competitiva sin comprometer el margen estructural, concentrando el esfuerzo en referencias clave. *Ejemplo:* cartelera de “precios bajos todos los días” en SKUs faro (cemento, plancha OSB, tornillos) y promociones tácticas en fines de semana.

En todos los casos, la ejecución en góndola es decisiva: sin un cartel visible, correcto y vigente, incluso la mejor mecánica pierde efecto.

### **3.2.3. Comportamientos inducidos en consumidores.**

Estos muestran patrones que se repiten y que ayudan a interpretar los resultados en tienda. En categorías con sustitución, las promociones afectan marca elegida, probabilidad de compra y cantidad adquirida (Bucklin & Gupta, 1992), además, algunas promociones dejan efectos persistentes en la elección de marca (Mela, Gupta, & Lehmann, 1997).

- Aceleración de compra y *stockpiling*. El cliente adelanta compras futuras cuando percibe una oportunidad clara, el efecto es mayor con descuentos profundos y

señalización nítida. Las rebajas pueden gatillar acumulación de inventario del consumidor y acelerar compras (Hendel & Nevo, 202).

- Cambio de marca y canibalización. Ante varias alternativas similares, la promoción puede desplazar demanda hacia el SKU mejor señalado o con mayor beneficio económico.
- Cambio de establecimiento. Si la propuesta percibida en precio/señalización es superior a la de un competidor, algunas compras migran hacia la tienda con mejor ejecución.
- Expansión de categoría y efectos halo. Parte del incremento puede provenir de canastos más grandes o de productos complementarios que “viajan” con el SKU en promoción.

Estos efectos no son uniformes: dependen de la profundidad del descuento, la mecánica, la estacionalidad, la elasticidad de la categoría y, especialmente, de la calidad de la señalización en góndola (en este proyecto, sólo promociones con cartel).

#### **3.2.4. Indicadores operativos y de desempeño.**

Para gestionar y aprender de las promociones conviene monitorear, al menos, lo siguiente:

- Profundidad del descuento. Diferencia absoluta y porcentual respecto del precio habitual; ayuda a contextualizar el potencial de respuesta.
- Rotación en vigencia y residuo post-promoción. Qué parte del inventario se mueve durante la ventana y cuánto queda por liquidar al cierre.
- Cumplimiento en góndola. Presencia del cartel correcto, en el lugar correcto y en la fecha correcta; es el puente entre la intención y lo que el cliente realmente ve.
- Alcance/visibilidad. Ubicaciones secundarias, cabeceras o islas que amplifican la exposición del mensaje.
- Tiempos de corrección. Rapidez con que tienda detecta y resuelve desalineaciones (desde la alerta hasta la normalización).

En síntesis, una promoción efectiva no es sólo un precio atractivo: requiere vigencia y condiciones claras, señalización precisa y visible y coherencia entre lo planificado y lo que el cliente observa en sala. En las secciones siguientes conectamos estas piezas con la excelencia operacional y proponemos modelos para cuantificar su impacto.

### **3.3. Excelencia operacional**

La ejecución en sala es decisiva para conectar lo planificado con lo que el cliente ve (Drèze, Hoch, & Purk, 1994). En promociones con descuento directo y cartel (alcance de este proyecto), la excelencia operacional se juega en tres frentes: montaje y retiro oportuno de cartelera, consistencia entre el precio informado y el cobrado, y capacidad de medir y mejorar el proceso con indicadores confiables. La visibilidad (posición/altura) y el número de facings modulan la atención y la evaluación en el punto de venta (Chandon, Hutchinson, Bradlow, & Young, 2009). Mover un SKU a posiciones de mayor visibilidad suele producir aumentos medibles en ventas (Measuring the Impact of Shelf Position on a Retailer's Sales).

#### **3.3.1. Montaje y retiro de cartelera.**

Implementar y retirar miles de carteles en una tienda de mejoramiento del hogar es una tarea intensiva en tiempo y coordinación. La carga se concentra en ventanas cortas (cambios semanales, fines de semana, campañas estacionales) y compite con otras prioridades de piso. Esto introduce variabilidad en quién, cuándo y cómo se ejecuta, lo que aumenta la probabilidad de errores, como cuando no se retiran a tiempo (carteles promocionales inactivos).

Ejemplo: si un lote de 300 carteles de pintura debe desmontarse entre el jueves noche y el viernes AM, una desviación de 24 horas deja sin actualizar la mayor parte de promociones vencidas.

### **3.3.2. Precio exhibido vs. cobrado.**

El principio de precio informado exige coherencia entre lo que el cliente ve en la góndola y lo que paga en caja. Cuando un cartel permanece fuera de vigencia, se genera un riesgo económico directo (diferencia entre precio oferta y precio normal que la tienda podría terminar respetando) y un costo indirecto en tiempo de colaboradores (gestión del error, notas de crédito) y en confianza del cliente. Por eso, más que un problema aislado, las “inactivas” son una fuente recurrente de desperdicio operativo.

### **3.3.3. Medición y mejora.**

Los *benchmarks* externos de merchandising rara vez son comparables entre cadenas y formatos. En esta memoria se privilegia la medición interna, apoyada en lecturas robóticas diarias (regla D→D+1 y exclusión de domingos):

- Horas-hombre sustituidas por la auditoría robótica, estimando el tiempo de “barrido” manual.
- Tiempos de resolución de alertas: días desde que aparece una faltante/inactiva hasta su cierre.
- Cobertura efectiva: relación entre pasillos efectivamente escaneados y planificados, para contextualizar las tasas.
- First-Time Fix (FTF): proporción de alertas corregidas en el primer día hábil posterior.

- Backlog de alertas: cantidad de alertas de promoción inactivas, acumuladas por más de  $n$  días.
- Reincidencia: % de SKUs que vuelven a presentar la misma alerta en 14 días.

En síntesis, la excelencia operacional en promociones no depende sólo de “poner carteles”, sino de hacerlo a tiempo, retirarlos cuando corresponde, asegurar la consistencia de precio y cerrar el ciclo con medición. Estos elementos se conectan directamente con los modelos que alimentan (i) el cálculo de horas-hombre ahorradas y (ii) la valoración del riesgo por inactivas.

### **3.4. Cartelería promocional**

En la operación diaria de una tienda, una promoción funciona cuando concurren tres condiciones: visibilidad (cartelería presente en el lugar correcto), vigencia (dentro de sus fechas) y consistencia (precio comunicado = precio cobrado). Cuando cualquiera de estas piezas falla, la estrategia diseñada en oficina no alcanza a materializarse en la góndola y el resultado es previsible: oportunidades de venta que no se concretan, márgenes que se erosionan y clientes que desconfían de la información de precio. En términos de excelencia operacional, estas fallas constituyen desalineamientos de ejecución en sala que aumentan costos, generan retrabajos y afectan la experiencia del cliente.

En este marco, las dos desviaciones más frecuentes son: (a) cartelera promocional faltante y (b) cartelera promocional inactiva. La primera ocurre cuando la promoción está declarada en la maestra (SKU, precio oferta y fechas), pero no hay un cartel visible en góndola. La segunda se presenta cuando permanece visible un cartel con fechas vencidas o con condiciones ya no vigentes. Ambas deterioran el vínculo entre el precio informado y el precio cobrado y, por ende, la confianza del cliente y los resultados del negocio.

### **3.4.1. Cartelería faltante**

Se da cuando la promoción está declarada en la maestra (con su SKU, precio oferta y fechas), pero no hay un cartel visible en la góndola. No hablamos aquí de quiebres de stock ni de productos mal ubicados, sino del soporte físico que comunica la oferta al cliente. Las causas típicas incluyen montajes tardíos, retiro accidental de material, rotura del cartel, cambios de planograma no reflejados en cartelera o simplemente saturación de tareas en piso de venta.

La ausencia del cartel reduce la probabilidad de que el cliente perciba la oferta y, con ello, el *sales lift* esperado. En categorías de compra por impulso o alta sustitución, la pérdida se manifiesta como menores unidades vendidas o como canibalización hacia SKUs con mejor señalización. En categorías de compra planificada, la falta de cartel añade fricción (el cliente busca al asociado, valida precio en tótem o posterga la compra), afectando conversión y experiencia.

### **Limitaciones de datos que impiden su cuantificación.**

(i) No existe una forma de verificar que confirme la ausencia de cartel por SKU-día con la frecuencia necesaria, (ii) la detección de “no presencia” requiere supuestos fuertes sobre cobertura de navegación y ángulos de cámara, (iii) no se dispone de los datos de venta para estimar lifts atribuibles, (iv) el cruce con planogramas finos no forma parte del dataset de este estudio. Por estas razones, la cartelería faltante queda fuera del alcance.

#### **3.4.2. Cartelería inactiva**

Ocurre cuando permanece visible un cartel con fechas vencidas o condiciones ya no vigentes. A primera vista parece un error menor, pero su alcance es amplio: confunde al cliente, obliga a correcciones en caja (notas de crédito o cambios de precio), consume tiempo del equipo de tienda y expone a la organización a riesgos regulatorios por incumplimiento del principio de precio informado y deber de información sobre condiciones de la oferta (Biblioteca del Congreso Nacional de Chile (BCN), s.f.).

Componentes: **(i) directo**, si se termina respetando el precio comunicado en el cartel vencido (diferencia entre precio informado y precio vigente), y **(ii) indirecto**, por el impacto en satisfacción y confianza del cliente, además del costo interno de gestionar el error (tiempo de colaboradores y jefaturas para corregirlo).

### **Detección operativa.**

El robot observa cartelera en góndola y, al cruzarla con la maestra de promociones del día correspondiente, identifica cuando la promoción ya no debería estar activa. En concreto, se aplica la regla  $D \rightarrow D + 1$ : la lectura nocturna del día  $D$  se contrasta con la maestra cargada esa misma noche  $D$ , las alertas generadas se trabajan el día operativo  $D + 1$ . En los datos, `session_date` ya corresponde a  $D + 1$  (día operativo), y la maestra usada en la valoración es  $file\_date = session\_date - 1 \text{ día}$ .

Para minimizar falsos positivos, este estudio: (a) restringe el análisis a descuentos directos ( $precio_{oferta} < precio_{normal}$ ); (b) deduplica múltiples carteles del mismo SKU en un mismo día (una alerta por SKU-día); (c) excluye domingos por cobertura irregular; y (d) utiliza baja de stock entre días como proxy de unidades potencialmente expuestas en la valoración del riesgo.

### **Justificación del foco.**

A diferencia de la cartelera faltante, la condición de inactiva puede instrumentarse con reglas de negocio claras y trazables a partir de los datasets disponibles (alertas, maestra de promociones y stock).

### 3.5. Modelos de medición de impacto y eficiencia

A continuación, se presentan los dos componentes de valor alineados con el alcance del estudio. Para cada bloque se indica qué medimos, cómo lo calculamos y un ejemplo para fijar ideas.

#### 3.5.1. Eficiencia operativa

Consideraremos las HH ahorradas, como el tiempo de trabajo en tienda que deja de invertirse en auditorías manuales gracias a la observación robótica diaria y a la priorización con alertas.

##### Fórmula base

$$HH_{ahorradas_t} = \frac{\left( (t_{manual} \times N_{totalpasillos_t}) - (t_{conrobot} \times N_{pasillosconalerta_t}) \right)}{3600}$$

Donde  $t_{manual}$  es el tiempo promedio (en segundos) para auditar un pasillo sin robot y  $t_{conrobot}$  es el tiempo real invertido por pasillo con alertas cuando se opera con robot (p. ej., revisar alertas y ejecutar correcciones).  $N_{totalpasillos_t}$  es el total de pasillos auditables/cubiertos ese día y  $N_{pasillosconalerta_t}$  es el número de pasillos con al menos una alerta activa ese día.

Si se dispone de métricas por carteles en lugar de pasillos, la misma lógica se aplica reemplazando  $N_{total\_pasillos_t}$  por  $N_{carteles_t}$  y  $N_{pasillos\_con\_alerta_t}$  por  $N_{carteles\_con\_alerta_t}$ , junto con los tiempos de gestión de los carteles.

### **Agregación y valorización.**

$$Valor_{HH} = (\Sigma_t HH_{ahorradas_t}) \times Costo_{hora}$$

( $\Sigma$  en días válidos, sin considerar resultados días domingos).

### **Parámetros a levantar.**

- $t_{manual}$ : tiempo de auditoría manual por pasillo.
- $t_{con\_robot}$ : tiempo de gestión de alertas con uso de datos de robot.
- $N_{total\_pasillos_t}$ : pasillos recorridos/universo auditado.
- $Costo_{hora}$ : valor de la hora de trabajo de los colaboradores en tienda.

### **3.5.2. Mitigación de riesgo por cartelería inactiva.**

Es el valor económico esperado producto del precio cuando un cartel queda visible y fuera de vigencia, fuente de devoluciones/ajustes y pérdida de confianza. De acuerdo a la literatura, Los impactos suelen concentrarse en pocos SKU y días (van Heerde, Leeflang, & Wittink, 2004).

### Condición en datos.

Se considera que el evento ocurre cuando existe una alerta del robot para el SKU  $i$  el día  $t$  ( $inactive_{flag_{it}} = 1$ ). Operativamente, ese  $t$  corresponde a  $results_{date} = session_{date}$  (día operativo  $D+1$ ), y la promoción relevante es la de la maestra del día  $D$  ( $file_{date} = session_{date} - 1$ ). En términos de vigencia, equivale a que  $results_{date}$  esté fuera del intervalo  $[desde, hasta]$  de la promoción.

### Fórmula

$$Riesgo_{it} = p_{exposicion_{it}} \times \Delta precio_i \times unidades_{potenciales_{it}}$$

con  $\Delta precio_i = (precio_{normal_i} - precio_{oferta_i}) > 0$ .

### Aproximación de unidades potenciales:

Dado que no contamos con los datos de ventas directas,  $unidades_{potenciales_{it}}$ , en su lugar usaremos  $venta_{proxy_{it}} = \max(0, stock_t - stock_{\{t+1\}})$ , es decir, la caída de stock que recibimos en las maestras de stock.

$p_{exposición_{it}}$ : Es la fracción de transacciones potenciales del SKU  $i$  en el día  $t$  que estuvieron expuestas al cartel que están en góndola (por ejemplo, un cartel inactivo). Toma valor entre 0 y 1.

- Muy visible (cabecera, alto flujo): usa un  $p$  más alto ( $\approx 0.5-0.8$ ).
- Poco visible (góndola baja, pasillo poco transitado): un  $p$  bajo ( $\approx 0.1-0.3$ ).

Ejemplo. Si  $\Delta\text{precio} = \$2.000$ ,  $\text{venta}_{\text{proxy}} = 5$  y  $p_{tx} = 0,5$ , entonces

$$\text{Riesgo} = 0,5 \times 2.000 \times 5 = \$5.000 \text{ para ese SKU-día.}$$

### 3.5.3. Análisis de sensibilidad.

El objetivo es acotar la incertidumbre y entregar rangos de riesgo esperado a nivel SKU-día, día y total mensual. Se evalúa cómo varía el resultado al modificar dos palancas:

- (i) La fracción de exposición  $p_{\text{exposición}}$  (0–1), que aproxima la proporción de transacciones potenciales expuestas al cartel inactivo. Para  $p_{\text{exposición}}$  se reportan escenarios {0,25; 0,35; 0,50}.

Ejemplo: si  $p_{\text{exposición}}$  aumenta de 0,25 a 0,50, el riesgo esperado se duplica manteniendo constantes  $\Delta\text{precio}$  y  $\text{venta}_{\text{proxy}}$ .

La metodología propuesta es reproducible y se apoya en precios y volúmenes operacionalmente observables (Jeldres, 2009).

## 4. FUENTES E INTEGRACIÓN DEL PANEL

### 4.1. Inventario de fuentes

Detallaremos las maestras de promociones (mensual y diaria), alertas de cartelería promocional (provenientes de lecturas robóticas), stock (saldos diarios) y cronometrajes de trabajo tomados en tienda.

#### 4.1.1. Maestra de promociones

Es el plano de referencia de cada promoción en tienda: indica qué SKU está en oferta, a qué precio, desde cuándo y hasta cuándo. Con ella determinamos elegibilidad (si una promoción debería estar visible) y comparamos con lo que el robot observa en góndola.

- Columnas:
  - sku\_promocion
  - precio\_normal
  - precio\_oferta
  - file\_date (fecha de carga de la maestra).
- Uso metodológico. Para una alerta con  $session\_date = D + 1$  (día operativo), se utiliza la maestra del día D (es decir,  $file\_date = session\_date - 1$  día). Esto respeta la regla  $D \rightarrow D+1$ : la lectura nocturna del día D produce las alertas que se gestionan en D+1.

- Ejemplo. Si  $session_{date} = 2025 - 07 - 02$ , la valoración usa la maestra con  $file_{date} = 2025 - 07 - 01$ .
- Reglas de negocio.
  - Se consideran descuentos directos (casos con  $precio_{oferta} < precio_{normal}$ ).
  - Se calcula  $\Delta precio = \max(0, precio_{normal} - precio_{oferta})$  y se descartan valores fuera de rango ( $\leq 0$  o no numéricos).
  - Si existieran duplicados por (sku\_promocion, file\_date), se conserva el registro más reciente o con información completa (precio\_normal y precio\_oferta presentes).

#### 4.1.2. Maestra de stock y assortment

El propósito de esta maestra es para estimar las unidades potencialmente vendidas mediante la baja de stock diaria.

- Columnas:
  - SKU
  - SALDO\_DISPONIBLE (unidades)
  - data\_file
- Proxy de venta:  $Venta_{proxy\_t} = \max(SALDO_{\{t\}} - SALDO_{\{t-1\}}, 0)$

- Cuando el saldo aumenta entre  $t$  y  $t+1$ , se interpreta como reposiciones/ajustes y no se contabiliza venta ese día ( $venta_{proxy_t} = 0$ ).

### 4.1.3. Alertas del robot – cartelería inactiva

Señal diaria de cartel fuera de vigencia detectado en góndola.

- Columnas:
  - Item (SKU)
  - session\_date.
  - Opcionales (si existen): aisle, bay, facing. Se utilizan para ubicar la alerta en la tienda.
- Semántica. Una alerta indica que, para el SKU del registro, el robot observó cartelería visible cuya vigencia no corresponde según la maestra del día D.
- Frecuencia y cobertura. Las alertas se generan todas las noches.
- Deduplicación. Un mismo SKU puede tener múltiples carteles en sala. Para evitar sobrecontar, se trabaja con una alerta por SKU-día para el cálculo de riesgo.

## 4.2. Esquema de joins y keys

- Llave del panel de trabajo: (location\_id, Item/SKU, results\_date).

- Calendario:  $results_{date} = session_{date}$  (el dataset de alertas ya etiqueta el día operativo D+1 como  $session_{date}$ ).
- Join con promociones:  $Item \leftrightarrow sku_{promocion}$  y  $file_{date} = session_{date} - 1$  día (maestra de la noche D).
- Join con stock:  $Item \leftrightarrow SKU$  y  $date_{file} = results_{date}$  (y  $date_{file} = results_{date} + 1$  para calcular  $venta_{proxy}$ ).

Ejemplo de fechas. Si  $session_{date} = 2025 - 07 - 02$  (maestra de alertas), entonces:  $results_{date} = 2025 - 07 - 02$ ; la maestra de promociones a su vez tiene la columna  $file_{date} = 2025 - 07 - 01$ ; la maestra de stock contiene  $date_{file} = 2025 - 07 - 02$  (y 2025-07-03 para la caída de stock).

Notas. Validar tipos de dato (fechas en formato fecha, precios numéricos) y normalizar mayúsculas/minúsculas en claves.

### 4.3. Reglas de limpieza y exclusiones

Objetivo: garantizar que se calculen con días comparables y lecturas confiables.

- Excluir domingos para homogeneidad de comparación diaria.

- Mantener descuentos directos ( $precio_{oferta} < precio_{normal}$ ) y  $\Delta precio > 0$ .
- Validar unicidad de la llave elegida y rangos plausibles de precio ( $precio_{normal} \geq precio_{oferta} > 0$ ).
- Deduplicar alertas múltiples del mismo SKU-día (conservar una por SKU-día para riesgo; mantener  $N_{alertas}$  para HH ahorradas).
- Normalizar tipos (fechas, numéricos) y limpiar nulos/espacios.

#### 4.4. Diccionario de variables

- $inactive_{flag_{it}}$  (0/1). Indicador binario que señala la presencia de cartelería inactiva para el SKU  $i$  en el día  $t$ . Toma valor 1 cuando el robot detecta material visible fuera de vigencia (según la maestra del día D), y 0 en caso contrario. En los datos,  $results_{date} = session_{date}$  (día operativo D+1) y la vigencia se contrasta con la maestra  $file_{date} = session_{date} - 1$ .

- $venta_{proxy_{it}}$  (u.). Aproximación de unidades potencialmente transadas para el SKU  $i$  en el día  $t$ , calculada como la baja de stock entre días consecutivos:

$$venta_{proxy_{it}} = \max(0, stock_t - stock_{\{t+1\}}).$$

Si el stock aumenta (reposiciones/ajustes), se fija en 0 para evitar sobreestimar.

- $\Delta precio_i$  (CLP/u.). Diferencia de precio positiva entre el precio normal y el precio oferta del SKU  $i$  en la maestra del día  $D$  (misma noche de lectura):

$$\Delta precio_i = \max(0, precio_{normal_i} - precio_{oferta_i}).$$

Se consideran descuentos directos ( $precio_{oferta} < precio_{normal}$ ) y se descartan valores fuera de rango o no numéricos.

- $p_{exposición_{it}}$  (0–1). Fracción de transacciones potenciales del SKU  $i$  en el día  $t$  que estuvieron expuestas a la cartelería inactiva. Depende de visibilidad (cabecera vs. góndola baja), flujo del pasillo y cobertura de navegación. En este trabajo se reportan escenarios de sensibilidad {0,25; 0,35; 0,50} como valores razonables para distintos contextos de exposición.

- $riesgo_{it}$  (CLP). Valor esperado del impacto económico para el SKU  $i$  en el día  $t$  ante la presencia de cartelería inactiva:

$$riesgo_{it} = \Delta precio_i \times venta_{proxy_{it}} \times p_{exposición_{it}}$$

Representa un potencial costo. Se agrega por SKU–día, día, SKU y total mensual.

Con las fuentes integradas y validadas, a continuación se describe el diseño del estudio y el procedimiento aplicado para cuantificar (i) riesgo por cartelería inactiva y (ii) eficiencia operativa

## 5. METODOLOGÍA DE ANÁLISIS

En esta sección se detalla cómo se construyen los datos, qué indicadores se obtienen y con qué modelos se cuantifica el impacto. La intención es que cualquier lector pueda replicar paso a paso el proceso, entendiendo los supuestos y sus implicancias.

- **Tipo de estudio.** Cuantitativo, no experimental, longitudinal (panel SKU–tienda–día).
- **Unidad de análisis.** SKU en tienda por día (granularidad SKU–tienda–día).
- **Ámbito y muestra.** Una tienda de mejoramiento del hogar en Chile, julio-2025; exclusiones operativas: domingos y días sin sesión válida.
- **Variables clave.**  $\Delta$ precio, venta\_proxy(baja de stock),  $p_{\text{exposición}}$  y HH.
- Modelos.
  - **Riesgo esperado:**  $\mathbb{E}[R_{it}] = \Delta p_{it} \times \text{venta\_proxy}_{it} \times p_{it}$ .
  - **Eficiencia operativa:** HH ahorradas por comparación entre barrido manual por pasillos y gestión por alertas.
- **Supuestos operativos.** Regla  $\mathbf{D} \rightarrow \mathbf{D}+1$  (sesión nocturna del día  $D$  aplica a  $D + 1$ ); normalizaciones de llaves (SKU $\equiv$ item), control de calidad de saldos y precios, y exclusiones documentadas.

## 5.1. Construcción del panel SKU–tienda–día

Objetivo. Formar un panel diario por SKU–tienda que reúna, para cada día operativo, la alerta del robot, los precios vigentes de la maestra y la variación de stock.

Pasos.

1. **Integración** del panel SKU–tienda–día (regla  $D \rightarrow D+1$ ; llaves y formatos).
2. **Limpiezas y QC**: fechas, duplicados, decimales, stock negativo (truncado/flags), exclusiones (domingos, faltantes).
3. **Cálculo de  $\Delta$ precio**:  $\Delta p = \max(0, \text{precio\_normal} - \text{precio\_oferta})$ .
4. **Cálculo de venta\_proxy**: por **baja de stock** diaria,  $\text{venta\_proxy}_t = \max(\text{saldo}_{t-1} - \text{saldo}_t, 0)$ .
5. **Exposición  $p$** : escenario **bajo/medio/alto** (0,25 / 0,35 / 0,50) o promedio ponderado por ubicaciones; aplicar  $\tau$  si la inactividad fue parcial.
6. **Riesgo esperado**: agregar por SKU–día y luego por mes/tienda.
7. **Eficiencia (HH)**:
  - **Base manual**:  $HH_t^{manual} = \frac{t_{barrido} \times P_t}{3600}$ .
  - **Por alertas**:  $HH_t^{alertas} = \frac{t_{alerta} \times N_{alertas,t}}{3600}$ .
  - **Ahorro**:  $HH_t^{ahorradas} = \max(0, HH_t^{manual} - HH_t^{alertas})$ .

- **Valorización:**  $\text{Valor}_{HH} = (\sum_t \text{HH}_t^{\text{ahorradas}}) \times \text{Costo}_{\text{hora}}$ .
8. **Sensibilidad:** reportar rango con  $p \in \{0,25,0,35,0,50\}$  y bandas/cuantiles de  $\Delta p$ .
  9. **Reproducibilidad:** pipeline, scripts y artefactos (csv/figuras).

Resultado. Un dataset a nivel SKU-día con:  $\text{results}_{\text{date}}, \Delta \text{precio}, \text{venta}_{\text{proxy}}$ .

## 5.2. KPIs operativos

El propósito es medir la salud de ejecución y orientar la gestión diaria.

- Tasa de alertas de promociones inactivas. Proporción de carteles observados que están fuera de vigencia.
- Backlog de inactivas  $\geq n$  días. Acumulado de alertas que persisten en días consecutivos. Requiere observar continuidad de la señal por SKU-día.
- Lead time de corrección (días). Días transcurridos entre la primera detección y la primera fecha en que deja de observarse la inactiva para ese SKU. Resume oportunidad de retiro.

- Reincidencia 14 días (%). Porcentaje de SKU que, una vez corregidos, reaparecen con inactiva en las dos semanas siguientes.
- Cobertura de navegación (%). Fracción de lineales/pasillos efectivamente recorridos por el robot. Se reporta junto a cada KPI para dar contexto a los resultados.

Nota. Para HH se emplean dos contadores del día  $t$ :  $N_{total\ pasillos_t}$  (universo auditado) y  $N_{pasillos\ con\ alerta_t}$  (pasillos con  $\geq 1$  alerta), además de  $N_{alertas_t}$  cuando se usa la variante “por alertas”.

### 5.3. Estimación de ventas

**Definición.** La variable  $venta_{proxy_{it}}$  aproxima la demanda diaria del SKU  $i$  como la baja de stock entre el día  $t$  y  $t+1$ :

$$venta_{proxy_{it}} = \max(0, SALDO_{\{t\}} - SALDO_{\{t+1\}}).$$

#### 5.3.1. Tratamiento de casos frecuentes.

- Reposiciones/ajustes. Si  $SALDO_{\{t+1\}} \geq SALDO_{\{t\}}$ , entonces  $venta_{proxy} = 0$  (no se infiere venta).

- Último día del mes. Puede no existir  $SALDO_{\{t+1\}}$ ; por consistencia, se imputa 0 o se excluye el último día del cómputo de ventas.

- Outliers. Saltos inusuales pueden recortarse (winsorizar) para evitar que unos pocos casos distorsionen los agregados.

## 5.4. Modelos de impacto

### 5.4.1. Mitigación de riesgo por cartelera inactiva

Cuando un cartel vencido permanece visible, existe un riesgo esperado de impacto económico. Se valora como:

$$riesgo_{\{it\}} = (\text{precio}_{normal_i} - \text{precio}_{oferta_i}) * \text{venta}_{proxy_{\{it\}}} * p$$

con  $p$  la fracción de exposición (escenarios  $\{0,25; 0,35; 0,50\}$ ).

Consideraciones:

- Usar  $\Delta\text{precio} > 0$ , una sola alerta por SKU-día, y excluir días con cobertura irregular.
- Agregar por SKU-día, día, SKU y total mensual para análisis táctico (priorizar SKU con alto  $\Delta\text{precio} \times \text{venta}_{proxy}$ ).

Interpretación. Es un valor esperado (potencial de costo), no necesariamente un cargo efectivo en caja; su magnitud orienta la priorización de retiro de cartel no vigente.

### 5.4.2. Eficiencia operativa (ahorro de HH)

#### Enfoque por pasillos (base metodológica).

$$HH_{ahorradas_t} = \frac{\left( (t_{manual} \times N_{totalpasillos_t}) - (t_{conrobot} \times N_{pasillosconalerta_t}) \right)}{3600}$$

- $t_{manual}$ : tiempo promedio para auditar un pasillo sin robot (segundos).
- $t_{conrobot}$ : tiempo promedio por pasillo con alertas (segundos), considerando revisión y retiro/corrección.
- $N_{totalpasillos_t}$ : universo auditable ese día.
- $N_{pasillosconalerta_t}$ : pasillos con  $\geq 1$  alerta ese día.

#### Variante operativa (por alertas).

Útil cuando la gestión se realiza alerta a alerta: reemplazar el segundo término por  $\frac{t_{alerta} \times N_{alertas_t}}{3600}$ . En los resultados de la tienda, se reporta esta variante además del cálculo por pasillos.

$$HH_{ahorradas_t} = \frac{\left( (t_{manual} \times N_{totalpasillos_t}) - (t_{alerta} \times N_{alertas_t}) \right)}{3600}$$

Donde  $t_{alerta}$  es el tiempo que considera la gestión de la alerta de la cartelería no vigente, usando la auditoría del robot.

### 5.4.3. Sensibilidad y escenarios

Acotar la incertidumbre del modelo explorando combinaciones de (i) exposición  $p$  y (ii) profundidad del descuento  $\Delta p$ :

#### **Exposición $p$ :**

Se trabajan tres escenarios representativos de visibilidad:

- Bajo:  $p = 0,25$
- Medio:  $p = 0,35$
- Alto:  $p = 0,50$

#### **Profundidad del descuento $\Delta p$ :**

- Por bandas ([0–100], [101–500], [ $>500$ ] CLP/u.)
- Por cuantiles (p25/p50/p75).

#### **Supuestos que sostienen los extremos del rango**

- Límite inferior (bajo): pasillos de bajo flujo y/o góndola baja; inactividad parcial; predominio de descuentos leves [0,100]CLP/u.
- Caso base (medio):  $p = 0,35$ , distribución empírica observada de  $\Delta p$ .

- Límite superior (alto): cabeceras/islas o pasillos de alto flujo; mayor peso relativo en >500 CLP/u.

## 6. RESULTADOS

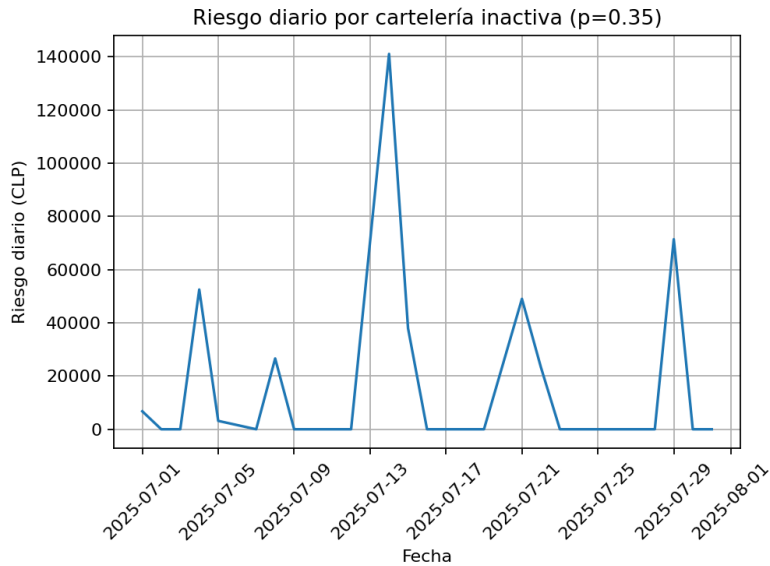
En esta sección se presentan los resultados obtenidos al ejecutar el pipeline del Anexo A sobre los tres archivos provistos para julio de 2025. Esta sección combina cifras, gráficos y un breve análisis operativo orientado a la toma de acción en tienda.

### 6.1. Principales resultados

- Alertas de cartelera inactiva (SKU-día): 1.381 en el mes.
- Riesgo económico total ( $p = 0,35$ ): \$411.675 CLP.
- Sensibilidad (fracción de exposición):
  - rango \$294.054 ( $p = 0,25$ ) –\$588.108 ( $p = 0,50$ )
- Promedio de alertas por día:  $\approx 48,6$  alertas.
- Ahorro operativo total: 427,24 h  $\rightarrow$  \$4.272.417 CLP.

Estas magnitudes sitúan el impacto en dos planos: un riesgo económico directo (precio exhibido fuera de vigencia) y una ganancia de eficiencia al gestionar por alertas, en lugar de auditar exhaustivamente cada pasillo.

## 6.2. Serie diaria de riesgo



**Figura 1** Riesgo diario por cartelería inactiva ( $p = 0,35$ )

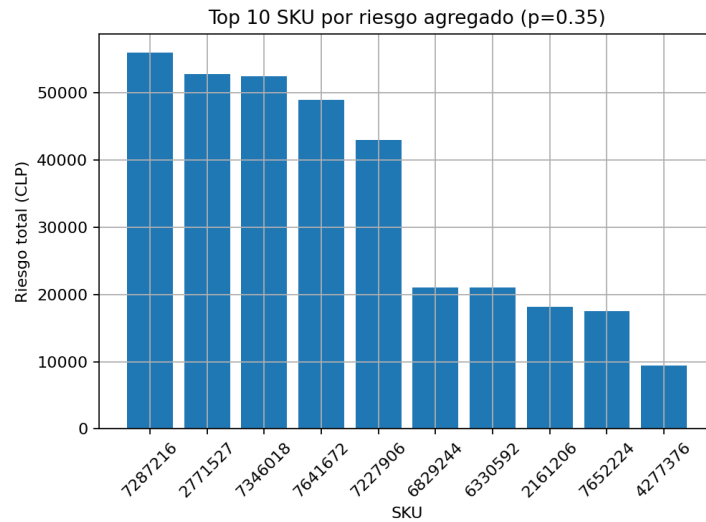
*Descripción:* serie espigada con picos acotados en pocos días, coherente con acumulación de carteles vencidos que persisten y luego se corrigen.

Muestra el riesgo diario (escenario  $p = 0,35$ ). La serie es marcadamente espigada: la mayor parte de los días el riesgo es bajo o nulo, pero se observan picos bien definidos. Este patrón es coherente con la dinámica operativa: un conjunto acotado de alertas de promociones inactivas con alto ( $\Delta precio$ ) y venta proxy puede concentrar el valor esperado en pocas jornadas, por ejemplo, cuando varios carteles vencidos persisten y se cruzan con días de mayor rotación. Los impactos suelen concentrarse en pocos SKU y días, coherentes con el ‘promotion bump’ (van Heerde, Leeflang, & Wittink, 2004).

### 6.2.1. Implicancia práctica.

Los picos sugieren priorizar tareas de retiro al día siguiente de la detección y reforzar la cobertura en fechas críticas (fin de vigencias, cambios de folletos o campañas). También es útil revisar la reincidencia de aquellos SKU que reaparecen con inactiva tras la corrección.

### 6.3. Concentración por SKU.



**Figura 2.** Top-10 SKU por riesgo agregado ( $p = 0,35$ ) *Descripción:* pocos SKU concentran una fracción relevante del riesgo mensual (regla 80/20).

A modo ilustrativo, el ranking lo encabezan SKU 7287216 (Freezer), 2771527 (Escalera), 7346018 (Secadora) y 7641672 (lavadora), todos con valores de riesgo en el orden de decenas de miles de CLP cada uno. En conjunto, este grupo concentra una fracción relevante del total mensual, lo que confirma una pauta común en retail: pocos SKU (los de mayor descuento y mayor salida) explican gran parte del problema.

SKU	riesgo_p35	venta_proxy	delta_precio
7287216	56.000	1	160.000
2771527	52.850	1	151.000
7346018	52.500	2	160.000
7641672	49.000	1	140.000
7227906	43.050	2	123.000
6829244	21.000	1	60.000
6330592	21.000	1	60.000
2161206	18.200	27	4.000
7652224	17.500	5	10.000
4277376	9.380	4	6.700

**Tabla 1** resumen el Top-10 de SKU por riesgo agregado ( $p = 0,35$ ).

Se sugiere construir un checklist semanal con los SKU del Top-10 y sus sustitutos cercanos para verificar retiro del material vencido y prevenir reincidencias.

#### **6.4. Eficiencia operativa**

Desde la operación, el robot evita dedicar tiempo a auditorías de barrido y focaliza el esfuerzo en la gestión de alertas. Con los parámetros obtenidos en tienda, en pruebas cronometradas

( $t_{alerta} = 30 \frac{s}{alerta}$ ,  $\approx 48,6 \frac{alertas}{día}$ ,  $Costo_{hora} = \$10.000$ ), el ahorro observado para el mes asciende a 427,24 h, equivalente a \$4.272.417 CLP.

#### 6.4.1. HH mediante trabajo manual

- Tiempo en gestionar manualmente cada pasillo, y considerando 65 pasillos, se calcula el tiempo total en revisar manualmente toda la tienda:

$$t_{revisar\_pasillo} = 15 \frac{min}{pasillo}, N_{total\ pasillos} = 65$$

$$HH_{manual} = 65 \times 15 \text{ min} = 975 \text{ min} \approx 16,25 \text{ h.}$$

De forma equivalente, si se usa el promedio de  $1.010 \frac{promociones}{día}$  y  $1 \frac{min}{promoción}$  serían  $\approx 1010 \text{ min} \approx 16,83 \text{ h.}$

- La carga supera con creces el máximo operativo disponible ( $\sim 1,5 \frac{h}{día}$ ), por lo que la auditoría manual completa no es practicable.

### 6.4.2. HH con robot y gestión por alertas

Considerando el tiempo en gestionar una alerta y la cantidad de alertas diarias generadas en promedio:

$$t_{alerta} = 30 \frac{s}{alerta}, N_{alertas} \approx \frac{48,6}{día}$$

Entonces, las HH mediante auditoría robótica corresponde a:

$$HH_{robot} = 48,6 \times 30 s = 1.458 s \approx 24,3 min.$$

### 6.4.3. Tiempo y valorización ahorro por gestión robótica.

- Ahorro diario estimado (variante por alertas):  $HH_{ahorradas_{día}} \approx 16,25 h - 0,405 h \approx 15,85 h$ .
- Valorización: con  $Costo_{hora} = \$10.000$ ,  $Valor_{HH_{día}} \approx \$158.500$ . Proyección mensual (27 días operativos):  $HH \approx 427,24 h \rightarrow Valor \approx \$4.272.417$ .

El contraste con la carga manual teórica ( $\approx 16,25$  h/día si se auditara el universo de 65 pasillos) muestra que, sin robot, la revisión total es impracticable dentro de la ventana disponible ( $\sim 1,5$  h/día). La automatización no sólo libera capacidad, sino que eleva la tasa de completitud: con 24 minutos diarios en promedio, es factible cerrar el 100% de las inactivas levantadas.

## 6.5. Hallazgos y oportunidades

- Anclar la corrección al día D+1. La espiga en la serie diaria respalda un proceso de gestión de alertas temprana, a primera hora de la jornada.
- Priorizar por impacto. Combinar  $\Delta\text{precio}$  con  $\text{venta}_{\text{proxy}}$  permite clasificar casos alto/medio/bajo. Los SKU del Top-10 deben tener seguimiento con mayor frecuencia.
- Revisar ventanas de fin de vigencia. Los picos suelen coincidir con fechas de término de las promociones, por lo que reforzar el retiro de material al equipo en esos hitos.
- Monitorear reincidencia. Para SKU que reaparecen con frecuencia, establecer un control adicional, por ejemplo., señalética con fecha de retiro visible en reverso, o checklist digital.
- Cobertura y calidad de datos. Mantener la cobertura de navegación por sobre 90% mejora la sensibilidad de detección y la confiabilidad del indicador. Para esto, se deben dar las condiciones para que robot pueda navegar sin problemas por la tienda, evitando dejar obstáculos en pasillos.

## 7. DISCUSIÓN

En esta sección se interpretan los resultados, se revisan sus implicancias operativas y se comentan las decisiones metodológicas que sostienen las estimaciones.

### 7.1. Lectura integrada de resultados

El análisis muestra dos aportes complementarios de la auditoría robótica:

- 1) **Mitigación de riesgo por cartelería inactiva.** El valor esperado de discrepancia de precio (escenario  $p = 0,35$ ) asciende a \$411.675 CLP en el mes, con picos concentrados en pocos días. Esta concentración es consistente con la operación: bastan algunas combinaciones de  $\Delta\text{precio}$  alto y rotación ( $\text{venta}_{\text{proxy}}$ ) para explicar una fracción relevante del total.
- 2) **Eficiencia operativa.** Al pasar de auditorías de barrido a gestión por alertas, se evitaron 427,24 horas de trabajo acumuladas en el mes ( $\approx$  \$4.272.417 CLP), manteniendo la tasa de completitud en 100% para las inactivas levantadas. La comparación con la carga manual teórica ( $\sim 16,25$  h/día) evidencia que el enfoque tradicional no es practicable en la ventana operacional disponible ( $\sim 1,5$  h/día).

La auditoría robótica libera capacidad y, a la vez, reduce exposición al riesgo de precio informado. Los dos componentes no son estrictamente aditivos en términos contables, pero sí dan un orden de magnitud del impacto que habilita la solución.

## 7.2. Patrones observados

- **Serie espigada.** El riesgo diario exhibe una distribución con colas: muchos días con valores bajos o nulos y pocos picos de alta magnitud. Operativamente, esto sugiere reforzar el ritual  $D \rightarrow D+1$  (revisión y retiro al día siguiente) y crear ventanas de retiro alrededor de fechas de término de promociones.
- **Regla 80/20 por SKU.** El Top-10 concentra una proporción significativa del riesgo mensual. Un pequeño subconjunto de SKU —con mayores descuentos y/o mayor salida— explica gran parte del problema.
- **Cobertura de navegación.** Días con mejor cobertura de navegación tienden a mostrar más alertas útiles y una medición de riesgo más confiable. Mantener cobertura es clave para una auditoria completa de la tienda.

## 7.3. Implicancias para la operación

- **Priorización simple y accionable.** Ordenar el backlog por  $\Delta \text{precio} \times \text{venta\_proxy}$  produce una cola de trabajo que combina impacto y factibilidad. El Top-10 debe tener responsables y un checklist de seguimiento semanal.
- **Ciclo de trabajo.** la apertura de trabajos con revisión de los resultados del robot y asignación de alertas permite reducir la probabilidad de reincidencia y evita arrastre de inactivas.

- **Gestión y seguimiento.** Un tablero con indicadores de cumplimiento (tasa de inactivas, lead time, reincidencia 14 días) y una reunión corta semanal permiten sostener mejoras sin carga adicional relevante.

#### **7.4. Alcance y extrapolación**

Los hallazgos corresponden a una tienda y un mes. La metodología es escalable y, aplicada a más tiendas/meses, permitirá construir curvas de aprendizaje (reducción progresiva de backlogs, reincidencia, etc.) y estimar beneficios a nivel cadena.

## 8. CONCLUSIONES

- Eficiencia domina el caso de negocio. La gestión por alertas permitió evitar del orden de 427 horas-hombre mensuales ( $\approx$  \$4,27 MM CLP), haciendo viable y sostenible la corrección diaria de cartelera inactiva sin ampliar dotación ni sacrificar otras tareas críticas de sala.
- El riesgo por inactivas es acotado y concentrado. El valor esperado mensual se estimó en \$411.675 CLP ( $p=0,35$ ), con rango \$294–588 mil bajo sensibilidad. La distribución es altamente concentrada en pocos SKU-día, lo que habilita priorización quirúrgica.
- Relación 10:1. El bloque de eficiencia supera en  $>10\times$  al riesgo directo, por lo que el aporte dominante de la auditoría robótica no es la contención del riesgo per se, sino la capacitación de tiempo para operar mejor.
- Valor al cliente y cumplimiento. Menos cartelera vencida reduce fricción de precio y refuerza coherencia góndola-caja, componente clave tanto de experiencia como de cumplimiento normativo.
- Metodología escalable. El pipeline SKU-tienda-día con regla  $D \rightarrow D+1$ , modelos de riesgo/eficiencia y sensibilidad parametrizable constituye una pieza reproducible, aplicable a otras tiendas y ventanas temporales.

## 9. LIMITACIONES

### 9.1. Limitaciones

- El análisis se centra en cartelería promocional inactiva. La cartelería faltante se reconoce como un fenómeno relevante, sin embargo, por disponibilidad y trazabilidad de datos, solo se menciona como contexto y no se cuantifica en esta memoria. Dado que no se cuenta con información suficiente y trazable para medir rigurosamente los efectos de la cartelería faltante, se la menciona como contexto, pero no se aborda en el análisis cuantitativo. El foco empírico se restringe a la cartelería promocional inactiva, para la cual sí disponemos de datos diarios, llaves de cruce y una metodología reproducible.
- Ventas POS. Se utiliza baja de stock como proxy; no se observan devoluciones ni transacciones.
- Cobertura y visión. La detección depende de la cobertura de navegación y condiciones de navegación en la tienda; días con baja cobertura pueden subestimar incidencias.
- Horizonte y muestra. Resultados de una tienda y un mes; la extrapolación requiere replicación.
- Supuesto de exposición (p). La fracción de exposición se modela por escenarios; no se dispone de mediciones directas por pasillo.

### 9.2. Líneas de trabajo futuro

- Integrar POS para validar ventas y aislar canibalización intra-categoría.

- Medición de exposición con aforos o sensores para calibrar  $p$  por tipología de pasillo y visibilidad.
- Ampliar cobertura temporal ( $\geq 6$  meses) y espacial (múltiples tiendas) para estimar tendencias y variabilidad.
- Otras mecánicas ( $2 \times 1$ , bundles, cupones) cuando existan reglas de valoración homogéneas en la maestra.

## 10. REFERENCIAS

- Biblioteca del Congreso Nacional de Chile (BCN). (s.f.). *Ley N.º 19.496 Sobre protección de los derechos de los consumidores (texto refundido, coordinado y sistematizado)*. Obtenido de LeyChile: <https://www.bcn.cl/leychile/navegar?idNorma=28784>
- Blattberg, R. C., & Neslin, S. A. (1990). *Sales Promotion: Concepts, Methods, and Strategies*. Englewood Cliffs, NJ: Prentice Hall.
- Blattberg, R. C., Briesch, R., & Fox, E. J. (1995). How Promotions Work. *Marketing Science*, G122–G132.
- Bucklin, R. E., & Gupta, S. (1992). Brand choice, purchase incidence, and purchase quantity: Three interrelated choice measures. *Journal of Marketing Research*, 307–327.
- Cámara de Comercio de Santiago (CCS). (2025). *Reporte e-commerce 2025 (agosto)*. Santiago: CCS.
- Chandon, P., Hutchinson, J. W., Bradlow, E. T., & Young, S. H. (2009). Does In-Store Marketing Work? Effects of the Number and Position of Shelf Facings on Brand Attention and Evaluation at the Point of Purchase. *Journal of Marketing*, 1–17.
- Clase Ejecutiva UC (Pontificia Universidad Católica de Chile). (s.f.). *Industria del retail en Chile: datos y tendencias*. Obtenido de Clase Ejecutiva UC: <https://www.claseejecutiva.uc.cl/blog/articulos/industria-del-retail-en-chile/>
- Drèze, X., Hoch, S. J., & Purk, M. E. (1994). Shelf management and space elasticity. *Journal of Retailing*, 301–330.

- Hendel, I., & Nevo, A. (202). Sales and Consumer Inventory. *The RAND Journal of Economics*, 195–220.
- Instituto Nacional de Estadísticas (INE). (2025). *Índice de Actividad del Comercio (IAC): Boletín mensual, agosto 2025*. Santiago: INE.
- Jeldres. (2009). *MODELO DE EVALUACIÓN DE PROMOCIONES APLICADO A UNA EMPRESA DE RETAIL PARA EL EQUIPAMIENTO Y MEJORAMIENTO DEL HOGAR*. Universidad Técnica Federico Santa María.
- (s.f.). *Measuring the Impact of Shelf Position on a Retailer's Sales*.
- Mela, C. F., Gupta, S., & Lehmann, D. R. (1997). The long-term impact of promotions and advertising on consumer brand choice. *Journal of Marketing Research*, 248–261.
- Servicio Nacional del Consumidor (SERNAC). (s.f.). *Información para consumidores: precios y ofertas. Ley 19.496*. Obtenido de Biblioteca del Congreso Nacional de Chile.: <https://www.bcn.cl/leychile/navegar?idNorma=61438>
- van Heerde, H. J., Leeflang, P. S., & Wittink, D. R. (2004). Decomposing the sales promotion bump with store data. *Marketing Science*, 23(3).

## 11. ANEXOS

### 11.1. Anexo A. Código – Pipeline de datos y gráficos

Subir a Colab los tres archivos CSV (alertas inactivas, promos, stock). Luego ejecute secuencialmente. Las rutas esperadas y parámetros se pueden ajustar en el bloque de "Parámetros".

```
# =====
#          0)          Imports          y          configuración          general
# =====
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from datetime import timedelta
from pathlib import Path

#          Configuración          para          los          gráficos
plt.rcParams.update({"axes.grid": True, "figure.autolayout": True})

# =====
#          1)          Parámetros          (ajustables)
# =====
#          Escenarios          de          fracción          de          exposición          al          cartel          inactivo
P_EXPOSURE_SCENARIOS = [0.25, 0.35, 0.50]

#          Excluir          domingos          (True/False)
EXCLUDE_SUNDAYS = True

#          Parámetros          de          eficiencia          operativa
TAU_MANUAL_SEC = 900
TAU_ALERTA_SEC = 30
COSTO_HH_CLP = 10000
TAU_ROBOT_SEC = 20 # Added definition for TAU_ROBOT_SEC

#          Rutas          a          los          archivos          de          datos
ALERTS_CSV = "alerts_inactive_promotion_id_tienda_20250701_to_20250731.csv"
PROMOS_CSV = "id_tienda_merged_promotion.csv"
STOCK_CSV = "id_tienda_Stock_filtered.csv"

# =====
#          2)          Carga          y          preparación          de          datos
# =====
# Función para leer CSV con codificación flexible y estandarizar columnas a minúsculas
```

```

def read_csv_flex(path):
    for enc in ("utf-8-sig", "utf-8", "latin1"):
        try:
            df = pd.read_csv(path, encoding=enc, sep=',')
            break
        except Exception:
            df = None
    if df is None:
        raise RuntimeError(f'No se pudo leer {path} con codificaciones comunes.')
    df.columns = [c.strip().lower() for c in df.columns]

    # Convert numeric columns that might have comma decimals
    for col in ["precio_normal", "precio_oferta", "saldo_disponible"]:
        if col in df.columns:
            # Replace comma with dot and convert to numeric
            df[col] = df[col].astype(str)
            df[col] = df[col].str.replace(",", ".", regex=False)
            df[col] = df[col].replace("", np.nan)
            df[col] = df[col].astype(float)
    )
    return df

```

```

# Carga directa especificando separador y manejo de codificación
alerts = read_csv_flex(ALERTS_CSV)
promos = read_csv_flex(PROMOS_CSV)
stock = read_csv_flex(STOCK_CSV)

```

```

# Renombrado de columnas explícito para consistencia
alerts = alerts.rename(columns={"aisle": "aisle", "facing": "aisle"})
stock = stock.rename(columns={"saldo_disponible": "saldo"})

```

```

# Función para convertir columnas a fecha
def parse_date_col(df, col, dayfirst=True):
    if col in df.columns:
        df[col] = pd.to_datetime(df[col], errors="coerce", dayfirst=dayfirst)
    return df

```

```

# Aplicar conversión de fechas
alerts = parse_date_col(alerts, "session_date", dayfirst=True)
promos = parse_date_col(promos, "file_date", dayfirst=True)
promos = parse_date_col(promos, "desde", dayfirst=True)
promos = parse_date_col(promos, "hasta", dayfirst=True)
stock = parse_date_col(stock, "date_file", dayfirst=True)

```

```

# Limpieza de datos nulos en columnas clave

```

```

alerts          =          alerts.dropna(subset=["session_date",          "item"]).copy()
promos          =          promos.dropna(subset=["sku_promocion",          "file_date"]).copy()
stock          =          stock.dropna(subset=["sku",          "saldo",          "date_file"]).copy()

# =====
# 3) Lógica de negocio: Joins, Venta Proxy y Riesgo
# =====
alerts["results_date"]          =          alerts["session_date"]
alerts["promos_file_date"]    =          alerts["session_date"] - pd.Timedelta(days=1)

if
alerts          =          alerts[alerts["results_date"].dt.weekday          EXCLUDE_SUNDAYS:
          !=          6].copy()

alerts_unique          =          alerts.drop_duplicates(subset=["item",          "results_date"]).copy()

# Convert item column to string for consistent merging
alerts_unique["item"]          =          alerts_unique["item"].astype(str)

promos["delta_precio"] = (promos["precio_normal"] - promos["precio_oferta"]).clip(lower=0)
promos          =          promos[promos["precio_oferta"]          <          promos["precio_normal"]].copy()

promos_key = promos[["sku_promocion", "file_date", "precio_normal", "precio_oferta", "delta_precio"]].copy()
alerts_promo          =          alerts_unique.merge(
promos_key,
left_on=["item",          "promos_file_date"],
right_on=["sku_promocion",          "file_date"],
how="left"
)

stock_min          =          stock.sort_values(["sku",          "date_file"])
stock_min["saldo_next"]          =          stock_min.groupby("sku")["saldo"].shift(-1)
stock_min["venta_proxy"] = (stock_min["saldo"] - stock_min["saldo_next"]).clip(lower=0)

# Convert sku column to string for consistent merging
stock_min["sku"]          =          stock_min["sku"].astype(str)

alerts_full          =          alerts_promo.merge(
stock_min[["sku",          "date_file"],          "venta_proxy"],
left_on=["item",          "results_date"],
right_on=["sku",          "date_file"],
how="left"
)

for          p          in          P_EXPOSURE_SCENARIOS:
alerts_full[f"riesgo_p{int(p*100):02d}"] = alerts_full["delta_precio"].fillna(0) * alerts_full["venta_proxy"].fillna(0)

# =====
# 4) Agregados y Eficiencia Operativa

```

```

# =====
cols_out = [
    "item", "results_date", "promos_file_date",
    "precio_normal", "precio_oferta", "delta_precio", "venta_proxy"
] + [c for c in alerts_full.columns if c.startswith("riesgo_p")]
res_sku_day = alerts_full[cols_out].copy()

res_daily = (
    res_sku_day
    .groupby("results_date", as_index=False)
    .agg({"riesgo_p35": "sum", "item": "count"})
    .rename(columns={"riesgo_p35": "riesgo_diario_p35", "item": "n_alertas"})
)

res_sku = (
    res_sku_day
    .groupby("item", as_index=False)
    .agg({"riesgo_p35": "sum", "venta_proxy": "sum", "delta_precio": "median"})
    .sort_values("riesgo_p35", ascending=False)
)

TOTAL_PASILLOS_UNIVERSO = 65
pasillos_alerta_diario = alerts_unique.groupby('results_date')['aisle'].nunique().rename('N_pasillos_con_alerta')
alertas_diario = alerts_unique.groupby('results_date')['item'].size().rename('N_alertas')

n_total_series = pd.Series(TOTAL_PASILLOS_UNIVERSO, index=pasillos_alerta_diario.index, name='N_total_pasillos')

hh_df = pd.concat([pasillos_alerta_diario, alertas_diario, n_total_series], axis=1).fillna(0)

hh_df['HH_pasillos_t'] = ((TAU_MANUAL_SEC * hh_df['N_total_pasillos']) - (TAU_ROBOT_SE
C * hh_df['N_pasillos_con_alerta'])) / 3600
hh_df['Valor_HH_pas_t'] = hh_df['HH_pasillos_t'].clip(lower=0) * COSTO_HH_CLP

hh_df['HH_alertas_t'] = ((TAU_MANUAL_SEC * hh_df['N_total_pasillos']) - (TAU_ALERTA_SE
C * hh_df['N_alertas'])) / 3600
hh_df['Valor_HH_al_t'] = hh_df['HH_alertas_t'].clip(lower=0) * COSTO_HH_CLP

HH_ahorradas_total_alertas = hh_df['HH_alertas_t'].sum()
AHORRO_CLP_alertas = hh_df['Valor_HH_al_t'].sum()

res_daily = res_daily.merge(hh_df.reset_index(), on='results_date', how='left')

# =====
# 5) Guardar resultados a CSV y graficar
# =====
res_sku_day.to_csv("risks_by_sku_day.csv", index=False)
res_daily.to_csv("risks_daily_totals.csv", index=False)
res_sku.head(10).to_csv("top10_skus_risk.csv", index=False)

```

```
hh_df.reset_index().to_csv("hh_savings_daily.csv", index=False)
```

```
print("
=====RESUMEN====")
print(f"Alertas únicas de inactivas (SKU-día): {len(alerts_unique):,}")
print(f"Total riesgo mensual (p=0.35): ${res_daily['riesgo_diario_p35'].sum():.0f} CLP")
print(f"Rango sensibilidad p=0.25 → p=0.50: $")
print(f"p=0.25: ${res_sku_day['riesgo_p25'].sum():.0f} CLP")
print(f"p=0.35: ${res_sku_day['riesgo_p35'].sum():.0f} CLP")
print(f"p=0.50: ${res_sku_day['riesgo_p50'].sum():.0f} CLP")
print(f"HH ahorradas (base por ALERTAS): {HH_ahorradas_total_alertas:,.2f} h → Ahorro: ${AH
ORRO_CLP_alertas:,.0f} CLP")
```

```
# Figura 1: Riesgo diario por cartelería inactiva (p=0.35)
plt.figure()
plt.plot(res_daily["results_date"], res_daily["riesgo_diario_p35"]) # sin colores explícitos
plt.title("Riesgo diario por cartelería inactiva (p=0.35)")
plt.xlabel("Fecha")
plt.ylabel("Riesgo diario (CLP)")
plt.xticks(rotation=45)
plt.tight_layout()
plt.savefig("fig_riesgo_diario_p35.png", dpi=160)
plt.show()
```

```
# Figura 2: Barras Top 10 SKU por riesgo agregado (p=0.35)
top10 = res_sku.head(10)
plt.figure()
plt.bar(top10["item"].astype(str), top10["riesgo_p35"]) # sin colores explícitos
plt.title("Top 10 SKU por riesgo agregado (p=0.35)")
plt.xlabel("SKU")
plt.ylabel("Riesgo total (CLP)")
plt.xticks(rotation=45)
plt.tight_layout()
plt.savefig("fig_top10_sku_riesgo_p35.png", dpi=160)
plt.show()
```

```
print("
Archivos generados:")
print(" - risks_by_sku_day.csv")
print(" - risks_daily_totals.csv")
print(" - top10_skus_risk.csv")
print(" - hh_savings_daily.csv")
print(" - fig_riesgo_diario_p35.png")
print(" - fig_top10_sku_riesgo_p35.png")
```

Salida esperada:

- CSV risks\_by\_sku\_day.csv con columnas [item, results\_date, promos\_file\_date, precio\_normal, precio\_oferta, delta\_precio, venta\_proxy, riesgo\_p25, riesgo\_p35, riesgo\_p50].
- CSV risks\_daily\_totals.csv (serie diaria con results\_date, riesgo\_diario\_p35, n\_alertas y métricas HH: N\_pasillos\_con\_alerta, N\_total\_pasillos, HH\_pasillos\_t, Valor\_HH\_pas\_t, HH\_alertas\_t, Valor\_HH\_al\_t).
- CSV top10\_skus\_risk.csv (ranking Top-10 por riesgo, p=0,35).
- CSV hh\_savings\_daily.csv (detalle diario de horas ahorradas y valorización).
- Figuras fig\_riesgo\_diario\_p35.png y fig\_top10\_sku\_riesgo\_p35.png.