



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

METODOLOGÍA PARA DETECCIÓN DE QUIEBRES DE STOCK EN EL RETAIL

TESIS PARA OPTAR AL GRADO DE
MAGÍSTER EN GESTIÓN DE OPERACIONES

MEMORIA PARA OPTAR AL TÍTULO DE
INGENIERO CIVIL INDUSTRIAL

RODRIGO ANDRÉS ARRIAGADA DÍAZ

PROFESOR GUÍA:
MARCELO OLIVARES ACUÑA

MIEMBROS DE LA COMISIÓN:
RICARDO MONTOYA MOREIRA
ANDRÉS MUSALEM SAID

SANTIAGO DE CHILE
2018

RESUMEN DE LA MEMORIA
PARA OPTAR AL TÍTULO DE
INGENIERO CIVIL INDUSTRIAL
POR: RODRIGO ANDRÉS ARRIAGADA DÍAZ
FECHA: 2018
PROF. GUÍA: MARCELO OLIVARES ACUÑA

METODOLOGÍA PARA DETECCIÓN DE QUIEBRES DE STOCK EN EL RETAIL

Los quiebres de stock son un problema que se presenta a nivel mundial y Chile no es la excepción. Estudios a nivel internacional indican que el promedio mundial de quiebres de stock es de 8.3%, mientras que en Chile, el nivel de quiebres de stock que presenta la industria es de un 15.7%. Esto genera pérdidas que han sido estimadas en un promedio de 3.9% de ventas perdidas para el retailer y un 2% de pérdidas para el proveedor. Para una industria con ventas estimadas en U\$602.000 millones, esto representa pérdidas de U\$24.000 millones para los retailers y U\$12.000 millones para los proveedores.

En particular, en esta tesis se aborda el problema de los quiebres de stock de la categoría Pan a granel en el supermercado Jumbo de Peñalolén. Para ello se cuenta con datos transaccionales del punto de venta con información de la tarjeta de lealtad y mediciones de los quiebres de stock en esta categoría realizados mediante cámaras de vídeo. El objetivo principal consiste en generar una metodología que permita detectar quiebres de stock usando datos transaccionales. La relevancia de esto está dado por el hecho que gran parte de la literatura se ha enfocado en abordar este problema generando modelos de inventario en góndola. Sólo Fisher y Raman plantean utilizar datos transaccionales con modelos de Control Estadístico de Procesos. A partir de esta idea, se analizaron las distintas técnicas de Control Estadístico de Procesos para encontrar las más adecuadas a este problema, siendo elegidos los gráficos de Shewhart y el Bernoulli Cumulative Sum. Para ambos casos se clasificaron los distintos SKU de la categoría de acuerdo a su nivel de rotación en alta, media y baja; y se utilizó el market share como el estadístico a analizar.

Para el caso de los gráficos de Shewhart se mostró que es un método simple de implementar y que es bastante efectivo para productos de alta rotación, obteniéndose niveles de detección entre un 40 y un 49%. Además, se mostró que agregando información histórica de preferencia de compra es posible lograr disminuciones significativas de las tasas de falsas alarmas de hasta un 67%, manteniendo niveles similares de detección. Sin embargo, este método pierde efectividad para productos de rotación más baja, que en el caso del pan a granel fue menor a 4%, ya que no es posible aplicar la metodología en muchos períodos de tiempo por la poca cantidad de información. Por otro lado, si bien el método de Bernoulli CUSUM es más complejo de implementar, éste mostró excelentes resultados en productos de rotación media y baja, llegando a niveles de detección de incluso un 58%, con tasas de falsas alarmas en torno al 10%. Para productos de rotación alta este método tuvo niveles de detección similares al los gráficos de Shewhart, sin embargo, presentó niveles de falsas alarmas superiores, entorno al 13%. Se concluye finalmente que los gráficos de Shewhart, combinado con información de la tarjeta de lealtad son el mejor método para productos de alta rotación y que los el Bernoulli CUSUM es el mejor para productos de rotación media y baja. Además, queda como trabajo futuro la revisión acerca de cómo auditar un quiebre de stock y cuánto demora este en ser observable en el punto de venta.

Dedicado a mi madre, Myriam, por su amor y apoyo incondicional durante este proceso.

Agradecimientos

Quiero agradecer a todos quienes me apoyaron en este largo proceso. Fueron muchas personas que me ayudaron en distintas etapas de mi vida universitaria. En primer lugar a mis padres, Juan Francisco y Myriam, por la educación y valores que me entregaron, además del apoyo que siempre me brindaron, sobre todo en las últimas etapas de mi carrera.

A todos mis amigos que conocí durante mi vida universitaria, de la cual guardo excelentes recuerdos gracias a ellos. En especial quisiera reconocer a algunos de ellos, los cuales fueron importantes especialmente en la última etapa, dándome su apoyo y motivación para terminar mi carrera. Claudio Kuhlmann, Pedro Abarca, Camila Paniagua, Gustavo Martínez, Luis Carmona, José Ignacio Pérez, Juan Andrés Vergara e Iván Serrano.

A Erika por ser ese soporte emocional y motivacional que necesitaba para terminar.

Y finalmente, no puedo dejar de reconocer a mis profesores guía por su paciencia, apoyo y comprensión.

Gracias a todos.

Tabla de contenido

1. Introducción	8
1.1. Motivación	9
1.2. Revisión bibliográfica	12
1.3. Objetivos y Alcances	13
1.3.1. Objetivo General	13
1.3.2. Objetivos Específicos	13
1.4. Metodología	13
2. Análisis Preliminar	15
2.1. Datos	15
2.2. Ventas	16
2.3. Quiebres de Stock	24
2.4. Clientes	25
3. Gráficos de Control	30
3.1. Metodología	31
3.2. Modelo	34
3.2.1. Segmentos de clientes según lealtad	37
3.3. Resultados	38
4. Cumulative Sum	43
4.1. Metodología	44

4.2. Modelo	48
4.3. Resultados	49
5. Comparación Resultados y Recomendaciones	56
5.1. Comparación Métodos	56
5.2. Recomendaciones	61
6. Conclusiones y trabajo futuro	65
6.1. Conclusiones	65
6.2. Trabajo futuro	66
Bibliografía	68
A. Market Share por día de la semana	I
B. Histogramas Límites inferiores	V
C. Cantidad de alarmas generadas en modelos de gráficos de Shewhart	X
D. Histogramas de market share según resultados de modelos Bernoulli CUSUM	XII

Índice de figuras

1.1. Magnitud de los quiebres de stock a en Chile y el mundo. Fuentes [16] [10]	9
1.2. Consecuencias directas de un quiebre de stock.Fuentes [16] [10]	10
1.3. Principales Causas de los quiebres de stock en el Mundo. Fuentes [10]	11
2.1. Market Share categoría Pan a Granel Jumbo Peñalolén. Fuente: Elaboración propia	18
2.2. Número de boletas de venta por día de la semana en Jumbo Peñalolén. Fuente: Elaboración propia	21
2.3. Promedio de ventas diarias por mes en Jumbo Peñalolén. Fuente: Elaboración propia	21
2.4. Market Share por día	22
2.5. Market Share por mes	23
2.6. Market Share por hora	23
2.7. Porcentaje del tiempo que un prodcto permaneció sin stock. Fuente: Elaboración propia	25
2.8. Clientes ordenados por percentiles de frecuencia de compra (Descendente). En el eje izquierdo se representa la frecuencia de compra y en eje derecho el porcentaje de las compras acumuladas que realiza cada percentil.	27
2.9. Histograma lealtades Hallulla	29
2.10. Histograma lealtades Marraqueta	29
3.1. Ejemplo de un Gráfico de Control. Fuente: [15]	31
3.2. Lealtades por percentiles de clientes	37
3.3. Niveles de detección según α	40
3.4. Niveles de detección según α	41

3.5. Histogramas market share de períodos según caso	42
4.3. Marraqueta: comparación falsas alarmas y detecciones	53
4.1. Gráficos Bernoulli CUSUM	54
4.2. Gráficos Bernoulli CUSUM	55
5.1. Marraqueta: comparación falsas alarmas y detecciones	57
5.2. Hallulla: comparación falsas alarmas y detecciones	58
5.3. Histogramas market share según stock	59
5.4. Coliza: comparación falsas alarmas y detecciones	60
5.5. Mendocino: comparación falsas alarmas y detecciones	61
A.1. Market Share por hora	I
A.2. Market Share por hora	II
A.3. Market Share por hora	II
A.4. Market Share por hora	III
A.5. Market Share por hora	III
A.6. Market Share por hora	IV
A.7. Market Share por hora	IV
B.1. Histograma Coliza 2.5 %	V
B.2. Histograma Coliza 5 %	VI
B.3. Histograma Coliza 10 %	VI
B.4. Histograma Coliza percentil 30 %	VII
B.5. Histograma Coliza percentil 40 %	VII
B.6. Histograma Coliza percentil 50 %	VIII
B.7. Histograma Coliza percentil 60 %	VIII
B.8. Histograma Coliza percentil 70 %	IX
B.9. Histograma Coliza percentil 80 %	IX

D.1. Histograma Marraqueta después de CUSUM	XII
D.2. Histograma Hallulla después de CUSUM	XIII
D.3. Histograma Pita Blanco después de CUSUM	XIII
D.4. Histograma Anís después de CUSUM	XIV

Índice de tablas

1.1. A quién afectan las pérdidas directas de los quiebres de stock	11
2.1. Datos POS	16
2.2. Datos Operacionales	16
2.3. Market Share Pan a Granel	19
2.4. Promedio de quiebres de stock	26
2.5. Cantidad de compras según percentiles	28
3.1. Valores de parámetros para gráficos de Shewhart	35
3.2. Valores promedio límite inferior	35
3.3. Quiebres detectados Fase I	36
3.4. Valores actualizados luego de Fase I	36
3.5. Valores promedio límite inferior	36
3.6. Lealtad según percentiles	38
3.7. Valores promedio límite inferior por percentiles ($\alpha = 5\%$)	38
4.1. Parámetros para diseño de Bernoulli CUSUM	48
4.2. Límites de control	49
4.3. Alarmas generadas	50
4.4. Market share según casos	52
4.5. Parámetros modelos Bernoulli CUSUM con p_1 ajustado	53

5.1. Parámetros modelo Bernouilli CUSUM para coliza y mendocino	56
C.1. Niveles de detección según α	X
C.2. Niveles de detección según Percentiles	XI

Capítulo 1

Introducción

En un contexto de gran concentración del mercado del retail a nivel mundial, existe una alta competencia entre las grandes empresas por atraer nuevos clientes y retener los ya existentes. Por esta razón, el servicio al cliente ha tomado un rol fundamental en las grandes cadenas, para aumentar el valor que entregan a sus clientes.

De esta manera, el servicio al cliente como define Mitchell [14] corresponde a la suma de acciones y elementos que permiten que el cliente reciba lo que necesita o desee de su establecimiento de retail. Así, dentro de las acciones que han tomado las cadenas de supermercados, ha sido una notoria alza en el número de SKUs (Stock-keeping unit) en sus salas de venta, con el fin de mejorar la experiencia de compra de sus clientes. Sin embargo esta alza en los SKUs, también conlleva un mayor desafío operacional.

Dependiendo del tamaño de la sala de ventas, un supermercado tradicional cuenta en promedio con unos 22.000 SKUs y un hipermercado puede llegar a tener más de 60.000 [1]. Esto hace que sea extremadamente difícil para el administrador de la sala, poder saber qué productos no están presentes en las góndolas, lo que genera este problema de quiebres de stock. Si bien, las tecnologías han evolucionado y hoy existen alternativas como los chip de RFID, aún su costo es muy elevado y siempre existirán productos que no podrán ser etiquetados con estas tecnologías, como por ejemplo, las frutas y verduras, productos de panaderías y en general, todos los productos frescos. Todas estas dificultades son las que motivan el presente trabajo de tesis.

Existen dos definiciones que son las más utilizadas en la literatura relacionada a los quiebres de stock [10], con distintos enfoques:

- Desde el punto de vista operacional, considera el porcentaje de los SKUs que están fuera de stock en las góndolas en un momento determinado. Por lo general, los estudios que utilizan este enfoque lo hacen mediante revisiones físicas de los locales, donde se selecciona una o más categorías y se realizan múltiples revisiones en diferentes días a una hora específica. Este es el enfoque más utilizado en la literatura y por ende se cuenta con una buena referencia de comparación.

- Desde el punto de vista del cliente y corresponde al porcentaje de la veces que un cliente busca un producto y no lo encuentra. Este enfoque tiene la ventaja de que mide los quiebres de stock que realmente importan al supermercado, ya que deterioran la experiencia de compra del cliente. La forma de medición de este enfoque se realiza principalmente mediante dos formas, realizando encuestas a los clientes o mediante modelos que utilizan datos del sistema de inventario con datos del Punto de Venta (POS, por sus siglas en inglés).

Dentro de la variedad de causas que generan la ausencia de un producto, existe una en la que el resultado de este trabajo puede tener importantes repercusiones. Se trata del quiebre de stock en el cual el producto no se encuentra presenta en la góndola del supermercado, pero sí en su bodega y no ha habido reposición. Este problema se conoce en la literatura como quiebre de stock *fantasma* (Phantom Stockout en inglés) y puede ser fácilmente solucionado luego de detectar el problema y enviar a un trabajador a reponer el producto.

1.1. Motivación

Los quiebres de stock son un problema que se presenta a nivel mundial y ciertamente en Chile también. En una recopilación de estudios realizada por Gruen [10], donde se analizaron más de 40 estudios a nivel mundial, se pudo constatar que el promedio mundial de quiebres de stock es de 8.3 %, mientras que en Chile, según estudios de Bosch [16], el nivel de quiebres de stock que presenta la industria es de un 15.7 %. En la figura 1.1 se puede apreciar los promedios mundiales de quiebres de stock en diferentes regiones.

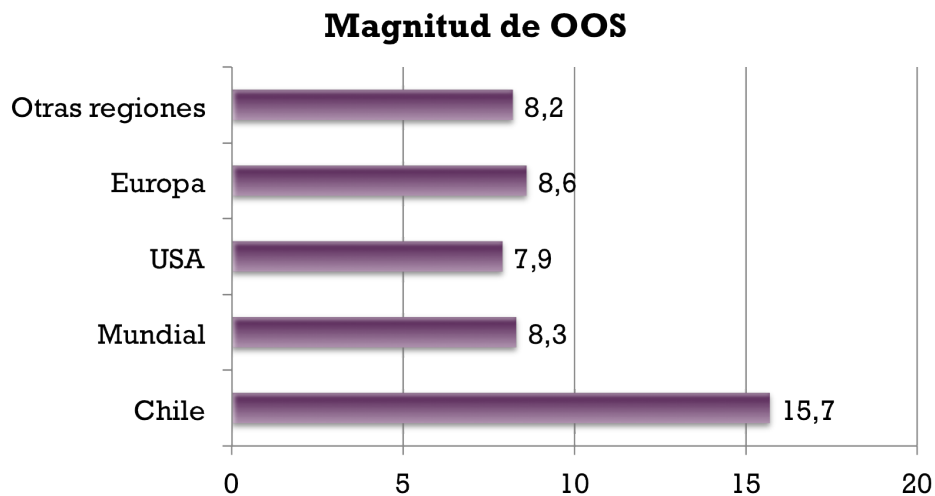


Figura 1.1: Magnitud de los quiebres de stock a en Chile y el mundo. Fuentes [16] [10]

Esto significa que por cada 13 items que un consumidor busca en un supermercado, al menos uno de ellos no lo encontrará y si se piensa en Chile, esta cifra se reduce a 1 de cada 7. Esto trae

diversas consecuencias, tanto para el retailer como para el proveedor. Los estudios realizados al comportamiento de los consumidores cuando se ven enfrentados a un quiebre de stock, indican que son cinco las principales consecuencias directas, las cuales se puede ver en la figura 1.2. En este gráfico se observa que el comportamiento que más se repite es *Comprar en otra tienda*, lo que sumado a las ventas pérdidas, también implica indirectamente una pérdida de lealtad y la oportunidad de probar otras tiendas de la competencia. Por otro lado, comportamientos *Sustituir por otra marca* y *No Comprar* presentan pérdidas para el proveedor que no tiene su producto en góndola y que indirectamente también produce un desbalanceo en la cadena de suministros, al subestimar la demanda.




Figura 1.2: Consecuencias directas de un quiebre de stock. Fuentes [16] [10]

En la tabla 1.1 se puede ver quién asume las consecuencias por cinco principales respuestas de los consumidores a los quiebres de stock.

Estas pérdidas han sido estimadas [10] en un promedio de 3.9% de ventas perdidas para el retailer y un 2% de pérdidas para el proveedor. Para una industria con ventas estimadas en U\$602.000 millones, esto representa pérdidas de U\$24.000 millones para los retailers y U\$12.000 millones para los proveedores¹.

Finalmente, si bien no existe un consenso entre los estudios a nivel mundial de cuáles serías las causas de los quiebres de stock, existen cinco causas principales vistas en los estudios recopilados por Gruen [10]. Como se puede ver en la figura 1.3 entre dos tercios y tres cuartos de los quiebres de stock son causados por problemas de la tienda, mientras que entre un cuarto y un tercio de los quiebres son causados por problemas aguas arriba en la cadena de suministro.

¹Fuente: Industry Overview 2011-2012, FMI

Respuesta del Consumidor	Retailer	Proveedor
Comprar Item en otra tienda	Sí (La más problemática de todas las opciones)	No
Postergar Compra	No (Pero afecta negativamente al flujo de caja y rotación de inventario)	No (Pero afecta negativamente el flujo de caja y exagera la fluctuación de la demanda)
Sustituir-Misma Marca	No (Pero existe un pérdida parcial cuando el consumidor sustituye por una opción de menor precio)	No (Pero existe un pérdida parcial cuando el consumidor sustituye por una opción de menor precio)
Sustituir-Otra Marca	No (Pero existe un pérdida parcial cuando el consumidor sustituye por una opción de menor precio)	Sí (La más problemática de las opciones)
No comprar	Sí	Sí

Tabla 1.1: A quién afectan las pérdidas directas de los quiebres de stock




Figura 1.3: Principales Causas de los quiebres de stock en el Mundo. Fuentes [10]

De la figura 1.3 se puede observar que un 25% de los quiebres de stock son causados por productos que se encuentran en bodega, pero que no se han repuesto en las góndolas. Primero fue Gruen y Corsten [11] quienes se refirieron a este desajuste entre los registros de inventarios en góndola mayores a los inventarios reales, llamándolo *inventario fantasma*. Luego, Fisher y Raman [8] acuñan el término *phantom stockout* (quiebre de stock fantasma), a quiebres de stock causados por el problema anterior y también a fallas en la ejecución de reposición de inventario

entre la bodega y la góndola.

Todo esto se debe a que en la gran mayoría de las cadenas de retail, existe un buen control del inventario que entra, sin embargo pueden existir desajustes en el registro de ventas de un SKU, pérdidas por deterioro, robos, incluso productos que no se encuentran su góndola o que han sido tapados por algún objeto. En resumen, dentro de un supermercado, con alrededor 30.000 SKUs, es imposible para sus administradores llevar un control apropiado de todos los productos, por lo que el sistema se encuentra en una especie de *caja negra*, en la que esta incertidumbre resulta en quiebres de stock de estos productos.

A diferencia de los quiebres de stock tradicionales, donde se define un nivel de inventario de acuerdo a un determinado nivel de servicio, los quiebres de stock fantasmas necesariamente deben resolverse mediante algún sistema de detección de esta situación, ya sea mediante inspección humana, sistema de detección de quiebres o modelos de inventario variable.

1.2. Revisión bibliográfica

Existe tres corrientes que tratan el problema de los quiebres de stock en el retail. La primera corresponde al manejo de inventario bajo imprecisiones en su registro, de las cuales se mencionarán las más importantes (un estudio más acabado puede ser encontrado en [6]). Esta corriente, a su vez puede ser dividida en dos categorías: sin inspecciones o con inspecciones. En la primera categoría se encuentran los trabajos de Mersereau [13], Bensoussan [2], entre otros, Ellos plantean modelos de reposición de inventario que además de la demanda, consideran una demanda *fantasma*, que incluye robos, deterioro y errores en el registro en caja. La segunda categoría, además de la reposición de inventario, también considera la implementación de políticas de auditorías, con tal de obtener certeza del nivel de inventario real. Dentro de los trabajos más importantes en esta categoría se encuentra el realizado por DeHoratius [7] y Kok y Shang [12] quienes proponen modelos bayesianos para estimar el inventario y en base a eso, determinar cuando es económicamente óptimo realizar una inspección, para reducir incertidumbre o reponer inventario. Otro trabajo importante es el que propone Chen [5], quien propone dos cadenas de markov ocultos para definir el problema de la demanda *fantasma* y otra para problemas en la ejecución de la reposición de inventario, como un proceso de deterioro. Se definen inspecciones de acuerdo a una política de cero ventas.

Esto último está relacionado con la segunda corriente de literatura, que corresponde a la utilización de modelos de control estadístico de procesos. Estos son utilizados por Chen [5] en su política de auditorías y fueron propuestos originalmente por Fisher y Raman [8]. En estos trabajos, se modela la cantidad de períodos con cero ventas consecutivos mediante una distribución de Poisson. Si la probabilidad disminuye más allá de cierto límite, se genera una alerta para realizar una inspección. Este es el método más parecido a los propuestos en este trabajo, sin embargo, se descartó el análisis de períodos de ventas debido a que por las características de la información operacional con la que se cuenta, donde no se miden realmente quiebres, si no que bajas en el stock y tampoco se sabe con certeza cuánto tiempo tarda el último cliente que compró el producto, antes que se agotase, en llegar a la caja. Por esta razón, se utilizaron métodos de SPC que analizan

disminuciones en las ventas, sin ser específicamente cero.

Una tercera corriente tiene un foco más administrativo y ve cuáles son las políticas de reposición de inventarios con mejores resultados para evitar los quiebres de stock por reposición. Ton y Raman [22] indican que mayores niveles de inventario y por ende, una menor frecuencia de reposición tienden a generar mayores niveles de quiebres de stock. Esto precisamente por los problemas de deterioro, robos y desorden en góndola. Para combatir este problema, Fisher y Raman [8] proponen un modelo JIT (Just in time), lo cual obligaría al administrador a generar mejores políticas de reposición.

1.3. Objetivos y Alcances

1.3.1. Objetivo General

Desarrollar una metodología que permita detectar quiebres de stock usando datos transaccionales.

1.3.2. Objetivos Específicos

- Extender métodos de control estadístico de procesos para detección de quiebres de stock.
- Generar una metodología que permita agregar variables exógenas los modelos utilizados para mejorar su poder de predicción.
- Realizar un benchmark de los modelos utilizados, para determinar los pro y contras de cada modelo.
- Encontrar modelos que sean de bajo costo computacional y fácilmente aplicables en la industria.

1.4. Metodología

De forma de lograr los objetivos detallados anteriormente, se desarrolló el trabajo siguiendo las etapas de metodología que se describe a continuación.

- **Revisión bibliográfica:** se realiza una revisión de los trabajos en relacionados a quiebres de stock, manejo de inventarios con incertidumbre y modelos de reposición automática. En particular, se analizó con mayor énfasis la literatura que trata sobre los quiebres de stock *fantasmas*, las herramientas y modelos que se utilizan para lidiar con ellos.
- **Extensión de Modelos de Control Estadístico de Proceso:** se desarrollan modelos que permiten determinar cuándo la cantidad de ventas de un determinado producto está fuera de

los rangos *normales* de venta y por lo tanto existe una probabilidad alta de que el producto se encuentre fuera de stock. Se utiliza data histórica para determinar cuáles son los límites superiores e inferiores de lo que se considera una rango *normal* de venta.

- **Inclusión de variables exógenas a modelos:** se complementan ambos modelos con variables exógenas que aporten más información y complejidad al modelo, de manera de predecir con mayor precisión si un producto se encuentra o no en quiebre de stock. Dentro de las variables exógenas que se considera incluir en los modelos está la información del historial de compra de los clientes.
- **Comparación de modelos y recomendaciones:** Se compararon los resultados de los distintos modelos con el fin de poder encontrar cuáles son las ventajas de y desventajas de cada uno. Con esta información, se realizan recomendaciones para una futura implementación en una cadena de retail.

Capítulo 2

Análisis Preliminar

Un primer paso para lograr una reducción en los niveles de quiebres de stock en una sala de ventas corresponde a entender cuáles son las características generales de los productos que se venden y qué ocurre cuando existen quiebres de stock. Es improbable encontrar una herramienta que funcione a niveles aceptables para todos los productos y en todos los casos, por lo que un conocimiento general de cómo y en qué intensidad reaccionan los consumidores frente a un quiebre de stock permitirá elegir la herramienta adecuada para cada situación.

El objetivo general de este capítulo es realizar un análisis estadístico descriptivo de las variables que inciden en la aparición de un quiebre de stock. Específicamente se estudiarán variables como los niveles de ventas, quiebres de stock y también análisis de clientes.

2.1. Datos

Antes de comenzar cualquier análisis, es necesario tener claridad de los datos con los que se cuenta y la calidad de su información. Los datos para la realización de este trabajo provienen de dos fuentes.

La primera corresponde a los datos de Punto de Venta (POS) de la categoría *Pan a Granel*, *Fiambrería* y *Electrodomésticos* del supermercado *Jumbo*, en su sala ubicada en la comuna de Peñalolén. Esta base de datos contiene la información de un año completo de ventas, con información detallada de canasta en cada compra realizada que incluyese las tres categorías mencionadas e información general de resto de las compras. En la tabla 2.1 es posible ver información de la base de datos. Además esta data se complementa con la información de la tarjeta de lealtad del supermercado. De esta manera, se cuenta con la siguiente información para realizar un modelo:

- Fecha y hora de la compra
- Información de canasta de compra (sólo compras que incluyen Pan a granel, Fiambrería y

Electrodomésticos)

- Información agregada de compras sin pan
- Identificación de cliente

Tabla 2.1: Datos POS

Fecha de las Observaciones	01/06/2008-31/05/2009
Local	Jumbo Peñalolén
Nro de SKU de Panes	34
Nro de Tickets	2.349.969
Tickets con Rut (%)	69.5 %
Tickets con Pan (%)	28.8 %
Nro de Clientes distintos	46865

La segunda fuente de información corresponde a datos operacionales los cuales fueron obtenidos gracias a la ubicación de cámaras de vídeo en las góndolas de la categoría *Pan a Granel* y que luego mediante un análisis de imágenes se determina si la góndola posee más de un 20% de su capacidad o no, entregando un 1 si la góndola tiene menos de un 20% de su capacidad y un 0 si tiene más. Estos datos se presentan en la tabla 2.2.

Este último es un dato relevante a la hora de generar cualquier modelo de detección de quiebres de stock, puesto que lo que se midió no fue un quiebre, si no una baja en el stock. Esto requerirá de un tratamiento especial de los modelos y existirán técnicas que no podrán ser utilizadas en este trabajo por las limitantes que presentan los datos, ya que probablemente no se vean períodos sin ventas, si no que sólo baja en las ventas.

Tabla 2.2: Datos Operacionales

Fecha de las Observaciones	5 marzo al 19 de Abril 2009
Intervalo entre Mediciones	30 minutos
Nro de Mediciones	1255
Nro de Productos Analizados	34

2.2. Ventas

Tener un conocimiento básico del comportamiento de las ventas de un producto es fundamental para poder reducir sus quiebres de stock. Se parte desde el supuesto que los quiebres de stock son producidos principalmente por las ventas del producto y que otras causas como pérdidas, robos y obsolescencia, pueden llegar a ser importantes y sus efectos son estudiados en otros trabajos ([5], [7]), pero no serán considerados en este trabajo. De esta manera, será más probable que existan quiebres de stock en períodos de altas ventas, si no se realiza una adecuada reposición de los productos.

Otra variable importante para considerar las ventas en un análisis previo a la implementación de un modelo de detección de quiebres de stock, está dado por la calidad de información. Como se mencionó en la sección 2.1, la información a utilizar en este trabajo corresponde a datos del punto de venta (POS), en específico, información de las boletas y el detalle de productos que incluyen. Si bien esta información es bastante completa, la cantidad de información con la que se cuenta varía período a período. Esto toma especial importancia al usar modelos probabilísticos y estadísticos, ya que pierden precisión al usar muestras pequeñas.

Por esta razón, es importante tener en cuenta la capacidad de detección del modelo a utilizar, dada la cantidad de datos que se tendrán. Esto puede ser medido calculando la probabilidad de error *tipo II* del modelo, dado el tamaño de la muestra a utilizar. Este error mide la cantidad de falsos negativos que genera el modelo, es decir, la probabilidad de no detectar un quiebre de stock. A mayor cantidad de datos, menor será la probabilidad de este error, por lo se deberán fijar niveles aceptables de error *tipo II* y la cantidad mínima de datos que se necesitarán para llegar a estos niveles.

De esta manera se hace crucial tener una noción de los niveles de venta de cada producto para poder decidir cuál es el modelo más adecuado y los tratamientos que se harán a la información con la que se cuenta. Así, para productos con un alto nivel de ventas, se podrán utilizar modelos con mayor poder de detección, pero que a su vez necesitan mayor cantidad de datos. También se podrá hacer un tratamiento y filtrado para dejar sólo aquellos datos que entregan mayor información.

Análisis por producto

En toda cadena de retail existirán productos o SKUs con distintos niveles de rotación. Algunos con muchas ventas por hora y otros en los que incluso pueden pasar días sin que se venda una unidad. Ciertamente existirán SKUs cuyos quiebres de stock serán mucho más críticos para el administrador que otros y a los cuales se querrá destinar más recursos para reducirlos. Incluso SKUs con bajos niveles de rotación pueden ser importantes para la cadena de supermercados. Ya sea por compromisos de niveles de servicio en su estrategia de marketing o por pertenecer a alguna categoría relevante.

Un análisis previo de los productos permite categorizarlos de acuerdo a sus distintos niveles de ventas y poder elegir un modelo adecuado a ello. Si bien, la cantidad SKUs que existe en una sala de supermercado puede ser muy grande, el procedimiento es bastante sencillo, no se necesita gran poder de cálculo y las mejoras en la detección pueden ser importantes. A continuación, en la figura 2.1 y en la tabla 2.3, se muestran los productos de mayor market share de la categoría *Pan a Granel*:

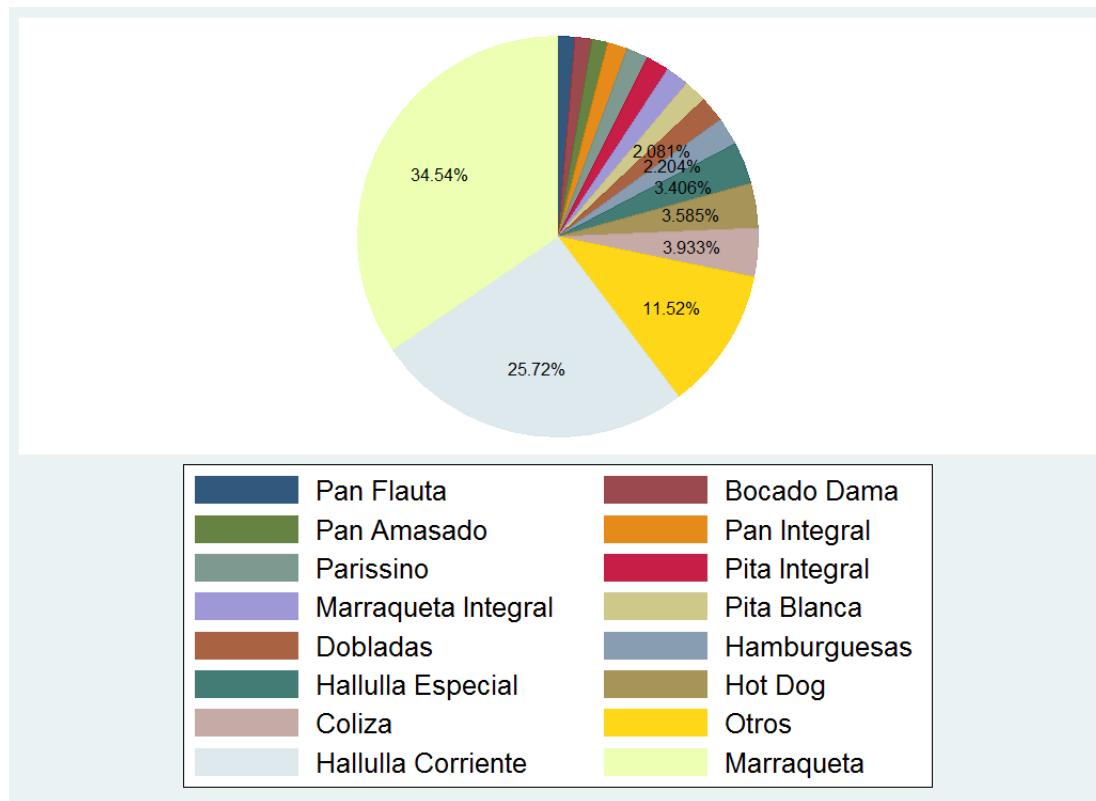


Figura 2.1: Market Share categoría Pan a Granel Jumbo Peñalolén. Fuente: Elaboración propia

Como se observa, existen claras diferencias en el market share de los productos de esta categoría. En primer lugar se encuentran la *Marraqueta* y la *Hallulla*, que en conjunto acumulan más del 60% de las preferencias de los consumidores. Luego viene un grupo de 18 productos cuyos market share varía entre 4% y 1% y que agrupan casi el 35% de las preferencias. Para finalizar existe otro grupo con niveles de rotación, inferiores a 1%, y que en conjunto acumulan cerca del 5% de las preferencias y cuya categorización se muestra en la tabla 2.3. Claramente estos grupos deben tener tratamientos distintos. Esto, principalmente por los niveles de información y también porque un quiebre en un producto de muy alta rotación como la *Marraqueta*, generará mayores pérdidas económicas que un producto de baja rotación.

Además, el market share captura efectos cruzados entre productos, ya que, como se mencionó en el capítulo 1, existe una importante cantidad de clientes que decide sustituir el producto faltante en góndola por otro de la misma categoría, ya sea de la misma marca pero en otro formato o cambiando de marca. De esta manera, estos cambios se verán reflejados en el market share ya que el producto faltante bajará su cuota de mercado, mientras que los otros la subirán.

Sin embargo, el market share no es el único parámetro en lo que se debe poner atención. En categorías de bajo nivel de ventas, incluso un producto con un alto market share, puede tener una baja rotación y un producto de bajo market share en una categoría de alto nivel de ventas puede tener un buen nivel de rotación. Por esta razón, es importante analizar el nivel de ventas en

Tabla 2.3: Market Share Pan a Granel

Variable	Incidencia de venta	Market Share	Mshare acumulado	
Marraqueta	291000	34.53 %	34.53 %	Rotación alta
Hallulla Corriente	217000	25.75 %	60.28 %	
Coliza	33126	3.93 %	64.21 %	Rotación media
Hot Dog	30190	3.58 %	67.79 %	
Hallulla Especial	28685	3.40 %	71.20 %	
Hamburguesas	18560	2.20 %	73.40 %	
Dobladas	17522	2.08 %	75.48 %	
Pita Blanca	16211	1.92 %	77.40 %	
Marraqueta Integral	15779	1.87 %	79.27 %	
Pita Integral	15187	1.80 %	81.08 %	
Parissino	14803	1.76 %	82.83 %	
Pan Integral	13585	1.61 %	84.44 %	
Pan Amasado	11421	1.36 %	85.80 %	
Bocado Dama	11413	1.35 %	87.15 %	
Pan Flauta	11213	1.33 %	88.48 %	
Pan de Hoja	10685	1.27 %	89.75 %	
Hallulla Integral	10493	1.25 %	91.00 %	
Coliza Peruana	10331	1.23 %	92.22 %	
Pita Linaza Integral	9580	1.14 %	93.36 %	
Pan Italiano	8920	1.06 %	94.42 %	
Mendocino	6478	0.77 %	95.19 %	Rotación baja
Anis	5888	0.70 %	95.89 %	
Pan de Queso	4477	0.53 %	96.42 %	
Toscano	4375	0.52 %	96.94 %	
Dobladas Integrales	4326	0.51 %	97.45 %	
Pan sin sal	3972	0.47 %	97.92 %	
Mini Barra Blanca	3484	0.41 %	98.33 %	
Croissant	3372	0.40 %	98.73 %	
Tolin Sesamo	3248	0.39 %	99.12 %	
Rosita	2778	0.33 %	99.45 %	
Mini Barra Integral	1731	0.21 %	99.65 %	
Pan de Campo	1576	0.19 %	99.84 %	
Pan de Campo Semilla	1057	0.13 %	99.97 %	
Panchito	274	0.03 %	100.00 %	
Mini Frica	3	0.00 %	100.00 %	
Total	842743			

la categoría y evaluar qué cantidad de información se posee de sus productos. Así se muestra en la tabla 2.3, que muestra los niveles de rotación de la categoría *Pan a Granel*, en donde incluso productos con bajos market share, de un 3% o 4%, pueden ser considerados como productos de mediana rotación, que pueden llegar a ser mayores que los de productos de categorías menos vendidas.

Estacionalidad

Conocer cómo se comportan las ventas en el tiempo puede entregar sencillas, pero a la vez prácticas reglas sobre las frecuencias de reposición, los métodos de detección de quiebres a usar en cada período y cómo se deben agrupar los datos. Toda tienda de retail tendrá horarios de mayor afluencia de público y en donde se deberán tener métodos de detección de quiebres mucho más sensibles para reaccionar de manera rápida ante cualquier anomalía en los comportamientos de compra de los clientes.

Por esta razón es importante identificar estacionalidad en los productos. Saber si es un día en específico, determinada hora del día o incluso si hay períodos del año en los cuales aumentan las ventas. En una primera instancia se puede hacer un análisis general de todas las ventas realizadas en una sala de supermercado, independiente del producto que compren, para saber cuánta gente está presente en la sala, realizando compras. Este es un análisis bastante sencillo y que por lo general, la gran mayoría de los administradores de las cadenas de supermercados conocen. Así, se podrá tener una estimación de cuánto podrían variar las ventas de cada producto en ese período. En las figuras 2.2 y 2.3, se muestran el número de boletas diferenciados por día y mes respectivamente. En ellas se observa que el número de tickets aumenta los fines de semana y se mantiene relativamente parejo en la semana. Por otro lado, el análisis por mes indica que Enero y Febrero son los meses del año con menor cantidad de tickets. Esta información es importante para saber cuándo el modelo funcionará de mejor manera y cuándo puede tener más errores. De esta manera, es de esperar que los modelos funcionen mejor los fines de semana, precisamente porque se cuenta con mayor información.

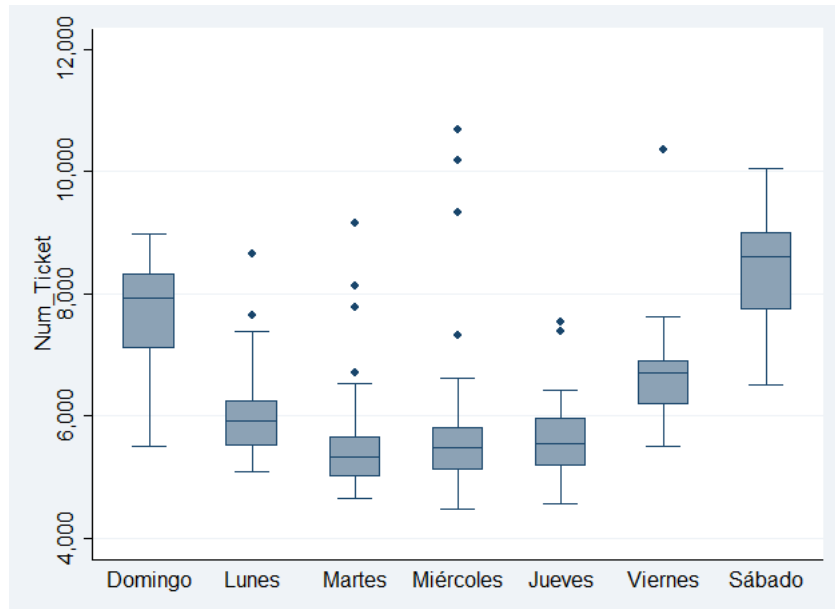


Figura 2.2: Número de boletas de venta por día de la semana en Jumbo Peñalolén. Fuente: Elaboración propia




Figura 2.3: Promedio de ventas diarias por mes en Jumbo Peñalolén. Fuente: Elaboración propia

Sin embargo, no todos los productos se comportan de la misma manera, ni sus ventas estarán correlacionadas con la cantidad de clientes en la tienda. Existen categorías de productos con estacionalidades más específicas, las cuales deberán analizarse individualmente y será labor del

administrador identificarlas. Si bien, este proceso puede ser bastante más tedioso, este debe ser un proceso gradual para ir mejorando cada vez más los modelos utilizados y su capacidad de detección.

En consecuencia, se analizó cómo varía el *Market Share* de una categoría, dependiendo de variables de tiempo, como el día la semana, la hora del día y mes del año. Esto se hizo utilizando gráficos del tipo Box Plot, los cuales se pueden ver a continuación:




Figura 2.4: Market Share por día




Figura 2.5: Market Share por mes




Figura 2.6: Market Share por hora

Como se observa en los gráficos anteriores, no existe diferencia significativa en el market share por día de la semana y por mes. En cambio, sí se detectan una pequeña estacionalidad dependiendo de la hora del día. Esto se debe tener en cuenta en el diseño de cualquier modelo para predecir quiebres de stock. No se debiese mezclar data histórica de dos períodos de tiempo distintos ya que esto aumentará la variabilidad de los datos y se tendrá un modelo menos preciso.

2.3. Quiebres de Stock

Un quiebre de stock existe cuando el tasa de salida de un producto supera a la tasa de entrada de éste en góndola. Como ya se mencionó, la salida de un producto corresponde a pérdidas, robos, obsolescencia y la más importante, las ventas. Por otro lado, la tasa de entrada corresponde a la reposición que se haga del producto, específicamente, la que se hace desde la bodega a la góndola. De esta manera, resulta lógico analizar cuáles son las políticas de reposición que se aplican a los diferentes productos. Sin embargo, no siempre existe un registro detallado de la reposición de los productos y menos aún de pérdidas, robos y obsolescencia. Por esta razón, el enfoque más cercano para estudiar esta problemática es realizando auditorías o revisiones periódicas de la disponibilidad de los productos en góndola y viendo cuándo existen quiebres de stock y su duración. Para el caso de este trabajo, se utilizaron datos extraídos mediante cámaras de video, realizó una revisión periódica de las góndolas de la categoría *Pan a granel* cada 30 minutos.

Ciertamente, no todos los productos se comportarán de la misma manera. Existen productos mucho más importantes que otros en términos de ventas, en los cuales se tendrá más énfasis a la hora de reponer su stock. Otros productos menos importantes podrán pasar horas e incluso días sin disponibilidad en góndola, pasando esto inadvertido para la administración. Esto se puede ver en la figura 2.7, que muestra un gráfico con el porcentaje del tiempo que un producto está sin stock en la categoría *Pan a granel*. En este gráfico se observa que existen productos con altísimos niveles de quiebre de stock, que llegan a más de un 60% del tiempo sin disponibilidad, mientras que en otros es muy bajo, entre un 5 y un 10%.




Figura 2.7: Porcentaje del tiempo que un producto permaneció sin stock. Fuente: Elaboración propia

En la tabla 2.4 se observa que productos con altos niveles de ventas, tienden a tener menores tasas de quiebre de stock. Esto habla de cuán frecuente debe ser la reposición y refuerza la idea que se invierten mayores esfuerzo en estos productos, ya que son más importantes. Además, como el pan es un producto bastante perecible, indica que la reposición de estos productos debe ser frecuente en el tiempo y que los períodos sin disponibilidad deben ser cortos.

2.4. Clientes

Gracias a la tarjeta de lealtad del supermercado, es posible identificar a cada cliente registrado que haya realizado una compra. Esto a la larga permite tener un registro histórico de las compras de los clientes, que pueden entregar información valiosa sobre sus comportamientos de compra.

Tabla 2.4: Promedio de quiebres de stock

Variable	Promedio
Anis	29 %
Bocado Dama	11 %
Coliza	12 %
Coliza Peruana	18 %
Croissant	32 %
Dobladas	12 %
Dobladas Integrales	12 %
Hallulla	6 %
Hallulla especial	6 %
Hallulla Integral	7 %
Hamburguesas	13 %
Hot Dog	12 %
Marraqueta	14 %
Marraqueta Integral	12 %
Mendocino	7 %
Mini barra blanca	36 %
Mini barra integral	43 %
Pan amasado	20 %
Pan Campo	21 %
Pan Campo semilla	20 %
Pan de hoja	40 %
Pan Queso	53 %
Pan Flauta	64 %
Pan Integral	17 %
Pan Italiano	15 %
Pan sin sal	18 %
Panchito	63 %
Parissino	26 %
Pita Blanco	25 %
Pita Integral	32 %
Pita linaza	26 %
Rosita	42 %
Tolin sésamo	24 %
Toscano	20 %

Compras

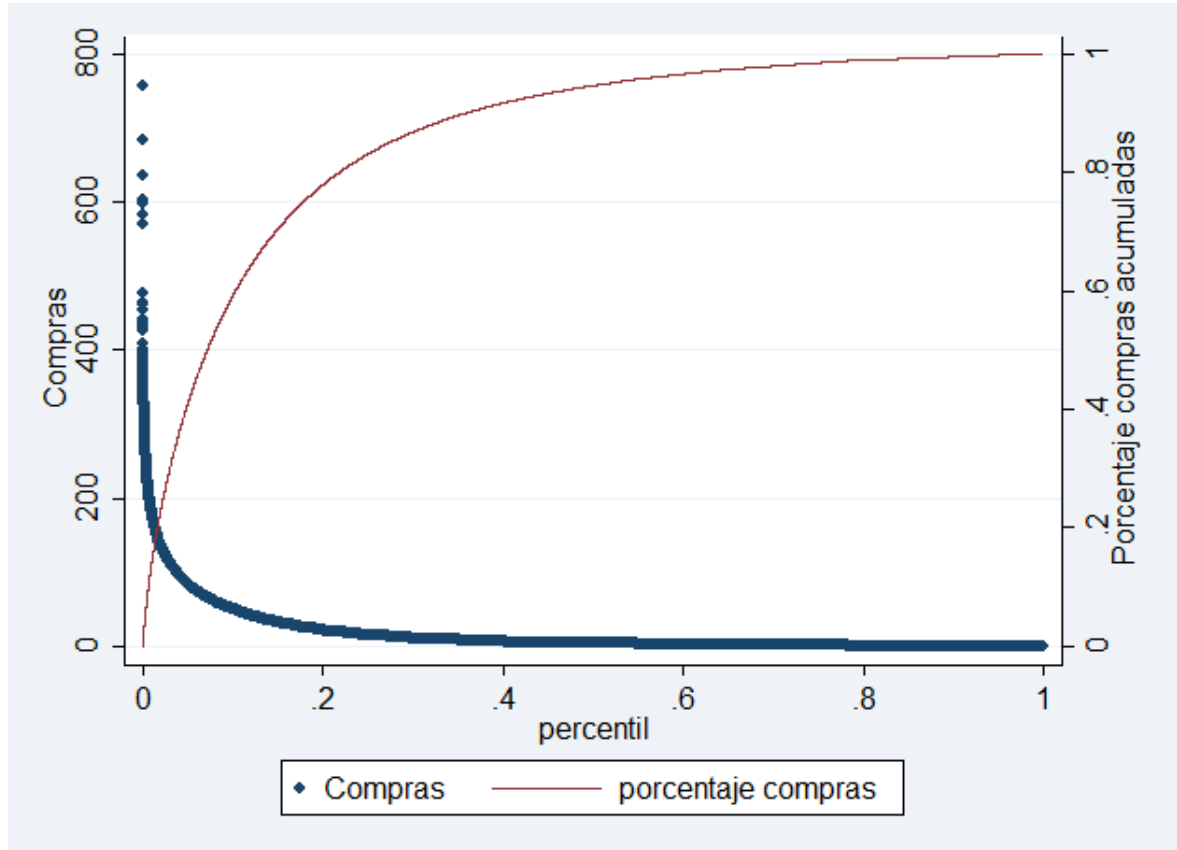


Figura 2.8: Clientes ordenados por percentiles de frecuencia de compra (Descendente). En el eje izquierdo se representa la frecuencia de compra y en eje derecho el porcentaje de las compras acumuladas que realiza cada percentil.

La información que entrega la figura 2.8 es muy importante. Éste gráfico ordena los clientes de mayor a menor frecuencia de compras y por otro lado se muestra el porcentaje acumulado de compras de estos clientes. La misma información se despliega en la tabla 2.5 y se muestra que el 20% de los clientes con mayor incidencia de compra, realizan el 78% de las compras. Esto significa que en la mayoría de las compras, serán hechas por clientes de quienes se tiene información de su comportamiento de compra. Esto indica que la información de la tarjeta de lealtad de un supermercado no sólo puede entregar información que refuerce las estrategias de marketing del retailer, si no que también puede entregar información valiosa desde el punto de vista operacional.

Por último, si se analizan lealtades de los distintos clientes mediante un histograma, se puede ver en las figuras 2.9 y 2.10 que existe una alta variabilidad de ellas. Esto es relevante al momento de seleccionar submuestras de datos. Por ejemplo en el caso la hallulla, existe más de un 15% de los clientes que nunca compra este producto y en el caso de la marraqueta, existe un segmento similar

Tabla 2.5: Cantidad de compras según percentiles

Percentil	Cantidad de Clientes	Compras	Compras acumuladas	Porcentaje acumulado
1 %	468	184	120122	14 %
5 %	2343	85	343929	41 %
10 %	4686	50	496498	59 %
15 %	7029	32	590770	71 %
20 %	9373	22	653185	78 %
25 %	11716	16	696592	83 %
30 %	14059	11	727821	87 %
40 %	18746	7	768635	92 %
50 %	23432	4	793379	95 %
60 %	28119	3	809683	97 %
70 %	32805	2	820797	98 %
80 %	37492	1	829288	99 %
90 %	42178	1	833974	100 %
100 %	46865	0	837820	100 %

de más de 10%; de tal manera que si un cliente perteneciente a estos segmentos no los compra, no entregará ninguna información adicional al modelo. Caso totalmente opuesto al segmento que tiene un 100% de lealtad, en el cual si uno de estos clientes no compra un producto, será muy relevante para inferir que este producto no está en stock.




Figura 2.9: Histograma lealtades Hallulla

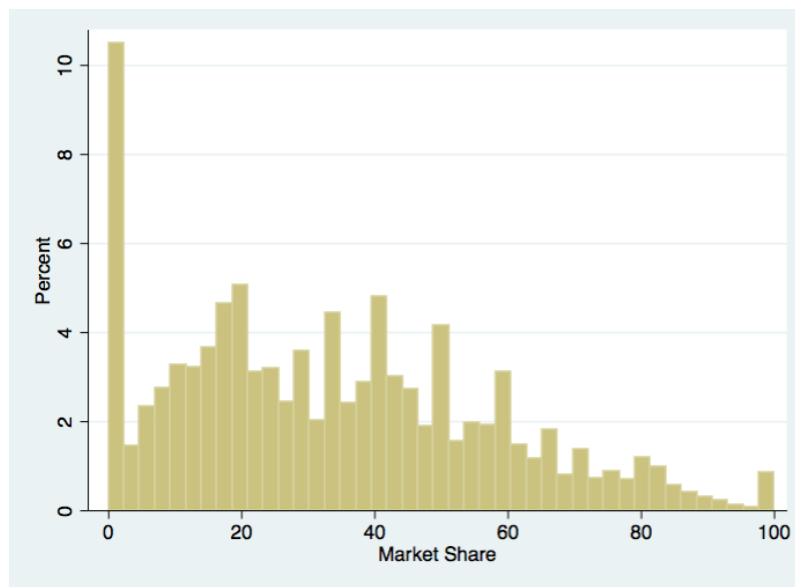


Figura 2.10: Histograma lealtades Marraqueta

Capítulo 3

Gráficos de Control

Los Gráficos de Control (*Control Charts* en inglés) o gráficos de Shewhart son una de las herramientas de Control Estadístico de Procesos más importantes y usadas en procesos manufactureros y la industria del servicio. Estos corresponden a representaciones gráficas usadas para el monitoreo de calidad de un determinado proceso y representarlo en su estado normal o *en control*. Para ello, estos gráficos definen una cierta *medida de calidad*, la cual ha sido obtenida de un muestreo, el cual se grafica en función del tiempo. Para la aplicación particular de la detección de quiebres de stock, se ha decidido utilizar el tipo de gráfico de control llamado de *Atributos*. Este tipo de gráficos es utilizado para procesos con características binarias, es decir, que cada unidad puede tomar sólo dos estados: *defectuoso* o *no defectuoso* y se define la medida de calidad como la fracción de productos *defectuosos* dentro de la muestra [15].

Las características básicas que contiene un Gráfico de Control se pueden ver en la figura 3.1 y son las siguientes:

- **Eje X:** Medida de calidad.
- **Eje Y:** Número de la muestra.
- **Línea Central:** Corresponde al valor promedio de la medida de calidad, cuando el proceso se encuentra en control.
- **Línea Superior de Control** :De aquí en adelante UCL, por su sigla en inglés. Corresponde al máximo valor que pueda tomar la medida de calidad para que el proceso se pueda seguir considerando en control.
- **Línea Inferior de Control** :De aquí en adelante LCL, por su sigla en inglés. Corresponde al mínimo valor que puede tomar la medida de calidad para que el proceso se pueda seguir considerando en control.

El principio estadístico utilizado detrás de este tipo de gráfico es modelar el proceso en función de una distribución *Binomial*. De esta manera, se considera que cada unidad producida

corresponde a la realización de una variable aleatoria de *Bernoulli*, con probabilidad p de ser defectuosa. Si se elige una muestra de n productos y se encuentra un número D de unidades defectuosas, entonces D tiene una distribución binomial de parámetros n y p , es decir:

$$(3.1) \quad P(D = x) = \binom{n}{x} p^x (1 - p)^{n-x}$$

En base a esta distribución, se fijan límites superior e inferior. Estos límites son calculados de tal manera que si el proceso está *en control* prácticamente todos los puntos caerán dentro de estos límites y no es necesario realizar ninguna acción. Sin embargo, si un punto llegase a caer fuera de estos límites, esto sería evidencia suficiente para decir que el proceso está *fuera de control* y es necesario realizar alguna acción para que el proceso vuelva a su estado original.




Figura 3.1: Ejemplo de un Gráfico de Control. Fuente: [15]

3.1. Metodología

El problema de los quiebres de stock en una sala de supermercado cuenta características similares a los procesos manufactureros descritos anteriormente. Esto hace pensar que la aplicación de esta metodología de trabajo para su detección puede ser exitosa. Al considerar los datos obtenidos del *Punto de venta* (POS por sus siglas en inglés) es posible considerar cada boleta como una variable de Bernoulli x_i la cual tendrá valor 1 si la boleta contiene el SKU analizado y 0 en caso contrario. Luego al tomar la fracción de boletas que contienen el SKU en un determinado período, se obtiene el *Market Share* del producto. Esta es una medida comúnmente usada en la industria del retail, por lo que no es difícil encontrar información histórica de una gran variedad

de productos, además facilita la implementación y la comprensión por parte del administrador de la cadena de supermercados, ya que es un concepto que conocen. De esta manera, la variación del *market share* de un SKU en el tiempo puede considerarse como un proceso que está representado por una distribución *Binomial*, en la cual, cada boleta corresponde a un ensayo de *Bernoulli* con una determinada probabilidad p de contener un producto. De esta manera en la aplicación de la metodología se tendrá la siguiente notación:

D_i	: Número de ventas del SKU en período i .
n_i	: Número de ventas de la categoría en período i .
p	: Probabilidad de venta del SKU
\bar{p}	: Estimador de p
σ	: Varianza del proceso
$\hat{\sigma}$: Estimador de σ

Para cada período la medida de calidad ocupada será el número de ventas del producto en ese período, dividido por el número de ventas totales en ese período, es decir:

$$(3.2) \quad \hat{p} = \frac{D_i}{n_i}$$

Por otro lado, la media y la varianza de \hat{p} pueden ser obtenidos de la distribución binomial:

$$(3.3) \quad \mu_p = \bar{p} = \frac{\sum D_i}{\sum n_i}$$

$$(3.4) \quad \hat{\sigma}_p^2 = \frac{\bar{p}(1 - \bar{p})}{n_i}$$

Elección de límites

El primer paso para la elaboración de un gráfico de control corresponde en fijar los límites superiores e inferiores del gráfico. Estos límites se calculan realizando una aproximación a la distribución normal del proceso y se definen pensando en qué porcentaje de los puntos del proceso se quiere que estén dentro de estos límites, si el proceso se encuentra *en control* (o en stock en este caso). Es decir, mientras más amplios sean estos límites, se disminuye la probabilidad de tener errores de *Tipo I*, o sea, de tener falsas alarmas, pero se aumenta el error de *Tipo II*, tener un proceso *fuera de control*, pero clasificado como *en control*. Al tener límites menos amplios, ocurre el proceso inverso. De esta manera se definen los límites del proceso de la siguiente forma:

$$\begin{aligned}
 (3.5) \quad & UCL = \bar{p} + Z_{\alpha} \hat{\sigma} \\
 & \text{LineaCentral} = \bar{p} \\
 & LCL = \bar{p} - Z_{\alpha} \hat{\sigma} \\
 & LCL \geq 0
 \end{aligned}$$

En la ecuación 3.5, Z_{α} constituye la distancia de los límites a la línea central y se obtiene de la tabla de la distribución normal, en la cual se quiere un error de *tipo I* de $100 - \alpha \%$. Para entender mejor cómo funciona un *Gráfico de Control*, se puede pensar en él como múltiples *test de hipótesis* que se realizan en el tiempo, en los cuales la hipótesis nula es que el proceso se encuentra en control estadístico, es decir que $\mu_{\hat{p}} = \bar{p}$. Así, si un punto del gráfico cae dentro de los límites definidos, significa que no se puede rechazar la hipótesis nula y si un punto cae fuera de los límites, entonces se puede rechazar la hipótesis nula y decir que $\mu_{\hat{p}} = \bar{p}$ con un $\alpha \%$ de certeza.

Usualmente, en muchas aplicaciones de calidad, se utiliza $Z_{\alpha} = 3$, que corresponde a un α de 99.99%, sin embargo, para este caso no es trivial elegirlo, teniendo en cuenta el *trade-off* entre tener un error de *tipo I* (Horas hombre mal utilizadas) versus tener un error de *tipo II* (Costo de tener un quiebre de stock).

Implementación de Gráfico de Control

Para la implementación de un gráfico de control, en primer lugar es necesario realizar una estimación de los parámetros a usar, lo que corresponde a calcular el valor de \bar{p} , UCL y LCL . Esto se hace utilizando data histórica del proceso. Así, se escogen datos de períodos pasados, con los cual se calcula el valor de \bar{p} de acuerdo a la ecuación 3.3 y con ello, también UCL y LCL .

Es importante tener en cuenta que estos dos límites son *provisorios*, ya que el objetivo es representar el sistema cuando está *en control*. Por esta razón, es necesario realizar un análisis de los puntos utilizados en la estimación para corroborar que efectivamente sean representativos de tal estado. Esto se realiza graficando estos puntos con los límites estimados. Si alguno de los puntos cae fuera de los límites, entonces es necesario revisar qué sucedió en ese período. Luego, si al realizar este ejercicio se descubre que en ese período ocurrió algo fuera de lo normal, ese punto debe ser retirado y la estimación de los límites se debe realizar nuevamente, sin este período.

Por lo mencionado anteriormente, se hace necesario que exista un período de calibración del sistema, donde se tome registro de la data y además de las situaciones que ocurran en cada período, este es llamado *Fase I*. En el caso del presente trabajo, se cuenta con data operacional de un intervalo de tiempo, que indica si el producto se encuentra o no en góndola (o sea, que el sistema está en *control*), por lo que se utilizará este intervalo para la calibración del sistema. Una vez calibrado el modelo, se pasa a la *Fase II*, que es donde se tiene una mejor estimación de todos los parámetros y el modelo debiese comportarse mejor.

Rational Subgrouping

La principal finalidad de los gráficos de control es poder detectar cambios que puedan indicar que el proceso está *fuera de control* por causa de algún desperfecto o un agente externo. Sin embargo existen varios factores que dificultan poder detectar estos cambios, siendo la variabilidad misma del proceso uno de los más importantes.

La incidencia de compra en una sala de supermercado presenta una alta variabilidad debido principalmente a las diferentes preferencias de compra que tienen los consumidores. Por esta razón, una de las principales hipótesis que se tratará de comprobar en esta tesis es que al utilizar la información con la que se cuenta de manera más selectiva, es posible representar el estado del sistema de mejor forma y aumentar la capacidad de detección. En este caso, usando la información histórica del comportamiento de compra de los clientes.

Segmentos de clientes informativos

Se plantea como hipótesis, que la identificación de segmentos de clientes altamente informativos permitirá mejorar los tiempos de detección de un modelo de control estadístico de proceso. Esto se basa en el hecho de que los límites de un gráfico de control dependen de la varianza del proceso, por lo que si es posible identificar segmentos de clientes que presenten una baja varianza en su comportamiento de compra, entonces se tendrá un gráfico con un rango de valores *en control* más estrecho y que permita identificar más rápidamente anomalías en el proceso de compra, como el que produce un quiebre de stock.

El modelo más básico de gráfico de Shewhart a utilizar, considera agrupar una suma variables de Bernoulli con probabilidad p de contener un determinado SKU, lo que, al analizar la fracción de variables que contienen el SKU, es considerado como una variable de Bernoulli. Sin embargo, la realidad es que estas variables de Bernoulli no son homogéneas, teniendo todas la misma probabilidad. Por el contrario, los gráficos 2.10 y 2.9, muestra que existe una gran heterogeneidad en las preferencias de cada cliente.

Por esta razón, se propone agrupar a los clientes según percentiles de preferencia de un determinado SKU y analizar submuestras en cada período. Como la varianza de este proceso depende inversamente del cuadrado del tamaño de la muestra, se debe ser cuidadoso en elegir submuestras lo suficientemente grandes para que lo que se gana en información al seleccionar los clientes, no se pierda por tener una muestra muy pequeña.

3.2. Modelo

Se definen las variables x_1, x_2, \dots, x_k como variables de Bernoulli, donde $x_k = 1$, si la k -ésima boleta contiene al SKU que está siendo analizado. Para este capítulo, se utilizarán los SKUs *Marraqueta*, *Hallulla*, *Coliza* y *Mendocino* y se cuenta con 1254 períodos con información operacional de los quiebres de stock, por lo que se ocuparán 400 períodos para la *fase I* de

calibración y los restantes 854 para el modelo en *fase II*.

Fase I

Utilizando los datos descritos en la sección 2.1, se agrupan las ventas en períodos de 30 minutos y se calcula por cada período el market share del producto, \hat{p} . Luego con el market share de cada período se procede a calcular \bar{p} de la ecuación 3.3, usando toda la data histórica disponible. luego para los primeros 400 períodos a analizar, se calcula $\hat{\sigma}_{\hat{p}}$. Los valores a utilizar son los mismos de la tabla 2.3 y se resumen a continuación en la tabla 3.1. Es importante recalcar que los valores de $\hat{\sigma}_{\hat{p}}$ corresponden a un promedio, ya que estos varían período a período, dependiendo del tamaño de la muestra.

Tabla 3.1: Valores de parámetros para gráficos de Shewhart

	Marraqueta	Hallulla	Coliza	Mendocino
\bar{p}	0.3453	0.2575	0.0393	0.0077
$\hat{\sigma}_{\hat{p}}$	0.0594216	0.0546464	0.0242837	0.0109243

Luego con estos valores se procede a calcular los valores del límite inferior LCL , de acuerdo a la ecuación 3.5. Para ello es necesario definir un Z_{α} que defina el nivel de falsas alarmas, utilizando una aproximación a la distribución normal. Para esta fase se ha definido como apropiado un $Z_{\alpha} = 1.96$, que corresponde a un $\alpha = 0,025$, es decir, un 2.5% de falsas alarmas. Los valores promedio se muestran en la tabla 3.2. Es importante señalar que el LCL resultó ser negativo en muchos períodos de el pan coliza y todos en el caso de el pan mendocino; estos valores debieron ser reemplazados por 0.

Tabla 3.2: Valores promedio límite inferior

	Marraqueta	Hallulla	Coliza	Mendocino
LCL	0.2269545	0.1486649	0.0015986	0

Con estos valores, se puede determinar qué períodos están en quiebre de stock. Por cada período se calcula si el market share de ese período es inferior o no al LCL de ese período. Si es así, significa que existe un quiebre de stock.

$$(3.6) \quad OOS = \begin{cases} 1 & \text{si } LCL_i < D_i \\ 0 & \text{si no} \end{cases}$$

Al aplicar esta a los datos de la fase I se obtienen los datos de la tabla ???. Como se observa en ella, el método tiene una efectividad regular para los SKU de alta rotación y muy mala para aquellos de media y baja rotación. Esto se debe a que los límites de control inferiores (salvo en algunos períodos en el pan coliza) son 0. Como el market share no puede ser negativo, significa que el modelo no podrá detectar quiebres en estos períodos.

Tabla 3.3: Quiebres detectados Fase I

	Quiebres durante Fase I	% de detección	Quiebres detectados
Marraqueta	53	0.340	18
Hallulla	28	0.429	12
Coliza	61	0.098	6
Mendocino	29	0.000	0

Fase II

Luego, con los quiebres de stock detectados y corroborados mediante la información operacional (tabla 3.3), se pueden calcular los valores actualizados de \bar{p} y $\hat{\sigma}_{\bar{p}}$, quitando del promedio a los períodos con quiebre de stock. Con estos valores, de igual manera que en la fase I, se calculan todos los parámetros del gráfico de Shewhart. En la tabla 3.4, se muestran los valores corregidos, los cuales han variado levemente de los valores registrados en la tabla 3.1. Esto va a depender principalmente de la cantidad de quiebres detectados y de qué porcentaje del tiempo permanece en quiebre de stock un producto. Si un producto permanece mucho tiempo en quiebre de stock, la baja en el market share será más notoria en el promedio. Nuevamente es necesario notar que los valores de $\hat{\sigma}_{\bar{p}}$ son el promedio en todos los períodos a analizar, debido a que estos varían dependiendo de la cantidad de boletas por período.

Tabla 3.4: Valores actualizados luego de Fase I

	Marraqueta	Hallulla	Coliza	Mendocino
\bar{p}	0.3349	0.2508	0.0408	0.0077
$\hat{\sigma}_{\bar{p}}$	0.0589731	0.0537655	0.0245427	0.0108418

Finalmente se calculan los valores de LCL para distintos valores de Z_{α} de acuerdo a las tablas de la distribución normal estandarizada. En particular, se analizarán los casos para tasa de falsas alarmas de 2.5%, 5% y 10%, cuyos valores son 1.96, 1.65 y 1.28, respectivamente. Los valores de estos límites se pueden ver en la tabla 3.5. En esta tabla se puede observar que los límites de control para la variable mendocino son todos iguales a 0, lo que indica que el modelo no será capaz de detectar quiebres en este SKU. Esto también ocurre en más del 60% de los períodos en el SKU coliza con α igual a 2.5%. En el apéndice B se pueden ver histogramas de los límites inferiores.

Tabla 3.5: Valores promedio límite inferior

	Marraqueta	Hallulla	Coliza	Mendocino
2.5%	0.2289	0.1447	0.0020	0
5%	0.2473	0.1614	0.0047	0
10%	0.2692	0.1815	0.0103	0

3.2.1. Segmentos de clientes según lealtad

Se analizó el registro histórico de compras de cada cliente registrado. Gracias a la información de la sección 2.4, se sabe que gran cantidad de los clientes tiene un historial de compras lo suficientemente grande como para hacer inferencias sobre la lealtad o preferencias de comprar por ciertos SKU. En particular, se seleccionaron aquellos clientes que cuenten con 5 o más compras realizadas en la categoría. Esta información ha sido agrupada en forma de percentiles de lealtad por cada SKU. De esta manera, se ordenan los clientes de mayor a menor lealtad, en el cual el percentil 10% corresponde al 10% de los clientes con mayor preferencia de compra por un SKU en específico y el percentil 100% corresponde a todos los clientes. Luego, se calcula una lealtad promedio de cada percentil, la cual equivaldrá al \hat{p} del modelo de gráfico de Shewhart. Las lealtades de los percentiles de los SKU seleccionados se muestran en la figura 3.2, donde se ve que la lealtad decrece rápidamente a medida que se va agrandando el subgrupo de clientes. La cantidad de clientes por cada percentil y el detalle de sus lealtades se puede ver en la tabla 3.6.

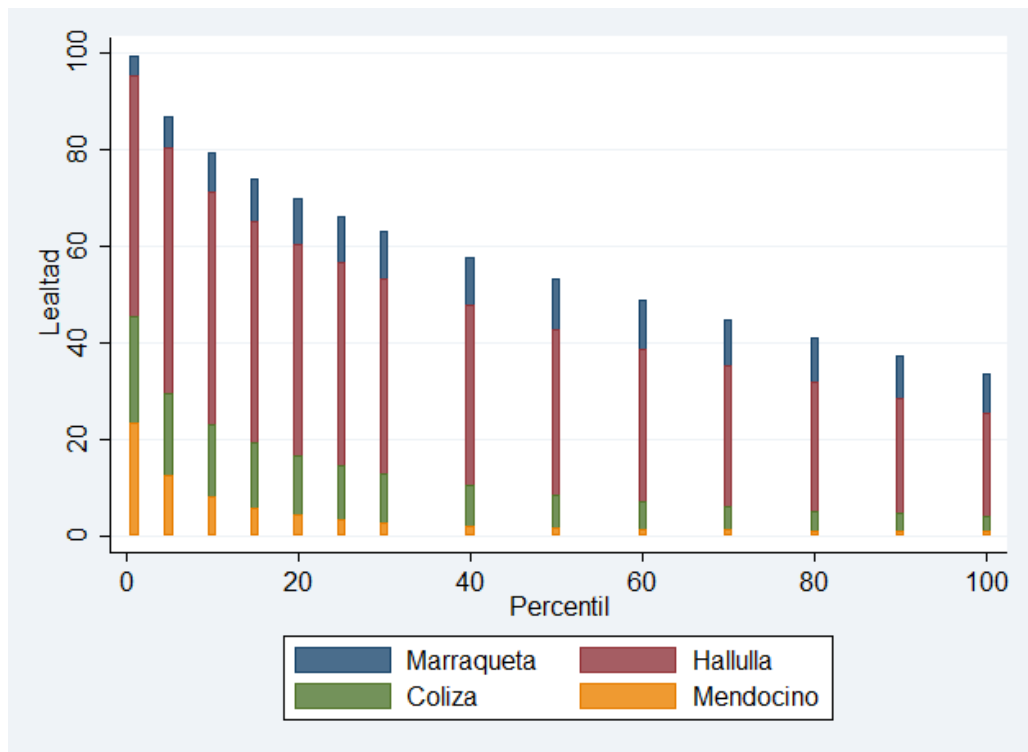


Figura 3.2: Lealtades por percentiles de clientes

El objetivo principal del *rational subgrouping*, es reducir al mínimo la variabilidad intrínseca del proceso generando subgrupos lo más homogéneos posible. De las figuras 2.9 y 2.10, se sabe que las preferencias de compra de los clientes distan bastante de ser homogéneas. Por esta razón, existirá la tentación de generar grupos muy pequeños, lo más homogéneos posible, con tal de reducir la varianza del proceso y mejorar la capacidad de detección del gráfico de Shewhart. Sin embargo, existe un *trade off* que es necesario sopesar y corresponde al hecho que la varianza

Tabla 3.6: Lealtad según percentiles

Percentil	Cantidad de clientes	Marraqueta	Hallulla	Coliza	Mendocino
1 %	227	99.4	95.3	45.2	23.4
5 %	1138	86.9	80.4	29.3	12.5
10 %	2276	79.3	71.2	22.9	7.9
15 %	3414	73.8	65.2	19.2	5.6
20 %	4552	69.7	60.5	16.6	4.2
25 %	5691	66.1	56.5	14.6	3.3
30 %	6829	63.0	53.3	12.9	2.8
40 %	9105	57.6	47.7	10.3	2.1
50 %	11382	53.0	42.8	8.3	1.7
60 %	13658	48.7	38.7	6.9	1.4
70 %	15934	44.6	35.0	5.9	1.2
80 %	18211	40.9	31.6	5.2	1.0
90 %	20487	37.1	28.3	4.6	0.9
100 %	22764	33.4	25.5	4.1	0.8

también depende inversamente del tamaño de la muestra, por lo que tampoco será conveniente utilizar segmentos demasiado pequeños.

Por estas razones se analizaron distintos percentiles, con el fin de comparar los resultados que se obtengan. Para el cálculo de los *LCL* se utilizaron los valores de la tabla 3.6 y sus resultados se muestran en la tabla 3.7.

Tabla 3.7: Valores promedio límite inferior por percentiles ($\alpha = 5\%$)

	Marraqueta	Hallulla	Coliza	Mendocino
Percentil 30 %	0.44122	0.32831	0.01862	0
Percentil 40 %	0.41174	0.30700	0.02305	0
Percentil 50 %	0.38530	0.28286	0.01734	0
Percentil 60 %	0.35776	0.25513	0.01230	0
Percentil 70 %	0.32662	0.26035	0.00921	0
Percentil 80 %	0.29771	0.21146	0.00724	0
Percentil 100 %	0.24725	0.16145	0.00466	0

3.3. Resultados

Con los parámetros calculados en la sección anterior, se procedió a la implementación de los gráficos de Shewhart de los tres de los cuatro SKU propuestos. Para el caso del SKU Mendocino, no se mostrarán resultados, puesto que el modelo fue totalmente inefectivo a la hora de detectar quiebres de stock. La aplicación del modelo se realizó en 854 de los 1254 períodos de tiempo de 30 minutos, en los cuales se tiene información operacional sobre los quiebres de stock, debido a

que los primeros 400 fueron utilizados en la fase I como calibración.

Según niveles de α

En las figuras 3.3 se observa que los niveles de detección mejoran al aumentar α , lo que es totalmente esperable, ya que se estrecharon los límites y por lo tanto más puntos caerán fuera. Para el caso de la marraqueta, los niveles de detección están en el rango del 40-50%, en el caso de la hallulla, del 30-40% y en la coliza el rango es más amplio y está entre el 15-45%. Este aumento tan notable en la detección de quiebres en el pan coliza se debe principalmente a que en los niveles de α de 2.5% y 5%, la gran mayoría de los *LCL* son igual a 0 (65% y 45% respectivamente), lo que hace que el modelo no se pueda aplicar en estos casos y cuando se cambia α a un 10%, la cantidad de *LCL* igual a 0 disminuye drásticamente a 16%, lo que permite aplicar el modelo en la mayoría de los períodos. El detalle de la cantidad de quiebres de stock detectados se puede ver en la tabla C.1.

Con respecto a las falsas alarmas, el primer punto a notar es que éstas no se comportaron de acuerdo a lo diseñado. En las figuras 3.3, se observa que para la marraqueta y hallullar, la tasa de falsas alarmas es más del doble que el α diseñado. El caso del pan coliza es especial debido a que para muchos de los períodos no se pudo aplicar el modelo, por lo que la cantidad de datos analizados es mucho menor.

Una posible explicación a esta discordancia entre lo diseñado y el resultado real, es lo mencionado en la sección 3.1. En la metodología se realizó una simplificación al considerar el proceso de compras de los clientes como una suma de variables de Bernoulli de probabilidad p . La realidad es que la gama de preferencias de compras de los distintos clientes es mucho más amplia. Esto hace subestimar la varianza en el modelo, lo que genera un *LCL* más estrecho que la realidad.


Sin embargo, teniendo en cuenta esto, si se quisiera generar límites más amplios, esto necesariamente aumentará la cantidad de quiebres no detectados. Esto se puede observar en los histogramas de las figuras 3.5.

Percentiles de clientes


En las figuras 3.4 se observa que la tasa de detección de quiebres mejora al utilizar percentiles de clientes. En el caso de la marraqueta el mejor resultado se obtiene en el percentil 60% seguido del percentil 40%, existiendo una diferencia de 2 quiebres más detectados. En el caso de la hallulla, el mejor modelo corresponde al percentil 40%, seguido del percentil 50%, en este caso, con una diferencia de apenas 1 quiebre adicional. Por último, en el caso del pan coliza, se aprecian diferencias significativas en las tasas de detección, existiendo diferencias notorias entre el modelo sin subgrupos, con un 27% y el percentil 40% con un 43%. Nuevamente, esto se explica por los histogramas del apéndice B, donde se muestra la distribución de los *LCLs* de acuerdo a cada percentil y se aprecia que en los modelos con menor tasa de detección, la proporción de límites inferiores igual a 0 es mayor.

Con respecto a las falsas alarmas, se observa que la teoría sobre la subestimación de la varianza puede ser real. Al agrupar los clientes de acuerdo a percentiles de lealtad, se reduce el error generado por la variabilidad de p . En las figuras 3.4, se observa que en el caso de la marraqueta y la hallulla, la tasa de falsas alarmas baja consistentemente a medida que se aplica un percentil más pequeño. Nuevamente, el caso del pan coliza es especial, debido a que los resultados no están sobre la misma cantidad de casos aplicados.


En la tabla 3.6 se muestra que todos los percentiles tienen una cantidad de clientes similar. Si bien, los clientes del mismo percentil para un determinado SKU pueden realizar un mayor número de compras que para otro SKU, en general, el número de compras debiese mantenerse parejo. Por esta razón, el número de compras filtradas para todos los SKU debiese ser parecido y es por esta razón que se repite el percentil 40% como uno de lo que mejor se comporta. Esto se debe a que para esta categoría en particular, el trade-off entre la reducción del tamaño de la muestra y la reducción de variabilidad debido a la agrupación de clientes. Sin embargo, para otras categorías, no debiese esperarse que se repita este percentil como uno de los mejores. Dependerá del categoría a categoría del número de compras.



(a) Marraqueta




(b) Hallulla




(c) Coliza


Figura 3.3: Niveles de detección según α



(a) Marraqueta




(b) Hallulla




(c) Coliza


Figura 3.4: Niveles de detección según α



(a) Marraqueta



(b) Hallulla



(c) Coliza

Figura 3.5: Histogramas market share de períodos según caso

Capítulo 4

Cumulative Sum

En el capítulo 3 se utilizaron gráficos de Shewhart para generar un modelos de detección de quiebres de stock. Una de las principales ventajas de este método corresponde a su simplicidad, que si bien es uno de objetivos de este trabajo de tesis, también posee una serie de desventajas que hacen necesario buscar otras metodologías. Dentro de estas desventajas, existen dos que son relevantes para el problema de un quiebre de stock.

La primera corresponde al uso de este tipo de gráficos cuando p_0 (market share en este caso) es bajo y el número de productos inspeccionados es (n) también es pequeño, como es el caso de productos con bajo market share, en una categoría de baja rotación o en horas de bajo flujo de ventas. Recordar que los gráficos de Shewhart realizan una aproximación de la distribución Binomial por una distribución Normal, la cual generalmente no es buena cuando n y p_0 son bajos. De esta manera los límites de control elegidos en los gráficos Shewhart utilizando la distribución Normal pueden resultar una tasa de falsas alarmas mayor a la deseada. Si bien Ryan y Schwertmann [20] realizan algunas recomendaciones sobre cómo calcular los límites en estos casos, realizando transformaciones de la data o calculándolos mediante la distribución binomial, ninguno de estos métodos es muy efectivo.

Además, dado que los límites dependen de p y n , si el valor de p es muy pequeño, existirán problemas con el límite inferior. Éste, tomará valores negativos si el valor de n no es lo suficientemente grande. Para contextualizarlo a los datos con los que se realiza este trabajo, en la base de datos se agruparon las compras en muestras equivalentes a un período de 30 minutos, en donde se realizan un promedio de 88 ventas (n). Si calculamos los límites inferiores, utilizando los valores de Z del capítulo 3, tendremos que estos serán negativos a partir de un *market share* de 4%. Es decir, si revisamos la tabla 2.3, del capítulo 3, se ve que sólo se podrán utilizar para los SKU *marraqueta* y *hallulla* y sólo en determinados casos, cuando exista una alta incidencia de venta, para el pan *coliza*.

La segunda desventaja, corresponde a la utilización de muestras de tamaño n para la utilización de gráficos de Shewhart. En casos como el presentado en este trabajo, se tiene un flujo constante de datos, en donde cada observación del POS, corresponde a una variable de Bernoulli. Estos datos deben ser artificialmente agrupados para generar una muestra, por lo

que se deberá esperar hasta el fin del período de agrupación (30 minutos en este caso), para poder tener información sobre si existen o no indicios para detonar una alerta; aún cuando el desajuste podría haber ocurrido al comienzo del período. Además, el hecho de analizar las muestras individualmente, sin hacer uso de las muestras pasadas, hace que se pierda información valiosa, lo que hace que los gráficos de Shewhart sean poco sensible a cambios pequeños en p , si n no es muy grande.

Como una mejor alternativa para todos estos problemas, nacen los gráficos de suma acumulativa (de ahora en adelante CUSUM por su nombre en inglés). Estos fueron desarrollados por Page [17] en 1954 inicialmente para variable con distribución normal, pero han sido adaptados para variables binomiales, Poisson y Bernoulli.

Los gráficos CUSUM van acumulando la información pasada, al ir gráficamente la suma acumulada de las desviaciones de cada observación con respecto a un valor objetivo, representativo de cuando el proceso se encuentra *en control*. El tipo de gráficos CUSUM más utilizados es el tabular o algorítmico. Este se define como la acumulación de desviaciones de un valor objetivo p_0 . Para ello utilizan un estadístico C^+ para desviaciones por sobre p_0 y un estadístico C^- para desviaciones por debajo de p_0 . Dado un conjunto de observaciones x_i de media p_0 , estos estadísticos son calculados de la siguiente manera:

$$(4.1) \quad C_i^+ = \max[0, x_i - (p_0 + k) + C_{i-1}^+]$$

$$(4.2) \quad C_i^- = \max[0, (p_0 - k) - x_i + C_{i-1}^-]$$

$$(4.3) \quad C_0^+ = C_0^- = 0.$$

En donde k es llamado **valor de referencia** y es calculado utilizando el método *sequential probability ratio test* (SPRT) desarrollado por Wald [23] en 1949 y cuyo valor dependerá del valor p_1 , que corresponde al cambio en la data que se quiere detectar. Ambos estadísticos, C^+ y C^- , tendrán un **umbral de decisión** h , el cual si es superado, indicará que el proceso se encuentra *fuera de control* y necesita ser corregido. A continuación se presentará una metodología de gráficos CUSUM para detectar quiebres de stock en una sala de supermercado.

4.1. Metodología

Como ya se ha mencionado anteriormente, la forma para utilizar la data de POS con la que se cuenta será usando cada boleta de venta de una categoría como una observación que puede o no contener un determinado SKU, lo que puede ser interpretado como una variable de Bernoulli con probabilidad p de contener este SKU.

Este es un problema común en la industria y fue tratado inicialmente por Bourke [3] en 1991, analizando el número de observaciones que existen entre observaciones positivas, lo cual tiene una

distribución geométrica. Éste enfoque fue propuesto por Fisher y Raman [8], quienes proponen un método para analizar períodos de cero ventas para la detección de quiebres de stock. Si bien este es un enfoque interesante, no es posible de utilizar con los datos de este trabajo. Esto, debido a que la información sobre los quiebres de stock no es exacta, ya que considera un quiebre de stock cuando existe menos de un 20% del producto, por lo que la data muestra que siguen existiendo ventas, aún cuando se reporta un quiebre de stock. A esto también se suma que una persona puede pasar un largo tiempo dentro de una sala de supermercado, por lo que el momento en que fue a buscar un producto no es el mismo que cuando pasa por la caja registradora. Por otro lado, Gan [9] propone agrupar las observaciones en muestras de tamaño n y analizar la proporción de observaciones con venta del SKU, lo cual sigue una distribución binomial, de donde proviene su nombre, Binomial CUSUM. El problema con este método es que el diseño de un Binomial CUSUM, es decir, la definición del *valor de referencia* k y el *umbral de decisión* h , se realizan en función del *número de observaciones promedio hasta detonar una señal* (average number of observations to signal, ANOS), la cual a su vez dependerá de n , que en este caso es variable, lo que dificulta enormemente su cálculo.

Finalmente, son Reynolds y Stoumbos [19] quienes proponen quienes desarrollan el método Bernoulli CUSUM, utilizando observaciones individuales con distribución de Bernoulli, el cual es propuesta en este trabajo para detectar disminuciones en el market share de un determinado producto, indicando la existencia de un quiebre de stock.

Bernoulli CUSUM

Sean X_1, X_2, X_3, \dots una secuencia de observaciones independientes de Bernoulli, en donde $X_k = 1$ si la k -ésima observación cae en la categoría que se quiere analizar y $X_k = 0$ si no. Para la mayoría de las aplicaciones se analizan defectos y para este trabajo en particular, se analizará si la observación contiene un determinado SKU. Se define p como $P(X_k = 1)$ y el objetivo del Bernoulli CUSUM será detectar una disminución de p de su valor cuando está en *en control* desde p_0 a otro valor $p < p_0$. El estadístico para este tipo de CUSUM se calcula de la siguiente manera:

$$(4.4) \quad B_k = \min(0, B_{k-1}) + (X_k - \gamma_B), k = 1, 2, \dots$$

$$(4.5) \quad B_0 = 0$$

En donde γ_B corresponde al **valor de referencia**. Esta constante puede ser elegida usando la representación un gráfico CUSUM como una secuencia de SPRTs para probar la hipótesis nula $H_0 : p = p_0$ versus la hipótesis alternativa $H_1 : p = p_1$ [18] [9], en donde se determina el valor óptimo de γ_B para detectar este cambio de p está determinado por las constantes r_1 y r_2 :

$$(4.6) \quad r_1 = -\ln\left(\frac{1 - p_1}{1 - p_0}\right)$$

$$(4.7) \quad r_2 = \ln\left(\frac{p_1(1-p_0)}{p_0(1-p_1)}\right)$$

$$(4.8) \quad \gamma_B = \frac{r_1}{r_2}$$

En [19] se muestra que γ_B tiene su valor óptimo para detectar un cambio en p , usando la ecuación 4.8. De esta manera un gráfico Bernoulli CUSUM generará una alarma de que ha habido una disminución de p si $B_k \leq h_B$, donde $h_B < 0$ es el *límite de control*. Las constantes r_1 y r_2 tomarán valores negativos cuando $p_1 < p_0$, por lo que γ_B será positivo. Cuando se busca una disminución de p , significa que habrá un aumento de observaciones en donde $X_k = 0$, por lo que $X_k - \gamma_B = -\gamma_B < 0$. Llevando esto al caso de la detección de quiebres de stock, cada vez que exista una observación sin el SKU analizado, se sumará al estadístico un valor de $-\gamma_B$ y se detonará una alerta cuando exista el estadístico caiga lo suficientemente abajo de 0.

Estimación de tasa de falsa alarma

Al momento de diseñar cualquier método de *Control Estadístico de Proceso*, uno de los principales aspectos que se debe tener en cuenta es la tasa de falsas alarmas que se tendrá. Si el método tiene una alta tasa de falsas alarmas, se perderá credibilidad y además está el costo asociado a la inspección de estas falsas alarmas. Al igual que en los gráficos de Shewhart, donde se define el *average run length*(ARL) como el número esperado de muestras requeridas para detonar una señal, en este caso se define el *número de observaciones promedio hasta detonar una señal*(ANOS) y que equivaldrá al ARL multiplicado por el tamaño de la muestra.

De esta manera, es deseable un ANOS relativamente grande cuando $p = p_0$, de tal manera que la tasa de falsas alarmas sea baja y por otro lado, cuando p cambie de valor (por un quiebre de stock en este caso), será deseable un ANOS pequeño, para detectarlo rápidamente. En la sección anterior se definió p_1 , como el cambio en p que queremos que sea detectado rápidamente. Es decir, es de interés calcular $\text{ANOS}(p_0)$ y $\text{ANOS}(p_1)$.

Existen principalmente dos enfoques para el cálculo del ANOS en un gráfico Bernoulli CUSUM. El primero consiste en modelar el estadístico CUSUM como una cadena de Markov [17]. Para la utilización de este método, se requiere que r_1/r_2 sea de la forma $1/m$ en donde m es un número entero. Luego de cada período se sumará $X_k - \gamma_B$, el cual tomará un valor de $m - 1/m$ si la observación es positiva y un valor de $-1/m$ en caso contrario. Con esto, se construirá una cadena de Markov, en que cada estado tendrá un valor de $-1/m, -2/m, -3/m, \dots, L/m$, donde $L/m = h_B$ es el estado absorbente, que corresponde al umbral de decisión.

Si bien, este método calcula el valor exacto del ANOS, presenta los inconvenientes de tener que modificar el valor de p_1 para que γ_B sea de la forma $1/m$ y también que se deben realizar el cálculo de varios parámetros para llegar al valor que se busca, lo cual puede resultar engorroso, sobre todo cuando el objetivo es realizar el cálculo del ANOS varias veces, para probar distintas combinaciones de parámetros. Las ecuaciones necesarias para calcular el ANOS de esta forma, se pueden encontrar en [18].

El segundo método corresponde al llamado método de aproximación mediante difusión corregida (*corrected diffusion*, CD). Este método fue desarrollado por Reynolds y Stoumbos [19], al extender el trabajo de Siegmund [21], modelando el estadístico CUSUM como un proceso de movimiento Browniano. Si bien, para procesos en los cuales p es muy pequeño ($p < 0,001$), Chang y Gan [4] han mostrado que esta aproximación no funciona bien, reportando errores de hasta un 13%, estos valores son poco usuales en el retail, por lo que se usará este procedimiento para el cálculo del ANOS. Las formulas que se utilizarán son bastante sencillas y su desarrollo queda fuera del alcance de esta tesis, pero se pueden ver en [19].

La aproximación CD utiliza un valor ajustado de h_B , cuya formula es

$$(4.9) \quad h_B^* = h_B - \varepsilon(p_0) * \sqrt{p_0 * (1 - p_0)}$$

donde $\varepsilon(p_0) * \sqrt{p_0 * (1 - p_0)}$ corresponde al exceso límite esperado del estadístico B_k sobre h_B . El valor de $\varepsilon(p)$ puede ser aproximado por

$$(4.10) \quad \varepsilon(p) \approx \begin{cases} 0,410 - 0,0842(\ln(p)) - 0,0391(\ln(p))^3 - 0,00376(\ln(p))^4 - 0,000008(\ln(p))^7 & \text{si } 0,01 \leq p \leq 0,5 \\ \frac{1}{3}(\sqrt{\frac{1-p}{p}} - \sqrt{\frac{p}{1-p}}) & \text{si } 0 < p \leq 0,01 \end{cases}$$

De esta forma, tomando r_1 y r_2 como constantes (calculadas con p_0 y p_1), se calcula el ANOS usando la aproximación CD con la siguiente ecuación

$$(4.11) \quad ANOS(p) \approx \frac{\exp(h_B^* r_2) - h_B^* r_2 - 1}{|r_2 p - r_1|}$$

Utilizando la ecuación 4.11 para $p = p_0$, se determinará la tasa de falsas alarmas y con $p = p_1$ se determinará la rapidez del modelo para detectar un cambio de p_0 a p_1 .

Diseño de un gráfico Bernoulli CUSUM

Resumiendo el proceso para el diseño de un gráfico Bernoulli CUSUM, se definen los siguientes pasos:

Paso 1: Determinar el valor *en control* p_0 y *fuera de control* p_1 , para calcular r_1 , r_2 y γ_B (ecuaciones 4.6, 4.7 y 4.8). Es importante recalcar que como el sistema pasará la mayor parte del tiempo *en control*, por lo cual es necesario realizar una buena estimación de p_0 , de lo contrario, aumentará mucho el número de falsas alarmas.

Paso 2: Decidir un ANOS para cuando el sistema esté *en control*. Generalmente se decidirá esto teniendo en cuenta la tasa de observaciones que se tendrá por unidad de tiempo y el costo de una inspección producto de una falsa alarma.

Paso 3: Con la información de los pasos 1 y 2, se utiliza la ecuación 4.11 con $p = p_0$ para encontrar un valor de h_B^* , para luego usando las ecuaciones 4.10 y 4.9, determinar el valor necesario de h_B para alcanzar este ANOS.

Una forma intuitiva de ver el valor de h_B es calculando $L_B = -h_B/\gamma_B$. Así se tendrá una idea del número máximo de observaciones sin ventas necesarias para detonar una alerta.

4.2. Modelo

Utilizando los datos descritos en 2.1, se agrupan todas las ventas registradas en la categoría *pan a granel* en orden cronológico. Cada venta estará asociada a un período de 30 minutos con la información operacional si en ese momento existió o no un quiebre de stock. Luego se define X_1, X_2, \dots, X_k como variables de Bernoulli, de tal manera que $X_k = 1$, si la k -ésima venta registrada corresponde al SKU que se está analizando en el momento. En este capítulo, se utilizarán dos SKUs de alta rotación, *Marraqueta* y *Hallulla*, un SKU de rotación media, *Pita Blanco* y un SKU de rotación baja, *Pan de Anís*.

Se define p como el market share en la categoría de un determinado SKU. Se determina p_0 como el market share de un producto cuando el producto se encuentra en stock y p_1 cuando el producto está en quiebre de stock. Éste valor será el cambio en p que se quiere detectar de manera óptima. Luego de esto, se calculan los valores de r_1 , r_2 y γ_B . Los valores de estos parámetros para los SKU elegidos se definen en la tabla 4.1:

Tabla 4.1: Parámetros para diseño de Bernoulli CUSUM

	Marraqueta	Hallulla	Pita Blanco	Anís
p_0	0.334	0.243	0.027	0.011
p_1	0.265	0.219	0.012	0.005
r_1	-0.099	-0.031	-0.015	-0.005
r_2	-0.333	-0.136	-0.803	-0.717
γ_B	0.299	0.231	0.018	0.008

Al revisar el valor de estos parámetros para cada SKU, se puede ver que hacen bastante sentido. Recordar que el estadístico CUSUM sumará $1 - \gamma_B$ si existe una venta y $-\gamma_B$ en caso contrario. Para el caso de la marraqueta, la diferencia será de 0.701 versus 0.299, en cambio para el caso del pan de anís es de 0.902 versus 0.008. Esto indica que la evidencia de una venta en el caso del pan de anís es mucho más fuerte para descartar que exista un quiebre de stock en ese período. De hecho, una venta equivaldrá a 112.75 períodos sin ventas.

Luego de esto se procede a definir un ANOS para cuando el sistema se encuentre en control. A diferencia de los valores normalmente ocupados en SPC [19], que van de 15000 observaciones

en adelante, es necesario tener en cuenta que este tipo de procesos es diferente. Un proceso SPC trabaja bajo el límites de calidad 3σ , debido principalmente a que es muy costoso realizar una inspección del proceso (es necesario parar producción), lo cual se traducirá en una pérdida si el modelo produjo una falsa alarma. En este caso, el costo es mucho más bajo, no es necesario detener el proceso de ventas, si no que basta con enviar a un trabajador de planta a revisar la góndola o incluso, sólo activar una cámara, como con las cuales se obtuvo los datos operacionales para este trabajo.

Por estas razones, al igual como se hizo en el capítulo 3, se definirá un un $ANOS(p_0)$ menor al estándar de SPC, un valor en torno a las 900 observaciones. Teniendo en cuenta, que en promedio, en cada período de 30 minutos hay 83 ventas, esto significa, que si no existe un quiebre de stock, se producirá una falsa alarma cada 10.84 período, lo que equivale a 5 horas y 25 minutos.

Con esto en cuenta, se utilizan la ecuación 4.11 para calcular el ANOS, utilizando los valores de la tabla 4.1. Como se mencionó en la sección anterior, se utilizará la forma $h_B = -L_B/\gamma_B$ para realizar iteraciones y probar distintos valores de h_B . Los valores utilizados en el modelo se detallan a continuación

Tabla 4.2: Límites de control

	Marraqueta	Hallulla	Pita Blanco	Anís
h_B^*	-8.0297263	-9.9652646	-2.7572089	-2.0727401
h_B	-7.7710884	-9.6972819	-2.4360158	-1.7467898
L_B	26	42	132	275
$ANOS(p_0)$	912.099962	916.520215	902.330249	901.024815
$ANOS(p_1)$	153.783364	377.991171	260.014887	419.570845

Como se observa en la tabla 4.2, el $ANOS(p_1)$ de ninguno de los SKU analizados es menor que el promedio de observaciones de un período (83). Por esta razón, es esperable que si los quiebres de stock son cortos, de un período o menos, no será posible detectarlos.

Finalmente en la implementación del estadístico CUSUM, B_k , se tuvo en consideración que, en el caso de este trabajo, se utiliza información histórica. En una implementación real, cada vez que el modelo detecta un quiebre de stock, se realizarán acciones para corregir este quiebre de stock o también, comprobar que se trató de una falsa alarma. El problema con trabajar con información histórica, es que no se pueden tomar acciones al respecto. De esta manera, el estadístico B_k sólo será reiniciado a 0, cuando exista una falsa alarma. En el caso de una detección de quiebre de stock, no se reiniciará el estadístico, debido a que no se sabe si se tomaron acciones para corregirlo.

4.3. Resultados

Con los parámetros calculados en la sección anterior, se procedió a la implementación del gráfico de Bernoulli CUSUM para los cuatro SKU propuestos. Esto se hizo durante los 45 días en los cuales se tiene información operacional de los quiebres de stock, en períodos de 30 minutos, lo que equivale a 1254 períodos en total. En la tabla 4.3 se muestra la cantidad de alarmas detonadas,

diferenciadas por los casos en que la información operacional indica que efectivamente existió un quiebre de stock y en el caso contrario, es decir, las falsas alarmas

Tabla 4.3: Alarmas generadas

(a) Marraqueta

Quiebre	Nº Períodos	% Períodos con Alarmas	Nº Alarmas	Porcentaje del total
No	1084	0.1383764	150	0.641
Si	170	0.4941176	84	0.359
Total	1254	0.1866029	234	

(b) Hallulla

Quiebre	Nº Períodos	% Períodos con Alarmas	Nº Alarmas	Porcentaje del total
No	1178	0.1578947	186	0.857
Si	76	0.4078947	31	0.143
Total	1254	0.1730463	217	

(c) Pita Blanco

Quiebre	Nº Períodos	% Períodos con Alarmas	Nº Alarmas	Porcentaje del total
No	938	0.125	117	0.430
Si	308	0.503	155	0.570
Total	1246	0.218	272	

(d) Anís

Quiebre	Nº Períodos	% Períodos con Alarmas	Nº Alarmas	Porcentaje del total
No	896	0.100	90	0.338
Si	358	0.492	176	0.662
Total	1254	0.212	266	

Detección

Revisando la tasa de detección del modelo en los distintos SKU, se observa que el modelo es capaz de detectar entre un 49-50% de los quiebres de stock en 3 de los 4 SKU. Sin embargo, en el caso de SKU hallulla, sólo se detecta un 40% de los casos. Esto se podría explicar principalmente a la baja variación que existe entre el estado con stock y con quiebre de stock de este producto, en donde p_0 es un 24.3% y p_1 es un 21,9%, es decir, una variación de un 10%. Esto sin duda hace mucho más difícil la detección. Por otro lado, cabe destacar la detección de los quiebres de stock en los SKU de rotación media y baja. En el caso del pan pita blanco, es un producto que se vende poco más de 49 unidades diarias y el pan de anís poco más de 18 unidades diarias. Su venta es tan baja, que hace imposible la detección de quiebres de stock con otro método SPC y es en estos casos, donde se hace importante una de las característica diferenciadoras de los gráficos CUSUM versus los gráficos de Shewhart: el uso de la información de varios periodos hacia atrás.

Rapidez de detección

Al revisar el valor del $ANOS(p_1)$ en la tabla 4.2, se observa que el este valor es mucho más pequeño para la marraqueta que para el resto de los productos analizados. Esto hacía pensar que el modelo se comportaría de mejor manera en este producto que en el resto para la detección de quiebres de stock en períodos más acotados. Esto se puede comprobar en el gráfico 4.1a, en donde se presenta el estadístico B_k un día en que ocurrieron distintos quiebres de stock de no más de una hora. Ahí se ve que el modelo es capaz de detectar la mayoría de los quiebres. Si se analiza una situación similar para el resto de los SKU, en los gráficos 4.1b, 4.2a y 4.2b, se observa que esto no ocurre y sólo en el caso de la hallulla se observa un poco más de sensibilidad frente a quiebres pequeños.

Por otro lado, en el caso de los quiebres más prolongados, los gráficos para el pan pita blanco(4.2a) y anís(4.2b), muestran que el modelo es bastante efectivo en detectar este tipo de quiebres, precisamente por la acumulación de información de varios períodos hacia atrás. Si bien, la detección no es inmediata y pueden pasar varios períodos antes de ello, finalmente son detectados, cosa que no habría sido posible con sólo la información de un períodos en particular.

Falsas alarmas y quiebres no detectados

Al revisar la tabla 4.3, resulta evidente que el modelo dista de ser perfecto en la detección de quiebres de stock. Se observa que en los SKU de alta rotación (4.3a y 4.3b) las falsas alarma superan ampliamente a los quiebres detectados sobre todo en el caso de la hallulla, donde el 85.7% de las alarmas corresponde a quiebres de stock. Si bien, la situación mejora para los productos de más baja rotación, aún existe una cantidad considerable de falsas alarmas.

Por esta razón se hace importante realizar un análisis de las falsas alarmas y también de los casos en que los quiebres de stock no fueron detectados. Para ello, ase analizó el market share de los SKU luego de la aplicación del modelo de Bernoulli CUSUM y contrastados estos resultados con la data operacional. De esta manera, al igual como se realizó en la sección 3.3, se muestra en la tabla 4.4 el promedio del market share y la cantidad de observaciones por cada caso. Los histogramas de estos casos se puede ver en el apéndice D.

En estas tablas, el primer dato que salta a la vista es el alto market share que tienen los casos de quiebres no detectados, llegando al extremo en los productos marraqueta y hallulla de ser mayor incluso que el market share cuando el producto está en stock. Esto hace pensar dos cosas. La primera, es que tal vez los supuesto utilizados para clasificar un período como en stock o en quiebre de stock son errados. Recordar que se extrapoló la información operacional a todas las observaciones de datos transaccionales ocurrido 15 minutos antes y 15 minutos después de tomado el dato operacional. Tal vez sea más conveniente considerar clasificar la información de forma distinta, por ejemplo 5 minutos antes y 25 después o simplemente 30 minutos después. Lamentablemente esto es difícil de comprobar a posteriori, ya que influyen dos factores que se desconocen, el primero es que no se sabe realmente cuándo empezó el quiebre y el segundo es que tampoco se sabe cuánto tarda un quiebre de stock en verse reflejado en las ventas.

El segundo tema a revisar es la calidad de la información de la data operacional. Recordar que la data operacional no indica realmente si existe o no un quiebre de stock, si no que si existe o no más de un 20% del stock. Muchos de estos períodos efectivamente serán quiebres de stock, pero habrá otros que no y los clientes siguieron comprando normalmente. Nuevamente resulta imposible saber cuánto es la influencia de este factor.

Tabla 4.4: Market share según casos

(a) Marraqueta			(b) Hallulla		
	Nº	Market share		Nº	Market share
No Detectado	86	.3498935	No Detectado	45	.2899567
Falsa Alarma	151	.2550513	Falsa Alarma	187	.1744428
Detectado	84	.1778098	Detectado	31	.1158889
En stock	934	.3472816	En stock	992	.2565049
Total	1255	.3250204	Total	1255	.2420034

(c) Pita blanco			(d) Anís		
	Nº	Market share		Nº	Market share
No Detectado	153	.0208162	No Detectado	182	.0081883
Falsa Alarma	126	.0108852	Falsa Alarma	91	.0046346
Detectado	155	.0034541	Detectado	176	.0020465
En stock	821	.0289309	En stock	806	.0111843
Total	1255	.0229833	Total	1255	.0089934

Por otro lado, las falsas alarmas también están relacionadas al punto anterior. Que exista un grupo de períodos considerados como en quiebre de stock y que tengan un market share tan alto hará subir la estimación de p_1 en el modelo. Esto hace que este valor, que es la baja en el market share que se quiere detectar rápidamente quede dentro del rango de market share normal del producto cuando está en stock. Si se observa las tablas 4.4 y se contrasta con los parámetros del modelo en la tabla 4.2, se puede apreciar que el promedio del market share en los casos de falsa alarma son inferiores al valor objetivo p_1 . Es esta manera, según los parámetros del modelo, está bien que en esos períodos se haya detonado una alarma. Esto también se puede ver en el apéndice D, donde en general, los histogramas de los períodos con falsa alarma son muy similares a los períodos en stock.

Existe otro factor para poder reducir la tasa de falsas alarmas, aparte de un parámetro h_B que entregue un $ANOS(p_0)$ mayor. Este corresponde a utilizar un parámetro p_1 menor, de tal forma que no entre en el rango normal del sistema cuando está en stock. En la tabla 4.5 se muestran los parámetros para el modelo Bernoulli CUSUM para la marraqueta, utilizando un p_1 calculado de la siguiente manera: $p_1 = p_0 - 1,65 * \sqrt{p_0 * (1 - p_0) / \bar{n}}$. Es decir, calculado en función de p_0 , donde sólo el 5% de los valores del market share cuando el sistema está en stock sean menor que p_1 .

En la figura 4.3 se muestra una comparación entre los resultados del modelo para ambos valores de p_1 . En el gráfico se aprecia que el porcentaje de falsas alarmas se redujo bastante de un 14% a un 10%, lo que significa 42 falsas alarmas menos. Si bien, también se redujo en un 1% la

Tabla 4.5: Parámetros modelos Bernoulli CUSUM con p_1 ajustado

	Marraqueta
p_0	0.3344631
p_1	0.19736932
r_1	-0.1873006
r_2	-0.7147505
γ_B	0.26205033
h_B^*	-5.7616949
h_B	-5.503057
L_B	21
ANOs(p_0)	1088.33036
ANOs(p_1)	67.80002

tasa de detección de quiebres, esto corresponde sólo a 2 quiebres menos detectados, lo cual es muy menor.


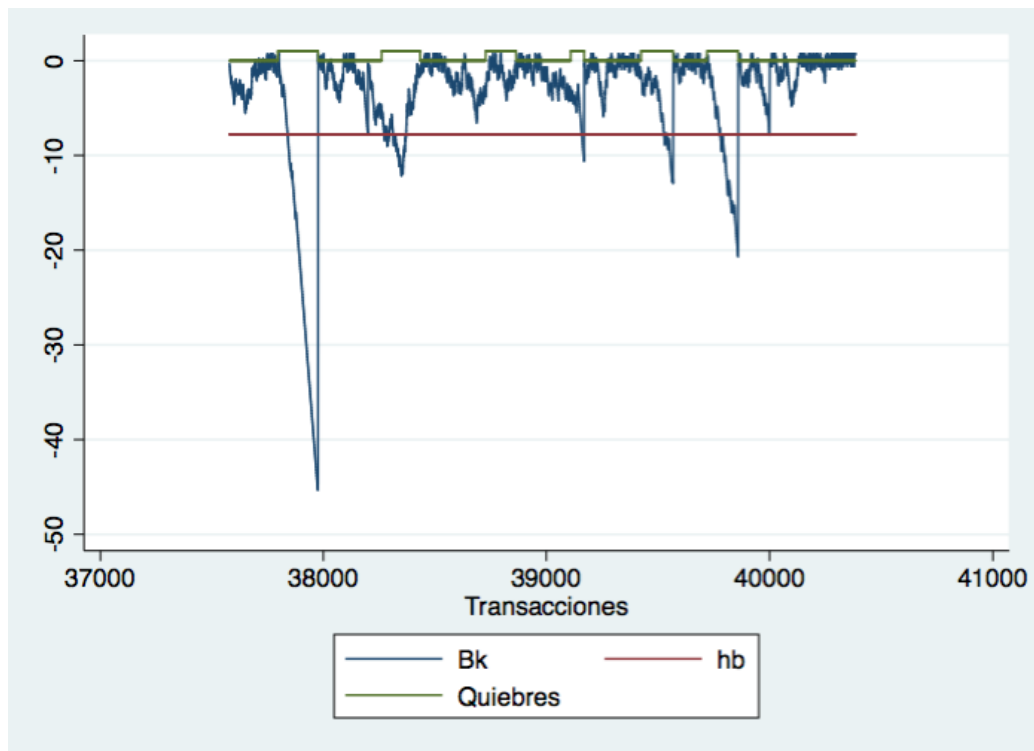


Figura 4.3: Marraqueta: comparación falsas alarmas y detecciones

Figura 4.1: Gráficos Bernoulli CUSUM

(a) Marraqueta, día 18



(b) Hallulla, día 18

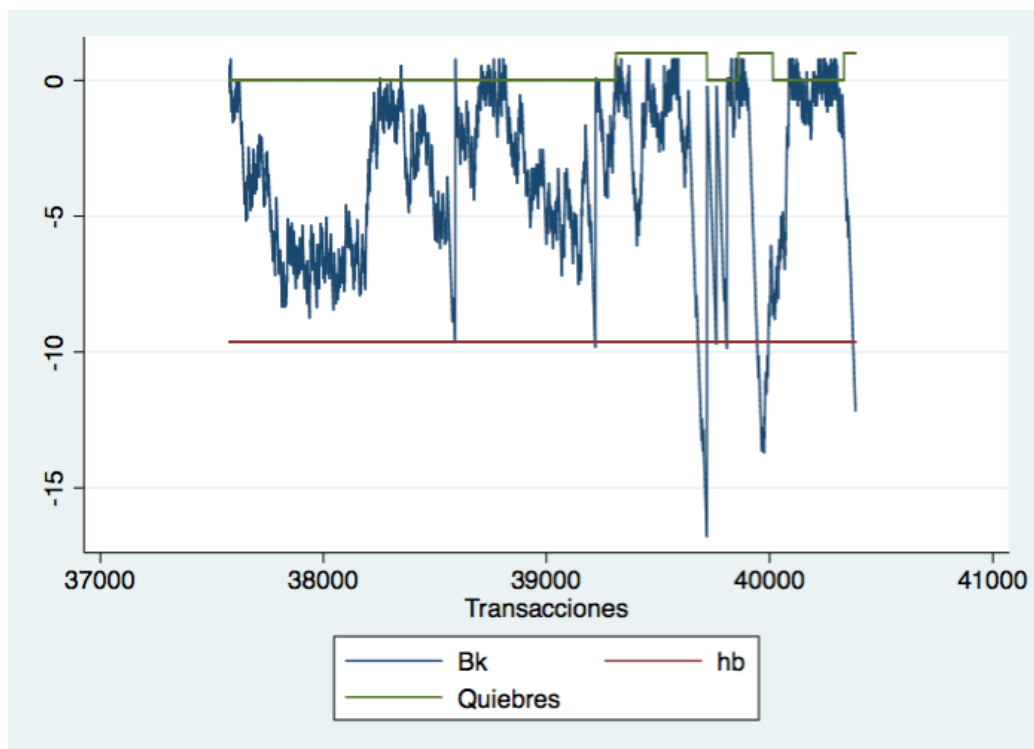
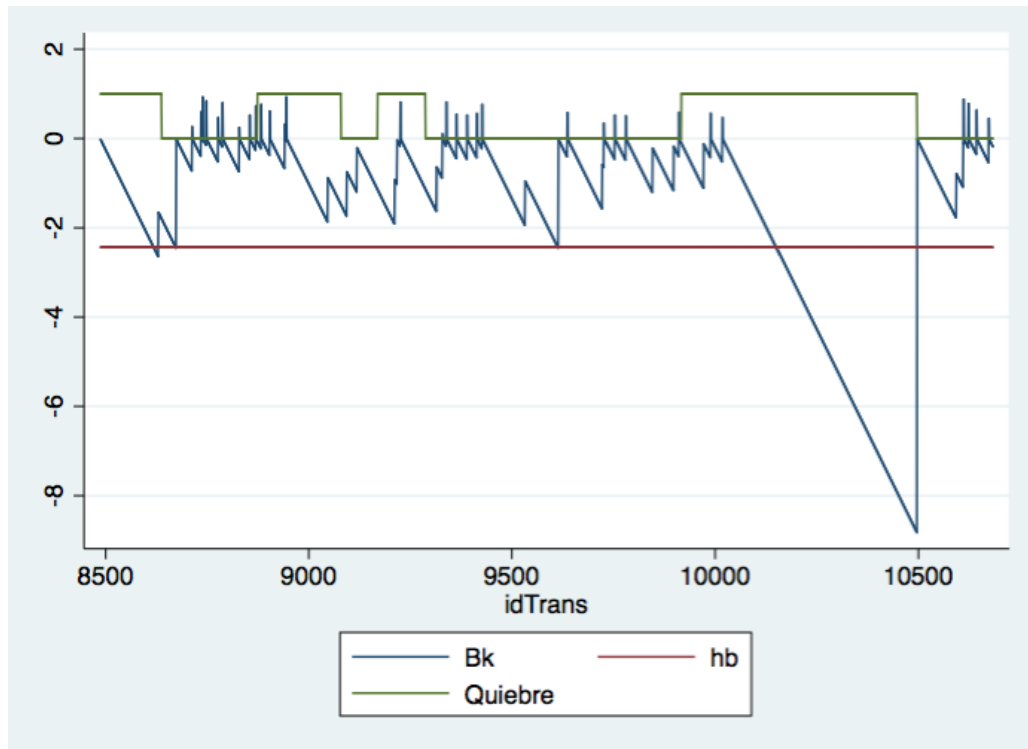



Figura 4.2: Gráficos Bernoulli CUSUM

(a) Pita Blanco, día 5



(b) Anís, día 7



Capítulo 5

Comparación Resultados y Recomendaciones

5.1. Comparación Métodos

Para realizar las comparaciones entre los distintos métodos, se utilizó todos los datos disponibles, es decir, los 1254 períodos en los cuales se cuenta con información operacional de los quiebres de stock. Para el caso de los gráficos de Shewhart, se utilizarán los mismos resultados de la sección 3.3, es decir, se ocuparán los percentiles 30-80% y el modelo sin subgrupos, todos calculados con un α igual a 5%. Por otro, para el modelo Bernoulli CUSUM se utilizarán los mismo resultados de la sección 4.3. Como en ese capítulo no se implementó el modelo para los SKU coliza y mendocino, se detallan en la tabla 5.1 los parámetros utilizados.

Tabla 5.1: Parámetros modelo Bernoulli CUSUM para coliza y mendocino

	Mendocino	Coliza
p_0	0.0050849	0.0429105
p_1	0.0039315	0.0208696
r_1	-0.0011586	-0.0227679
r_2	-0.258413	-0.7435909
γ_B	0.00448361	0.03061888
h_B^*	-1.8789714	-3.314893
h_B	-1.5513298	-3.0006504
L_B	346	98
ANOS(p_0)	897.917052	907.847442
ANOS(p_1)	707.2742	213.800184

Productos de alta rotación

En la figura 5.1 se observa que todos los métodos probados tuvieron una tasa de detección de quiebres de stock bastante pareja, entre el 43% y el 49%. Siendo el mejor método a la hora de detectar quiebres el de Bernoulli CUSUM (49%), seguido por el gráfico de Shewhart con subgrupo de clientes en el percentil 60%. Sin embargo, donde existe una notoria diferencia es en la tasa de falsas alarma, donde el método Bernoulli CUSUM acumula un 13.8% de falsas alarmas versus un 4% de falsas alarmas que acumula el gráfico de Shewhart con subgrupo del percentil 40%. Esta es una diferencia notoria, que equivale a 150 falsas alarmas versus sólo 40. De esta manera, la discusión radica en si es suficiente recompensa tener 6 detecciones más (84 versus 78) a cambio de 110 falsas alarmas extra.




Figura 5.1: Marraqueta: comparación falsas alarmas y detecciones

En el caso de la hallulla, se tiene que el método con mayor tasa de detección es el gráfico de Shewhart con subgrupo de percentil 40% y los menores son el mismo método, pero con percentiles 80% y sin subgrupos. Por otra lado, la mayor cantidad de falsas alarmas les tiene el método Bernoulli CUSUM con un 15.7%, versus un 6% para el gráfico de Shewhart usando subgrupo de percentil 30%. Para este SKU, el trade-off entre un mayor número de detecciones y una mayor tasa de falsas alarmas, no es tan drástico, ya que el método con mayor número de detecciones es el segundo método con menor tasa de falsas alarmas (7%), por lo que un aumento en 4 detecciones más, sólo significará 5 falsas alarmas más.

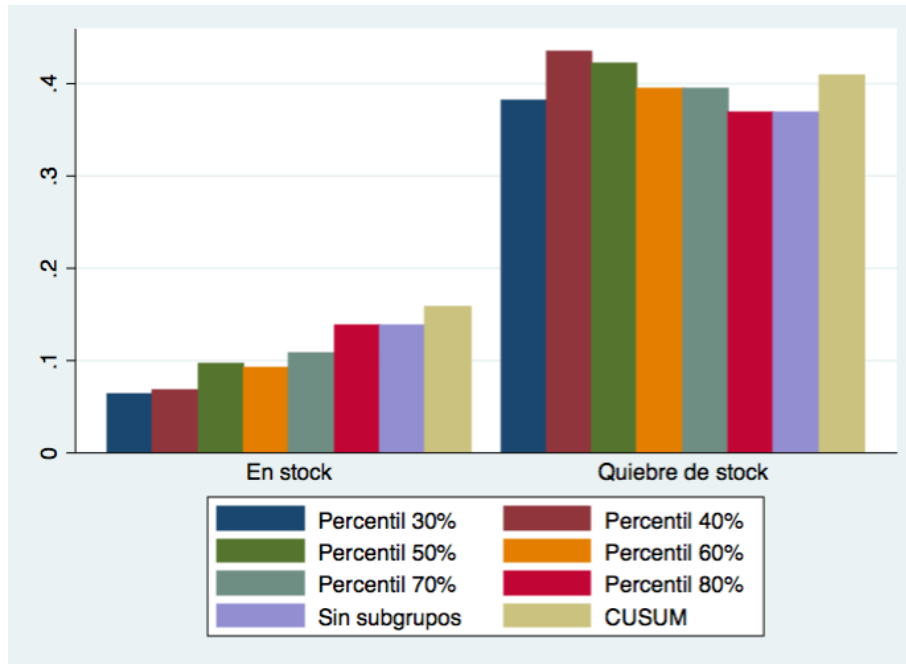


Figura 5.2: Hallulla: comparación falsas alarmas y detecciones

En general, se puede decir que para este tipo de SKU, con una alta rotación, todos los métodos se comportaron parejo a la hora de detectar quiebres, sin haber ninguno que destaque frente a los otros. Las grandes diferencias se encuentran en las falsas alarmas, donde el método Bernoulli CUSUM es el que presenta una mayor tasa de falsas alarmas, siempre seguido por el gráfico de Shewhart sin subgrupos.

El gran problema que existe con el modelo Bernoulli CUSUM para este tipo de productos, el cual también fue mencionado en la sección 4.3, es que este método para ser calculado, necesita una estimación del market share del producto cuando está sin stock. Si se observa la figura 5.3, se aprecia que el market share de ambos productos cuando están sin stock es muy amplio, llegan incluso a un 71% de market share en el caso de la marraqueta. Esto hace que el valor objetivo a detectar en el modelo caiga dentro del rango normal del producto cuando está en stock, lo que genera la gran cantidad de falsas alarmas.

Método recomendado

Para SKUs con una alta rotación, el método que mostró los mejores resultados es el gráfico de Shewhart usando subgrupos de percentil 40%. Este método combina una buena capacidad de detección con una baja tasa de falsas alarmas. Este tipo de productos es un buen ejemplo de cómo la información de la tarjeta de lealtad de un retailer, no sólo puede ayudar a la gestión comercial, si no que también podrá ser de utilidad para los aspectos operacionales. Al ser productos de alta rotación, gran parte de los consumidores tendrán un historial de compra de estos productos, lo que

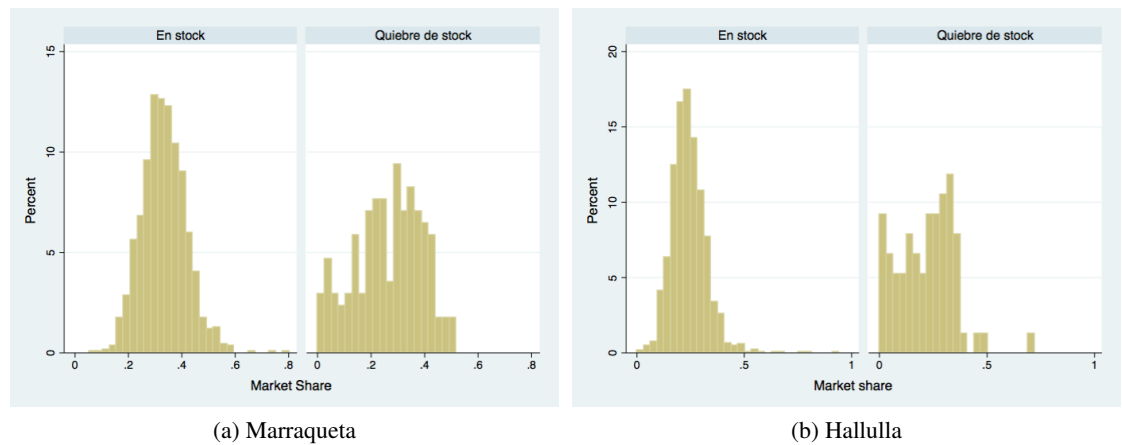


Figura 5.3: Histogramas market share según stock

hace realista poder pensar en la implementación de este método en la realidad.

Que para ambos SKU, el subgrupo que mejor se comportó fue el percentil 40%, es una característica particular de la categoría *pan a granel* y depende de la cantidad de compras realizadas en esa categoría, por lo que no se podrá extrapolar a otras. Este percentil para ambos casos contiene la misma cantidad de clientes, por lo que, para esta categoría en particular, el percentil 40% es el que mejor combina la reducción en la variabilidad debido a la selección de compras, versus el aumento en la variabilidad por reducir la muestra. Para otras categorías con mayor incidencia de compra, quizás el percentil adecuado sea menor y para otras con menor incidencia, el percentil deba ser mayor.

Productos de rotación media y baja

En la figura 5.4, se observa que el método Bernoulli CUSUM con una tasa de detección de un 58% es claramente más efectivo a la hora de detectar un quiebre en un producto de mediana rotación como este. Como ya se mencionó anteriormente, no es sorpresa que el mejor gráfico de Shewhart sea el que usa un subgrupo de percentil 40%, teniendo tasas de detección similares a cuando fue utilizado en productos de alta rotación. Por otro lado, los niveles de falsas alarmas se muestran parejos, siendo importante recalcar que el bajo nivel de falsas alarmas para los gráficos de Shewhart de percentiles altos, se debe principalmente a que el modelo no fue posible de aplicar en muchos de los períodos, debido a que el *LCL* fue igual a 0. Ver Apéndice B.




Figura 5.4: Coliza: comparación falsas alarmas y detecciones

Con respecto a los modelos a utilizar en SKUs de baja rotación(figura 5.5), no existe mucho por comparar, debido a que el único modelo que funciona para este caso es el Bernoulli CUSUM. Con una tasa de detección de un 28% y falsas alarmas de un 10% este es el mejor método que se puede aplicar. Si bien para este SKU, la tasa de detección no fue muy alta, en el capítulo 4, se mostró el caso del pan de anís, en el cual, con una misma tasa de falsas alarmas, se detectaron el 49% de los quiebres de stock.




Figura 5.5: Mendocino: comparación falsas alarmas y detecciones

Método Recomendado

Sin dudas el método recomendado para este tipo de productos será el de Bernoulli CUSUM. El bajo market share de estos productos hace que sea muy difícil poder detectar un quiebre de stock con la cantidad de información de un sólo período de 30 minutos. Por esta razón, los métodos CUSUM, al utilizar toda la información pasada, constituyen el método perfecto para la detección de quiebres de stock en estos casos.

Se tema de estudio ver si los niveles de falsas alarmas para este tipo de productos. Tal vez, no sea económicamente conveniente tener un 10% de falsas alarmas, para un producto con tan baja incidencia de compras.

5.2. Recomendaciones

A continuación se presentan recomendaciones generales sobre qué modelos utilizar en cada caso, cómo utilizarlos y qué cuidados se debe tener en la implementación de un modelo de detección de quiebres de stock en una cadena de retail.

Análisis previo

Se recomienda realizar un análisis previo completo de la categoría en la cual se quiere implementar un modelo de este tipo. En primer lugar es necesario analizar las ventas, con tal de conocer el nivel de ventas de la categoría y el market share de cada SKU en ella. Estos son datos que el administrador de la sala de supermercado ya debiese contar con ellos y será el primer filtro sobre la aplicabilidad de los modelos. En una categoría con una baja rotación y SKUs con market share bajos, en general será difícil poder implementar cualquier tipo de modelo de detección de quiebres de stock. También es importante analizar estacionalidades, las cuales puede hacer cambiar los parámetros del modelo, no por un quiebre de stock, si no como algo natural del producto y su estacionalidad.

Analizar la información histórica de los clientes ha sido mostrado que es una importante pieza de información adicional a los modelos implementados en este trabajo. Mientras más amplio sea el registro de clientes en tarjeta de lealtad y más extendido en el tiempo, se contará con más y mejor información de los comportamientos de compra de los clientes. De esta manera será importante revisar previamente a la implementación de estos modelos, si existe la información suficiente para poder aplicarla.

Medición de quiebres de stock

Un tema de estudio importante antes de implementar un modelo de detección de quiebres de stock será definir la mejor forma de medirlos. Un tema recurrente durante este trabajo fue la incertidumbre existente con respecto a la veracidad de los datos y los supuestos usados para aplicar en los modelos.

De esta forma, saber si por ejemplo es posible trabajar con información que no sea un quiebre de stock propiamente tal, si no una disminución a un porcentaje bajo de stock, como el caso de la información de este trabajo, donde se consideró un quiebre cuando el stock fue inferior a 20%. Saber además cada cuanto tiempo realizar las auditorías también es importante, esto debido a que la información con la que se contó para este trabajo fueron inspecciones regulares, cada 30 minutos. sin embargo se desconoce cuándo comenzaron y cuando terminaron los quiebres de stock. Esto obligó a realizar supuestos para determinar qué periodos de tiempo tuvieron efectivamente un quiebre de stock. Además, saber cuánto tiempo después empiezan a ser afectadas las ventas de un producto debido a un quiebre de stock, permitirá plantear de mejor manera los supuestos anteriormente mencionados.

Estimación de parámetros

En general, se observó que los modelos de gráfico de Shewhart son poco sensibles a errores en la estimación de parámetros. Éstos modelos son posibles de implementar utilizando información histórica de los market share, sin discriminación sobre quiebres de stock. Es luego de una primera fase, donde gracias a los quiebres detectados, es posible ajustar los parámetros para aplicarlos en

una segunda fase.

El problema es bastante distinto para el caso de los modelos de Bernoulli CUSUM, los cuales son muy sensibles a la mala estimación de parámetros. Esto se debe precisamente a la sensibilidad que tienen para detectar pequeños cambios en el sistema y gracias a lo cual es interesante su utilización. Precisamente por esto y relacionado al punto anterior, es que estos modelos fueron los que presentaron las mayores tasas de falsas alarmas. Se desconoce cuánto porcentaje de los quiebres no detectados y las falsas alarmas, fueron causadas por malos supuestos o errores de la medición de los quiebres de stock.

Modelos a utilizar

Esto ya fue mencionado en la sección 5.1. En resumen y como recomendación general se tiene que para productos de alta rotación será conveniente utilizar modelos de gráficos de Shewhart generando subgrupos por percentiles de preferencia. Qué percentil ocupar dependerá de la tasa de incidencia de compra de cada categoría. Es de esperar que mientras mayor sea la incidencia en una categoría, se podrá utilizar un percentil menor, pero que entregue mayor información.

Para los productos de rotación media y baja se recomienda la utilización del modelo de Bernoulli CUSUM. Si bien, este modelo no mostró ser efectivo a la hora de detectar quiebres de stock de corta duración, sí fue altamente efectivo para detectar quiebres prolongados. Este tipo de quiebres, debido a la poca incidencia de venta de estos productos y pueden pasar largos períodos de tiempo sin ser notados por el administrador.

Lamentablemente, en los datos utilizados no existió ningún SKU intermedio entre el 25 % de market share de la hallulla y el 4 % de del pan coliza, por lo que es difícil saber a ciencia cierta qué método será el mejor para un SKU con un market share intermedio. Sin embargo, el pan coliza se pudo observar que está en el borde de los SKU que se pueden analizar con gráficos de Shewhart, por lo que si existiese un producto en esta categoría con un market share mayor a 4 %, probablemente sea conveniente analizarlo con este tipo de métodos.

Recomendaciones de diseño e implementación

El éxito de un modelo de detección de quiebres de stock dependerá en gran medida de una correcta implementación en la realidad. Factor importante para esto será la tecnología para realizar las auditorías de inventario. Si se utilizan tecnologías que permitan comprobar el estado del inventario a un bajo costo (como por ejemplo con cámaras), ciertamente será posible implementar modelos con tasas de falsas alarmas mayores, pero que a la vez detecten una mayor cantidad de quiebres. Por el contrario, si se utilizan métodos de baja tecnología, como la auditoría humana, se deberá ser muy cuidadoso en determinar qué tasa de falsas alarmas se querrá. Esto, con tal de no perder credibilidad en el sistema. Un modelo donde un 85 % de las alarmas son falsas, ciertamente no será tomado en serio.

Es importante tener en cuenta que el modelo puede ser ajustado en el tiempo. A medida que se

tiene información más certera de los quiebres de stock, se pueden ir ajustando los parámetros, con tal de mejorar las capacidades del modelo. Esto toma especial importancia a la hora de implementar un modelo de Bernoulli CUSUM. En general, se recomienda partir con un modelo más bien conservador, con baja tasa de falsas alarmas e ir ajustándolo con el tiempo de tal manera de ir ganando mayores niveles de detección.

Capítulo 6

Conclusiones y trabajo futuro

6.1. Conclusiones

Los quiebres de stock en el retail son un problema relevante tanto en Chile como en el mundo. Es un problema que genera pérdidas equivalentes al 4% de las ventas anuales, lo que equivale a aproximadamente a U\$24 mil millones para los retailers. Del total de las causas que generan este problema, un 25% corresponde a problemas de reposición entre la bodega y la góndola. Esto ocurre principalmente a desajustes entre el sistema de control de inventario y el registro de ventas, además de robos, pérdidas y deterioro. Por esta razón, gran parte de la literatura está enfocada a generar sistemas de inventario en góndola que además incluyan las pérdidas, robos y deterioros. Sólo Fisher y Raman [8] plantean un enfoque distinto, mediante el uso de métodos de Control Estadístico de Procesos (SPC) para analizar los períodos sin ventas generados por un quiebre de stock. Tomando esta idea, es que se propone analizar las distintas técnicas y buscar las más adecuadas para detectar quiebres de stock y así generar una metodología de trabajo que sea simple de implementar.

Se mostró que parte importante para lograr esto fue realizar un análisis previo de todas la data a disposición y así poder los métodos más adecuados y qué variables pudiesen entregar información valiosa a la hora de detectar un quiebre. Para la realización de este trabajo se tuvo a disposición gran cantidad de información de punto de venta(POS) de la categoría pan a granel, correspondientes a un año de ventas en una sala de supermercado e información operacional de los quiebres de stock durante 45 días, realizado mediante auditorias con cámaras de vídeo cada 30 minutos de los 34 SKU de la categoría.

El primer método utilizado fue el gráficos de Shewhart. A pesar de su simplicidad, este método probó ser una excelente opción para una primera implementación, principalmente porque no necesita gran trabajo previo y se puede ir mejorando en el tiempo. Para este método se utilizó el market share de cada producto como el estadístico a analizar, donde si este valor desciende de un cierto límite, se declara una alerta de que puede existir un quiebre de stock. La principal desventaja de este método es que necesita muestras relativamente grandes para poder ser utilizado. Para el caso del pan a granel, que corresponde a una de las categorías con mayor incidencia de compra,

éste método es efectivo sólo para productos con un market share mayor a 4 % aproximadamente.

Una de las principales contribuciones de este trabajo corresponde al uso de información histórica de preferencias de compra de clientes. Una importante fuente de error del modelo de gráficos de Shewhart es la simplificación que se realiza al considerar que todos los clientes tienen una determinada preferencia p por cada producto. Sin embargo esto dista de ser verdad, al analizar las lealtades a cada producto, se puede ver que la variabilidad es muy alta. Esto genera una subestimación de los parámetros de diseño del modelo, lo que a su vez provoca una mayor tasa de falsas alarmas. Al agrupar a los clientes en percentiles de preferencia de compra y filtrar los datos del punto de venta realizados por estos grupos de clientes, se logró mejorar este supuesto y lograr una concordancia entre el diseño y los resultados obtenidos. Esto se tradujo en tasas de falsas alarmas notablemente más bajas y mejorando levemente los niveles de detección. Esto muestra que los datos de la tarjeta de lealtad de la cadena de retail, no sólo sirven para tomar acciones de marketing, si no que también pueden tener un uso operacional.

El segundo método utilizado fue el de Bernoulli CUSUM. Éste método utiliza toda la información pasada para determinar si un proceso se encuentra en su estado normal o existe una anomalía. Por esta razón, este método está documentado en la literatura como una excelente opción para procesos con un bajo p . Esto es precisamente el tipo de procesos en el cual los gráficos de Shewhart no pueden ser utilizados. Reynolds y Stoumbos [19] desarrollaron un método bastante sencillo de diseñar este método, el cual entrega una relativamente buena aproximación de los resultados reales. Luego de la implementación de este método, se comprobó lo descrito en la literatura. Se obtuvo excelentes resultados para SKUs de bajo market share, con niveles de detección de quiebres superiores al 40% y bajos niveles de falsas alarmas.

Un tema de discusión importante es el uso de la información operacional de los quiebres de stock. Se detectaron períodos de tiempo con altos market share en los cuales la data operacional indicaba que el producto estaba en quiebre de stock. Esto hace pensar que los supuestos utilizados para considerar estos períodos de quiebre son errados o que la información obtenida no es correcta. En general, los períodos con quiebres de stock no detectados por los modelos, fueron períodos con market share similar o incluso mayor que otros períodos sin quiebres de stock. Esto hace que sea prácticamente imposible mejorar los niveles de detección, sin aumentar las tasas de falsas alarmas.

Finalmente, se puede decir que la aplicación de métodos de control estadísticos de proceso pueden ser una excelente opción para mejorar los niveles de servicio al cliente, disminuyendo los quiebres de stock. Este tipo de método, combinado con sistemas de auditoría a bajo costo pueden significar una excelente opción para mejorar el manejo de inventario en góndola.

6.2. Trabajo futuro

El diseño e implementación de los métodos propuestos en este trabajo desde cero es sin dudas un excelente trabajo a desarrollar. Poder implementar una toma de datos operacionales efectiva, podrá cerrar las dudas que se tienen con respecto a la veracidad de los datos y los supuestos utilizados. Es importante poder realizar un análisis de cuánto demora un quiebre de stock en

verse reflejado en los datos del punto de venta. También saber también la periodicidad de las auditorías, con tal de tener una mayor certeza de cuándo empieza cada quiebre de stock. Cerradas estas incertidumbres en la metodología propuesta en este trabajo, se podría ver el real poder de estos métodos para la detección de quiebres de stock.

Otro punto interesante de analizar corresponde a la inclusión de información histórica de preferencias de compra al modelo de Bernoulli CUSUM. Al igual que en el modelo de gráficos de Shewhart, en este modelo también se utiliza el supuesto que todos los clientes tendrán la misma preferencia de compra p , lo cual puede significar una supuesto demasiado fuerte. Para el desarrollo de un modelo que incluya esta variabilidad, se deberá modificar la forma de calcular todos los parámetros y límites del modelo.

Finalmente, otro trabajo interesante de desarrollar es poder determinar las preferencias de compra utilizando otros datos aparte de la información histórica. Recordar que solo una fracción de los clientes presentan información histórica de sus preferencias de compras. Por esta razón, poder determinarla con otros datos, como podría ser el análisis de la canasta de compra, puede ser un gran aporte al modelo.

Bibliografía

- [1] Agnese, Joseph: *Industry survey for supermarkets and drugstores*. Standard and Poors. December, 19, 2008. http://homepage.smc.edu/thomas_phillip/rpt/SupermarketsAndDrugstores.pdf.
- [2] Bensoussan, Alain, Cakanyildirim, Metin, Minjárez-Sosa, J Adolfo, Sethi, Suresh P y Shi, Ruixia: *Partially observed inventory systems: The case of rain checks*. SIAM Journal on Control and Optimization, 47(5):2490–2519, 2008.
- [3] Bourke, Patrick D: *Detecting a shift in fraction nonconforming using run-length control charts with 100 inspection*. Journal of Quality Technology, 23(3):225–238, 1991.
- [4] Chang, TC y Gan, FF: *Cumulative sum charts for high yield processes*. Statistica Sinica, 11(3):791–806, 2001.
- [5] Chen, Li: *Fixing phantom stockouts: Optimal data-driven shelf inspection policies*. Informe técnico, Duke University. Working Paper, 2014.
- [6] Chen, Li y Mersereau, Adam J: *Analytics for operational visibility in the retail store: The cases of censored demand and inventory record inaccuracy*. En *Retail Supply Chain Management*, páginas 79–112. Springer, 2015.
- [7] DeHoratius, Nicole, Mersereau, Adam J y Schrage, Linus: *Retail inventory management when records are inaccurate*. Manufacturing & Service Operations Management, 10(2):257–277, 2008.
- [8] Fisher, Marshall y Raman, Ananth: *The new science of retailing: how analytics are transforming the supply chain and improving performance*. Harvard Business Review Press, 2010.
- [9] Gan, FF: *An optimal design of CUSUM control charts for binomial counts*. Journal of Applied Statistics, 20(4):445–460, 1993.
- [10] Gruen, Thomas W, Corsten, Daniel y Bharadwaj, Sundar: *Retail out-of-stocks: A worldwide examination of extent, causes and consumer responses*. Grocery Manufacturers of America Washington, DC, 2002.
- [11] Gruen, Thomas W y Corsten, Daniel S: *A comprehensive guide to retail out-of-stock reduction in the fast-moving consumer goods industry*. Grocery Manufacturers of America, 2007.

- [12] Kök, A Gürhan y Shang, Kevin H: *Inspection and replenishment policies for systems with inventory record inaccuracy*. Manufacturing & service operations management, 9(2):185–205, 2007.
- [13] Mersereau, Adam J: *Information-Sensitive Replenishment when Inventory Records Are Inaccurate*. Production and Operations Management, 22(4):792–810, 2013.
- [14] Mitchell, Philip: *Discovery-Based Retail*. Hillcrest Publishing Grp, 2008.
- [15] Montgomery, Douglas C: *Introduction to statistical quality control*. John Wiley & Sons, 2007.
- [16] Máximo Bosch, Rafael Hilger, Ariel Schilkrut: *La Medición de Faltantes en Góndola*. Universidad de Chile, 2005.
- [17] Page, ES: *Continuous inspection schemes*. Biometrika, páginas 100–115, 1954.
- [18] Reynolds, Marion R: *The Bernoulli CUSUM chart for detecting decreases in a proportion*. Quality and Reliability Engineering International, 29(4):529–534, 2013.
- [19] Reynolds Jr, Marion R y Stoumbos, Zachary G: *A CUSUM chart for monitoring a proportion when inspecting continuously*. Journal of Quality Technology, 31(1):87, 1999.
- [20] Ryan, Thomas P y Schwertman, Neil C: *Optimal limits for attributes control charts*. Journal of Quality Technology, 29(1), 1997.
- [21] Siegmund, D: *Corrected diffusion approximations in certain random walk problems*. Advances in Applied Probability, páginas 701–719, 1979.
- [22] Ton, Zeynep y Raman, Ananth: *The effect of product variety and inventory levels on retail store sales: A longitudinal study*. Production and Operations Management, 19(5):546–560, 2010.
- [23] Wald, A: *Sequential analysis*. 1947, 1947.

Apéndice A

Market Share por día de la semana




Figura A.1: Market Share por hora




Figura A.2: Market Share por hora




Figura A.3: Market Share por hora




Figura A.4: Market Share por hora




Figura A.5: Market Share por hora




Figura A.6: Market Share por hora




Figura A.7: Market Share por hora

Apéndice B

Histogramas Límites inferiores

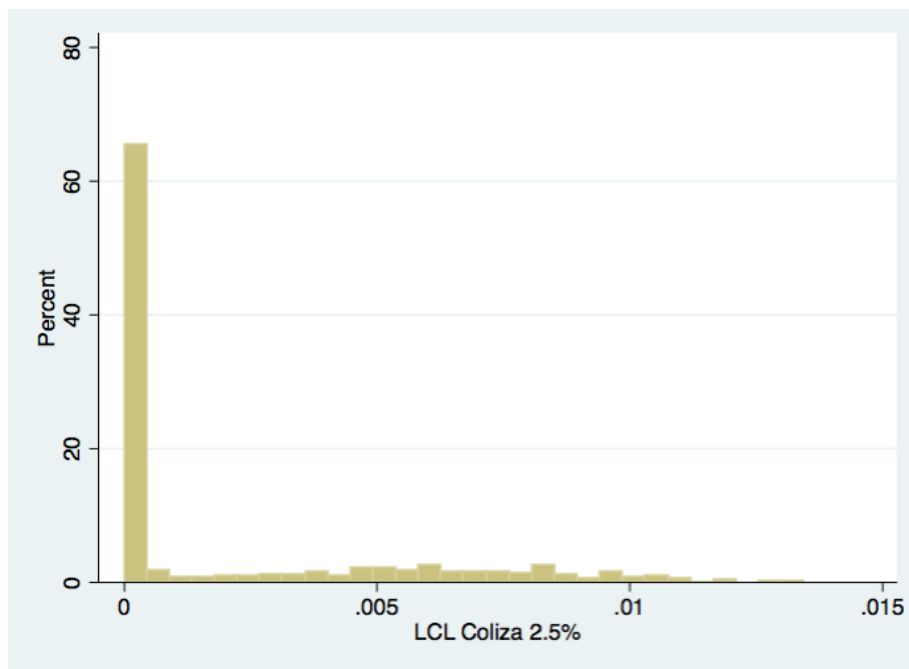


Figura B.1: Histograma Coliza 2.5 %




Figura B.2: Histograma Coliza 5%




Figura B.3: Histograma Coliza 10%




Figura B.4: Histograma Coliza percentil 30%




Figura B.5: Histograma Coliza percentil 40%




Figura B.6: Histograma Coliza percentil 50%




Figura B.7: Histograma Coliza percentil 60%




Figura B.8: Histograma Coliza percentil 70%




Figura B.9: Histograma Coliza percentil 80%

Apéndice C

Cantidad de alarmas generadas en modelos de gráficos de Shewhart

Tabla C.1: Niveles de detección según α

(a) Marraqueta

	α			Total
	2.5 %	5 %	10 %	
En stock	47 6 %	88 12 %	136 18 %	737
Quiebre de stock	50 43 %	54 46 %	58 50 %	117

(b) Hallulla

	α			Total
	2.5 %	5 %	10 %	
En stock	75 9 %	122 15 %	193 24 %	806
Quiebre de stock	14 29 %	16 33 %	18 38 %	48

(c) Coliza

	α			Total
	2.5 %	5 %	10 %	
En stock	24 3 %	46 6 %	101 13 %	760
Quiebre de stock	15 16 %	25 27 %	41 44 %	94

Tabla C.2: Niveles de detección según Percentiles

(a) Marraqueta

	Percentiles							Total
	30 %	40 %	50 %	60 %	70 %	80 %	100 %	
En stock	43	40	55	64	72	75	133	1084
	4 %	4 %	5 %	6 %	7 %	7 %	12 %	
Quiebre de stock	74	78	75	80	76	73	76	170
	44 %	46 %	44 %	47 %	45 %	43 %	45 %	

(b) Hallulla

	Percentiles							Total
	30 %	40 %	50 %	60 %	70 %	80 %	100 %	
En stock	75	80	113	109	126	162	163	1178
	6 %	7 %	10 %	9 %	11 %	14 %	14 %	
Quiebre de stock	29	33	32	30	30	28	28	76
	38 %	43 %	42 %	39 %	39 %	37 %	37 %	

(c) Coliza

	Percentiles							Total
	30 %	40 %	50 %	60 %	70 %	80 %	100 %	
En stock	81	173	152	112	93	77	63	1099
	7 %	16 %	14 %	10 %	8 %	7 %	6 %	
Quiebre de stock	43	66	62	59	52	52	42	155
	28 %	43 %	40 %	38 %	34 %	34 %	27 %	

Apéndice D

Histogramas de market share según resultados de modelos Bernoulli CUSUM




Figura D.1: Histograma Marraqueta después de CUSUM

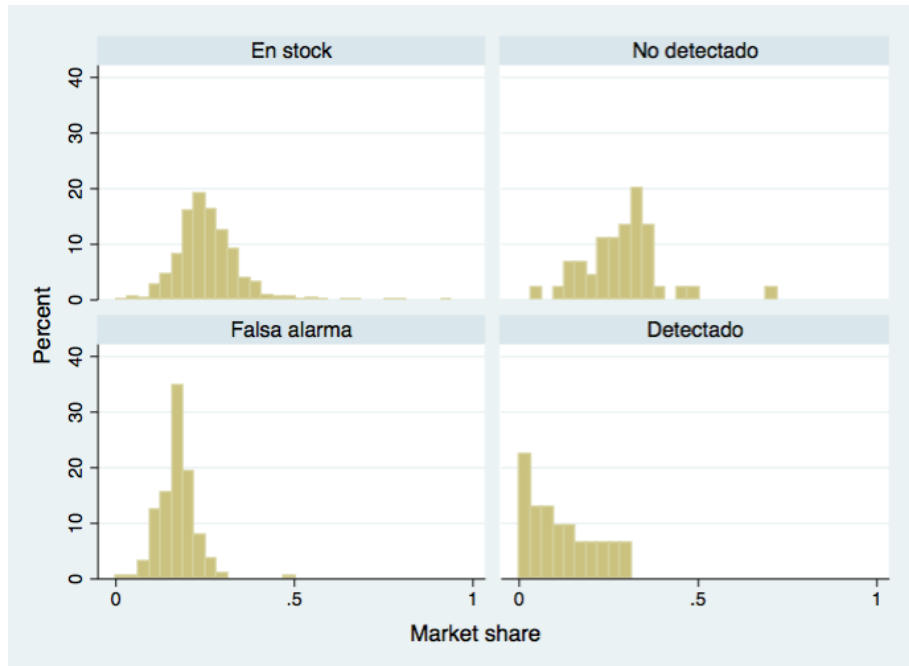


Figura D.2: Histograma Hallulla después de CUSUM




Figura D.3: Histograma Pita Blanco después de CUSUM




Figura D.4: Histograma Anís después de CUSUM