



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

ASIGNACIÓN EFICIENTE DE LA FUERZA DE VENTA EN TIEMPO REAL:
APLICACIÓN EN UNA TIENDA DE RETAIL

TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN GESTIÓN DE OPERACIONES

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL INDUSTRIAL

PABLO EDUARDO JOFRÉ ORTEGA

PROFESOR GUÍA:
MARCELO OLIVARES ACUÑA

MIEMBROS DE LA COMISIÓN:
RICARDO MONTOYA MOREIRA
ANDRÉS MUSALEM SAID
DANIEL YUNG MEYOHAS

Este trabajo ha sido parcialmente financiado por
CONICYT-PCHA/MagisterNacional/2014 - 22141193
CONICYT/Proyecto FONDEF/IT13I20031

SANTIAGO DE CHILE

2017

RESUMEN DE LA MEMORIA PARA OPTAR
AL TÍTULO DE MAGÍSTER EN GESTIÓN DE OPERACIONES
POR: PABLO EDUARDO JOFRÉ ORTEGA
FECHA: 2017
PROF. GUÍA: SR. MARCELO OLIVARES ACUÑA

ASIGNACIÓN EFICIENTE DE LA FUERZA DE VENTA EN TIEMPO REAL: APLICACIÓN EN UNA TIENDA DE RETAIL

Para las tiendas de retail los costos relacionados a la mano de obra son un porcentaje importante de los costos operacionales (Ton 2009[10]). "Después del costo de los bienes vendidos, el gasto relacionado en contratar, capacitar y la mano de obra de la tienda constituyen por lejos la mayor componente del costo de los retailers"(Netessine et al. 2010[6]). Por lo tanto, es sumamente importante lograr el mejor rendimiento posible de esta gran inversión.

El objetivo principal de este estudio es optimizar la eficiencia de la fuerza de venta de una tienda de retail, decidiendo la ubicación de los vendedores en tiempo real, utilizando información de las cámaras de seguridad de la tienda.

La metodología utilizada se compone de dos partes. En primer lugar, se proponen diferentes modelos de *Poisson* que explican las transacciones ocurridas durante un periodo de 30 minutos, dentro de un departamento, como un proceso de conteo que depende de distintas variables y controles. Estos se estiman por el método jerárquico bayesiano, complementado con una función de control para solucionar la endogeneidad del número de vendedores. En segundo lugar, con el resultado del análisis econométrico, se genera una heurística que tiene como objetivo maximizar las transacciones de la tienda, esta heurística decide cada 30 minutos el número de vendedores asignados a cada departamento dependiendo de la cantidad de clientes, el día, la hora y un conjunto de variables que permite controlar las estacionalidades de las ventas. Usando herramientas de simulación se estudia el incremento en las transacciones al incorporar flexibilidad en la movilidad de los vendedores a lo largo de distintos departamentos, es decir, incorporar vendedores capaces de atender en más de un departamento.

El resultado del análisis econométrico, muestra que el efecto del número de vendedores en las transacciones presenta heterogeneidad entre departamentos y depende de la hora. Se muestra que existe un grado de congestión, ya que el parámetro asociado al número de vendedores al cuadrado es negativo, lo que significa que llega un momento en que agregar un vendedor más a algún departamento tiene un efecto negativo en las transacciones. La cantidad de clientes está relacionada positivamente con las transacciones. En relación al proceso de simulación, se encuentra que las ventas aumentan a medida que los vendedores son capaces de atender en más departamentos, llegando a aumentar en 11.4% si los vendedores fueran capaces de atender en toda la tienda, en comparación a que atiendan en sólo un departamento.

Se concluye que la heterogeneidad del efecto de los vendedores en los distintos departamentos, permite que la heurística desarrollada aumente las transacciones en la tienda ubicando a los vendedores de manera estratégica, aprovechando la información que entregan las cámaras de seguridad. Además la incorporación de vendedores polifuncionales brindan mayor flexibilidad al proceso de ubicación de la fuerza de venta, lo que se traduce en un mejor desempeño de la tienda.

Dedicado a Martín y Amparo.

Tabla de Contenidos

Introducción	1
1. Datos	3
1.1. Recopilación de datos	3
1.2. Datos	4
1.3. Análisis descriptivo	5
1.4. Histogramas de frecuencia de variables de interés	6
1.5. Correlación entre variables de interés	8
1.6. Comportamiento horario de variables y diferencia entre departamentos	10
2. Análisis econométrico	15
2.1. Especificación del modelo econométrico	15
2.2. Extensión del modelo econométrico	17
3. Resultados empíricos y discusión	21
3.1. Variables de control y exógenas	21
3.1.1. Controles	21
3.1.2. Variables exógenas	21
3.2. Estimación	22
3.3. Resultados	23
4. Simulación de políticas de asignación eficiente de vendedores	29
4.1. Heurística de asignación eficiente	29
4.2. Especificaciones generales de las simulaciones	30
4.3. Caso base	31
4.4. Grupos	32
4.5. Resultados	32
5. Conclusión	34
A. Descripción de los datos	38
B. Estimación	39
B.1. Resultado modelos	39
B.1.1. Modelo 1	39
B.1.2. Modelo 2	40
B.1.3. Modelo 3	41

B.1.4. Modelo 4	42
B.1.5. Modelo 5	43
B.1.6. Modelo 6	44
B.1.7. Modelo 7	45
B.1.8. Modelo 8	46
B.1.9. Modelo 9	48
B.2. Convergencia	49
C. Simulación	61
C.1. Distribución de la tienda según N_{grupos}	61
C.1.1. $N_{grupos} = 14$	61
C.1.2. $N_{grupos} = 7$	61
C.1.3. $N_{grupos} = 6$	62
C.1.4. $N_{grupos} = 5$	62
C.1.5. $N_{grupos} = 3$	63
C.1.6. $N_{grupos} = 2$	63
C.1.7. $N_{grupos} = 1$	63

Índice de Tablas

1.1. Estadísticos descriptivos de los datos agrupados por tienda, departamento, fecha, hora y periodo de 30 minutos.	5
1.2. Lista de los departamentos bajo estudio con su respectivo identificador. . . .	6
1.3. Matriz de correlación	9
2.1. Definición de la variable CL según el percentil en que se encuentre la variable C .	16
3.1. Criterio DIC para los modelos estimados.	23
3.2. Resultados <i>modelo 6</i>	24
4.1. Tabla que reporta las transacciones esperadas para cada política definida según la cantidad de grupos, además se presenta el incremento porcentual con respecto a la política con 14 grupos.	33
B.1. Resultados <i>modelo 1</i>	39
B.2. Resultados <i>modelo 2</i>	40
B.3. Resultados <i>modelo 3</i>	41
B.4. Resultados <i>modelo 4</i>	42
B.5. Resultados <i>modelo 5</i>	43
B.6. Resultados <i>modelo 6</i>	44
B.7. Resultados <i>modelo 7</i>	45
B.8. Resultados <i>modelo 8</i>	46
B.9. Resultados <i>modelo 9</i>	48

Introducción

Para las tiendas de retail los costos relacionados a la mano de obra son un porcentaje importante de los costos operacionales (Ton 2009[10]). "Después del costo de los bienes vendidos, el gasto relacionado en contratar, capacitar y la mano de obra de la tienda constituyen por lejos la mayor componente del costo de los retailers"(Netessine et al. 2010[6]). Por lo tanto, es sumamente importante lograr el mejor rendimiento posible de esta gran inversión. Para esto es fundamental hacer coincidir periodos de gran afluencia de público con la fuerza de venta necesaria, es decir, minimizar el desbalance entre el tráfico de la tienda y la falta o exceso de personal, ya que se ha encontrado que la falta de personal en periodos de alta demanda puede generar una baja del 7.02 % en la rentabilidad de la tienda durante ese periodo (Mani et al. 2015 [4]).

En la literatura existen estudios previos que utilizan información recopilada con herramientas tecnológicas para medir el impacto de distintas decisiones operacionales dentro del rendimiento de la tienda, por ejemplo, Kesavan et al. (2014)[3] utiliza videos con los que miden la congestión en el área de probadores y estudia como esta impacta en las ventas. De acuerdo a esto, mide el aporte de un empleado que esté encargado específicamente de minimizar la congestión en esta área. Perdikaki et al. (2012)[7] utiliza sensores en la entrada de las tiendas para medir el tráfico de clientes, a partir de esto descubren que incrementar el promedio del tráfico por hora en una unidad, incrementa el promedio del volumen de las ventas por hora en US\$9.97, además descubren que este efecto depende del número de vendedores que tenga la tienda. Estos resultados implican que la localización de los vendedores a lo largo de las tiendas es una decisión relevante, ya que tiene un impacto dentro de las ventas.

Por otro lado, Pinna and Seiler (2014)[8] utilizan información de "path-tracking" que es obtenida a través de un dispositivo que permite obtener la posición de los carros de compra dentro de la tienda y a partir de esto se infiere la posición de los clientes dentro de la tienda, esto combinado con información del punto de venta, fue utilizado para estudiar el impacto del esfuerzo que los clientes emplean en la búsqueda de un producto en el precio que pagan por él. En el estudio de Musalem et al. [5] (2016) se utiliza información obtenida a través de videos de cámaras de seguridad, con los cuales obtienen métricas que permiten medir objetivamente la asistencia de los vendedores a los clientes. Muestran que el incremento en la tasa de asistencia en una desviación estándar, implica un incremento de 18.5 % en el número de transacciones y un 8 % en el tamaño de la canasta.

El presente estudio se enmarca en una tienda de retail ferretero, donde se utilizan las

cámaras de seguridad para obtener información sobre la posición de los clientes y vendedores dentro de la tienda, también se posee información del punto de venta. Con los datos disponibles se mide el efecto de los vendedores en las ventas, este efecto se presume diferente para cada uno de los departamentos de la tienda. Con esto se encuentran las secciones de la tienda que tienen mayor demanda y también en las que el accionar de los vendedores tiene un impacto significativo en las transacciones, lo que permite ubicar a los vendedores de forma estratégica para obtener el mayor beneficio posible de los recursos utilizados. La novedad de este estudio es que utiliza información en tiempo real, desde las cámaras de seguridad, con la que es posible tomar decisiones operativas de forma dinámica con respecto a la posición de los vendedores, considerando la demanda que los diferentes departamentos están enfrentando y en cuál de ellos el impacto de los vendedores se espera que sea mayor, teniendo como objetivo obtener los mayores ingresos posibles. En tiendas de gran superficie el flujo de clientes puede variar de manera significativa entre un departamento y otro, esto genera que el problema del desbalance entre tráfico de clientes y fuerza de venta pase a ser un problema a nivel de departamento y no sólo a nivel de tienda, este estudio apunta a la solución de esto, generando un movimiento de vendedores a los departamentos en los que en realidad están siendo requeridos.

La tienda de retail utilizada en este trabajo está ubicada en EE. UU. y posee 14 departamentos cada uno especializado en diferentes tipos de bienes, dentro de estos se pueden mencionar *appliances, building materials, cabinets, cleaning, fashion plumbing*, entre otros. Estos 14 departamentos se distribuyen en dicha tienda en un total de 8.000 m^2 . La cadena, a la cual pertenece esta tienda, al año 2.010 poseía 1.749 tiendas emplazadas en EE.UU., Canadá y México, además durante ese año percibió alrededor de US\$48.815 millones en ventas.

Los datos disponibles para realizar este trabajo son el flujo de clientes (entrada y salida), información que es recopilada a través de sensores en la entrada de la tienda, número de vendedores y clientes en cada uno de los departamentos, esta información se obtiene al procesar los videos de cámaras de seguridad. Los datos del punto de venta permiten obtener la cantidad de transacciones de cada departamento, es decir, asignando a cada departamento las transacciones que posean a lo menos un producto asociado a ese departamento, por lo tanto una transacción de la tienda puede estar asociada a más de un departamento.

El principal objetivo de este estudio es optimizar la eficiencia de los vendedores de esta tienda, para esto se decide la ubicación de la fuerza de venta dentro de la tienda, teniendo siempre como objetivo la maximización del número de transacciones. Logrando así una asignación eficiente de la fuerza de venta en tiempo real, es decir, una asignación vendedor-cliente que permita obtener la mayor utilidad posible considerando todos los descubrimientos resultantes de los análisis previos.

Capítulo 1

Datos

En el presente capítulo se describen los datos con los que se trabaja, el método de recopilación y sus limitantes. Además se definen las variables que se utilizan a lo largo de la investigación.

Los datos disponibles para esta investigación fueron facilitados por *SCOPIX*.

1.1. Recopilación de datos

Los datos se obtienen de distintas fuentes, siendo la primera de ellas cámaras de seguridad instaladas en los distintos departamentos de la tienda de retail. Estas cámaras capturan fotografías cada cierto intervalo de tiempo y por medio de un algoritmo de reconocimiento de imagen, se cuenta la cantidad de vendedores y clientes que se encontraban presentes en ese instante en esa sección de la tienda. Técnicamente el algoritmo reconoce el color de la ropa de cada persona que aparece en la fotografía y con esto se identifica a las personas que tienen el color del uniforme utilizado por los vendedores, permitiendo contar la cantidad de empleados y clientes presentes. Una limitación de estos datos es la posibilidad de que un cliente que esté usando el mismo color que los vendedores, sea contado como un vendedor, por lo que este dato tiene cierto grado de error en su medición.

Una segunda fuente de recolección de datos son sensores de movimiento instalados en las entradas y salidas de la tienda, estos son capaces de contar la cantidad de personas que entran y salen de la tienda en cierto intervalo de tiempo. Un problema de esta fuente es que probablemente una persona que se pasee por la puerta, entrando y saliendo de la tienda, será contada varias veces sin la necesidad de que ingrese a los pasillos de la tienda, por lo que la probabilidad de compra de esta persona es cero.

Por otro lado, se disponen de datos *POS* (*Point of Sales*), relacionados con las transacciones que se realizaron en la tienda. También existe información sobre los empleados, específicamente la cantidad de vendedores calendarizados a asistir en un día específico y la cantidad de vendedores que realmente asistieron, donde lo segundo varía con respecto a lo

calendarizado según el ausentismo que ocurra esa fecha en específico.

1.2. Datos

Se disponen datos de una tienda, en la que existen 14 departamentos. Los datos están agregados en un horizonte de tiempo de 30 minutos y la información fue recopilada entre las fechas 17 de Marzo hasta el 20 de Junio del año 2014. A continuación se presenta la descripción de la base de datos.

Identificadores de las observaciones:

- *Store*: Corresponde a la tienda bajo estudio, sólo existen datos para una tienda la cual es identificada con el número 478.
- *Department*: Es el departamento de la tienda correspondiente a la observación. Se identificará con i .
- *fdate*: Es la fecha de la observación. Como se mencionó anteriormente los datos abarcan desde el 17 de Marzo hasta el 20 de Junio del año 2014, sin embargo este intervalo de fechas varía dependiendo del departamento. Se identificará con f .
- *hour*: Registra la hora en que ocurre la observación. Los datos contiene información desde las 8:00 hasta las 20:59 horas, esta variable sólo contiene la hora de la observación, es decir, si una observación corresponde a las 15:30 horas entonces esta variable es igual a 15.
- *period30min*: Es el periodo de 30 minutos correspondiente a la observación, los periodos están codificados desde el número 16 hasta el 41, dando un total de 26 periodos para cada día, es decir, dos periodos para cada hora entre las 8:00 y 20:59 horas. Se identificará con t .

VARIABLES:

- ntr_{itf} : Corresponde al número de transacciones, técnicamente es el número de boletas emitidas en las cuales hay por lo menos un producto del departamento i durante el periodo t en la fecha f .
- *salespeople* (S_{itf}): Es el promedio de vendedores observados en las fotografías tomadas durante el periodo t , en el departamento i , en la fecha f .
- *customers* (C_{itf}): Es el promedio de clientes observados en las fotografías tomadas durante el periodo t , en el departamento i , en la fecha f .
- *nsamples*: Corresponde al total de fotografías utilizadas para calcular S_{itf} y C_{itf} .
- *fsalespeople* (fS_{itf}): Contiene a la cantidad de vendedores observados en la primera fotografía que se realizó en el periodo t , en el departamento i , en la fecha f .
- *fcustomers* (fC_{itf}): Contiene a la cantidad de clientes observados en la primera fotografía que se realizó en el periodo t , en el departamento i , en la fecha f .
- *scheduled* (sc_{itf}): Cantidad de vendedores calendarizados para el periodo t , en el departamento i , en la fecha f .

- *actual_hours* ($ah_{t,f}$): Cantidad de vendedores que realmente estuvieron disponibles, es decir, que asistieron en el periodo t , en el departamento i , en la fecha f .

Las siguientes variables están agregadas a nivel de tienda y no a nivel de departamento como las variables anteriores.

- *entrance* ($in_{t,f}$): Indica la cantidad de personas que ingresaron a la tienda durante el periodo t , en la fecha f .
- *out* _{t,f} : Indica la cantidad de personas que salieron de la tienda durante el periodo t , en la fecha f .

1.3. Análisis descriptivo

En la tabla 1.1 se muestran algunos estadísticos descriptivos de los datos disponibles como su media, desviación estándar, valor mínimo y máximo. La muestra contiene 16.012 observaciones.

Variable	Obs	Media	Desv. Est.	Min	Max
store	16.012	478	0	478	478
hour	16.012	13,85	3,67	8	20
period30min	16.012	28,21	7,36	16	41
ntrx	16.012	7,16	7,30	0	54
entrance	12.572	144,50	49,81	32	424
out	12.572	151,17	53,35	23	459
customers	16.012	1,59	1,50	0	14
salespeople	16.012	0,65	0,77	0	12
fcustomers	16.012	1,62	1,94	0	17
fsalespeople	16.012	0,65	0,98	0	12
nsamples	16.012	5,69	5,74	1	30
actual_hours	16.012	1,40	0,84	0	5
scheduled	16.012	1,40	0,86	0	6

Tabla 1.1: Estadísticos descriptivos de los datos agrupados por tienda, departamento, fecha, hora y periodo de 30 minutos.

Las variables *entrance* y *out* tienen menos observaciones que las demás, ya que hubo algunos días donde los sensores de movimiento no registraron información.

En la tabla 1.2 se presentan los departamentos en estudio con su respectivo número identificador.

id	Departamento
1	Appliances
2	Building Materials
3	Cabinets
4	Fashion Plumbing
5	Flooring
6	Hardware
7	Home Fashions
8	Lumber
9	Millwork
10	Outdoor Power Equipment
11	Paint
12	Rough Electrical
13	Rough Plumbing
14	Tools

Tabla 1.2: Lista de los departamentos bajo estudio con su respectivo identificador.

1.4. Histogramas de frecuencia de variables de interés

En la figura 1.1 se puede apreciar el histograma de frecuencia del número promedio de clientes por periodo y departamento, se puede mencionar que como se señala en la tabla 1.1 el número máximo del promedio de clientes es 14. En un alto porcentaje de tiempo los departamentos se encuentran sin clientes, en la mayoría de los casos hay 2 o menos clientes, además es muy poco probable observar un periodo de 30 minutos con un número promedio de clientes en algún departamento mayor o igual a 5 clientes, lógicamente no todos los departamentos se comportan de la misma manera, pero en promedio ocurre lo descrito anteriormente.




Figura 1.1: Histograma del número de clientes.

En la figura 1.2 se presenta el histograma del número promedio de vendedores por departamento y periodo de 30 minutos. Es fácilmente identificable que un alto porcentaje del

tiempo un departamento promedio no tiene vendedores presentes, muy rara vez se observó más de dos vendedores en promedio.




Figura 1.2: Histograma del número promedio de vendedores en un horizonte de 30 minutos.

Además en la figura 1.3 se representa el histograma de frecuencia de la variables *ntrx*, es decir, el número de transacciones por departamento y periodo de 30 minutos. En la mayoría de las observaciones la cantidad de transacciones es menor a 10, a diferencia de las variables anteriores, existen más periodos donde hay por lo menos una transacción en comparación a la cantidad de casos donde no se observan. Es muy poco probable encontrar un periodo de 30 minutos donde hubieron más de 20 transacciones en algún departamento.

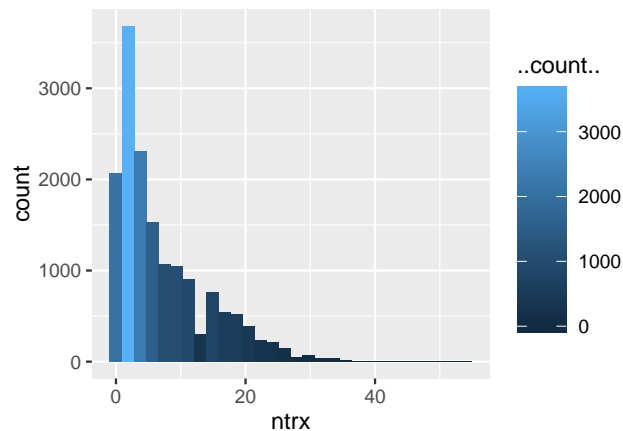


Figura 1.3: Histograma del número de transacciones.

Por otro lado en la figura 1.4 se muestra el histograma de frecuencia del número de clientes que ingresaron a la tienda, es necesario aclarar que es la cantidad de clientes que entraron en la tienda (no a algún departamento) por periodo de 30 minutos. Se puede notar que el ingreso a la tienda se concentra entre los 100 y 200 clientes cada 30 minutos, en pocas ocasiones el flujo de clientes supera los 200 y es menor a 75.




Figura 1.4: Histograma número de personas que ingresaron a la tienda.

Finalmente, se presenta en la figura 1.5 el histograma de frecuencia del número de clientes que salieron de la tienda durante el periodo de 30 minutos, el cual es semejante al histograma de entradas, como es esperar (puesto que todo cliente que entra a la tienda eventualmente saldrá). Al ser semejantes da algún indicio de que en promedio las personas se quedan dentro de la tienda un tiempo semejante.




Figura 1.5: Histograma del número de personas que salieron de la tienda.

1.5. Correlación entre variables de interés

En la tabla 1.3 se presentan las correlaciones entre las variables de interés, donde destaca el hecho que todas las correlaciones son positivas, resultado esperable considerando que en ninguna posible combinación de las variables expuestas es normal que tengan una correlación negativa, es decir, que al aumentar una la otra disminuya. Sin embargo, existen algunas que tienen correlación cercana a cero, como lo es el caso de la entrada y salida con el número de vendedores, donde hay una correlación de 0,097, esto tiene su explicación en que el número de vendedores que hay en la tienda no varía dependiendo de la cantidad de personas que

vayan ingresando o saliendo de la tienda, ya que los vendedores son fijados al inicio de la jornada y no varía significativamente a los largo de ella, como se puede apreciar en la figura 1.9.

	ntrx	salesp...	cust...	fsalesp...	fcust...	sch...	act...	ent...	out
ntrx	1,000								
salespeople	0,153	1,000							
customers	0,443	0,443	1,000						
fsalespeople	0,129	0,773	0,343	1,000					
fcustomers	0,363	0,351	0,775	0,306	1,000				
scheduled	0,155	0,243	0,175	0,198	0,138	1,000			
actual_hour	0,150	0,280	0,178	0,223	0,138	0,788	1,000		
entrance	0,236	0,118	0,276	0,097	0,211	0,200	0,195	1,000	
out	0,237	0,115	0,257	0,097	0,217	0,207	0,196	0,925	1,000

Tabla 1.3: Matriz de correlación

Las variables *entrance* y *out* tienen una correlación muy cercana a 1 (0,925), esto se condice con la semejanza en sus histogramas¹ y refuerza la teoría de que los clientes en su gran mayoría pasan un tiempo semejante dentro de la tienda, alrededor de uno o dos periodos. La correlación entre estas variables y el número de transacciones (*ntrx*), aunque es positiva no es tan alta como se esperaba, esto se puede explicar porque, estas dos variables están agregadas a nivel de tienda y no de departamento como lo está *ntrx*, quizás si se estudia las ventas totales de la tienda la correlación sería más alta.

Llama la atención que el número promedio de vendedores, aunque tiene una correlación positiva con el número de transacciones no es muy fuerte (0,153), lo que preliminarmente haría cuestionarse la eficiencia del accionar de los vendedores. También se observa una correlación positiva, pero no tan fuerte, entre el número promedio de vendedores y el número promedio de clientes (0,443) por lo que se podría pensar, en que los turnos de los vendedores están enfocados en periodos donde existe una mayor afluencia de público, pero hay un margen para mejorar este balance.

Por último, hay una alta correlación (0,775) entre el número promedio de clientes (*customers*) y la cantidad de clientes observados en la primera foto del periodo (*fcustomers*), por lo que se podría decir que la primera foto explica de buena forma la cantidad promedio de clientes que habrá durante ese periodo en ese departamento. De forma análoga ocurre con el número de vendedores y la cantidad de vendedores vistos al inicio del periodo.

¹Histogramas presentados en las figuras 1.4 y 1.5

1.6. Comportamiento horario de variables y diferencia entre departamentos

En esta sección se presenta el comportamiento, a lo largo del día, de las distintas variables de interés, así como también de los distintos departamentos dentro de la tienda para comprender las diferencias y semejanzas de cada departamento. Es relevante conocer los distintos *peaks* que se pueden presentar durante el día ya sea del flujo de clientes, transacciones, cantidad de vendedores, entre otras.

En la figura 1.6 se presenta la distribución de la entrada de clientes durante el día. Se puede apreciar que el *peak* de entradas de clientes se alcanza entre las 11 y 14 horas donde en promedio ingresan más de 150 personas cada 30 minutos, luego de las 14 horas este flujo comienza a disminuir en forma paulatina hasta las 20 horas donde el ingreso de clientes disminuye a 75 clientes en promedio. Además en la figura 1.7 se presenta la distribución de salida de clientes de la tienda, la cual tiene un comportamiento muy similar a la entrada de clientes.




Figura 1.6: Distribución de la entrada de clientes por hora.




Figura 1.7: Distribución de la salida de clientes por hora.

En la figura 1.8 se despliega la distribución del promedio de clientes por departamento, se observa un comportamiento aproximadamente homogéneo durante el día, no tiene un *peak* marcado durante la jornada. Se puede mencionar que a lo largo del día normalmente el promedio de clientes varía entre 1 y 3, además estos comienzan a llegar después de las 9 horas. En la figura 1.9 se presenta la distribución del promedio de vendedores por hora, el cual tampoco presenta un *peak* durante el día y en promedio hay entre 0 y 1 vendedor en cada departamento, manteniéndose esta cantidad prácticamente homogénea.




Figura 1.8: Distribución del promedio de clientes en los departamentos por hora.




Figura 1.9: Distribución del promedio de vendedores en los departamentos por hora.

La distribución del número de transacciones se muestra en la figura 1.10. Esta variable tampoco muestra un *peak* claro durante el día, más bien su comportamiento es homogéneo entre las 9 y 18 horas, antes y después de este intervalo las transacciones son casi nulas.




Figura 1.10: Distribución del número de transacciones en los departamentos por hora.

En la figura 1.11 se presenta la distribución del número de transacciones por departamento, en la cual se puede apreciar que los departamentos con mayor número de transacciones son *Hardware*, *Paint*, *Rough Plumbing* y *Tools*, donde en promedio las transacciones varían entre 10 y 20 cada 30 minutos. Sin embargo la figura 1.12, donde se muestra la distribución del número promedio de vendedores por departamento, indica que hay una mayor presencia de vendedores en los departamentos de *Appliances*, *Cabinets*, *Flooring*, *Hardware*, donde en promedio hay 0,5 y 1 vendedor, y *Paint*, donde hay entre 1 y 2 vendedores en promedio, lo que no se condice con los departamentos con el mayor número de transacciones, lo que

puede llevar a pensar preliminarmente que los vendedores no están distribuidos de la mejor manera, sin duda se debe llevar un análisis más profundo para poder llegar a alguna idea más concluyente.

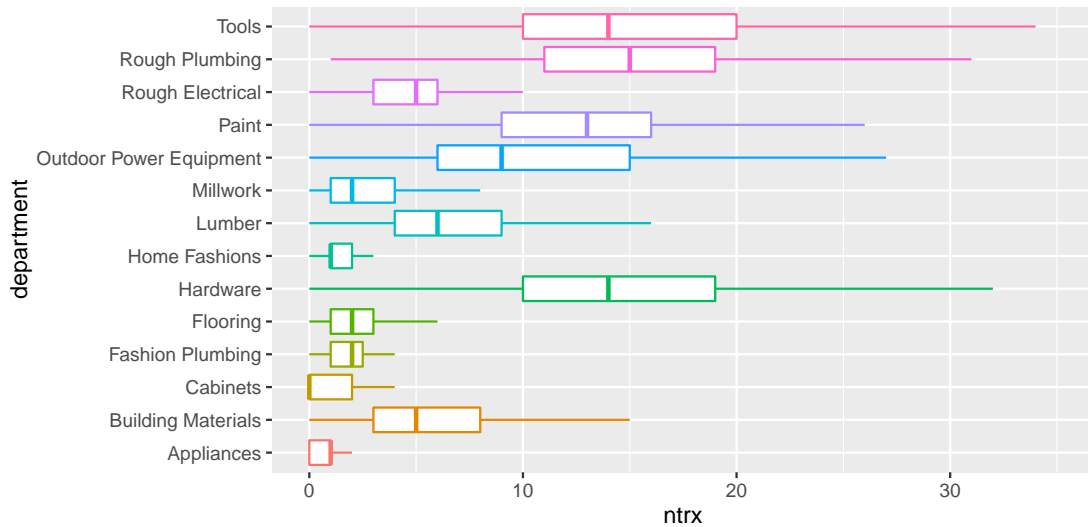


Figura 1.11: Distribución del número de transacciones por departamento.

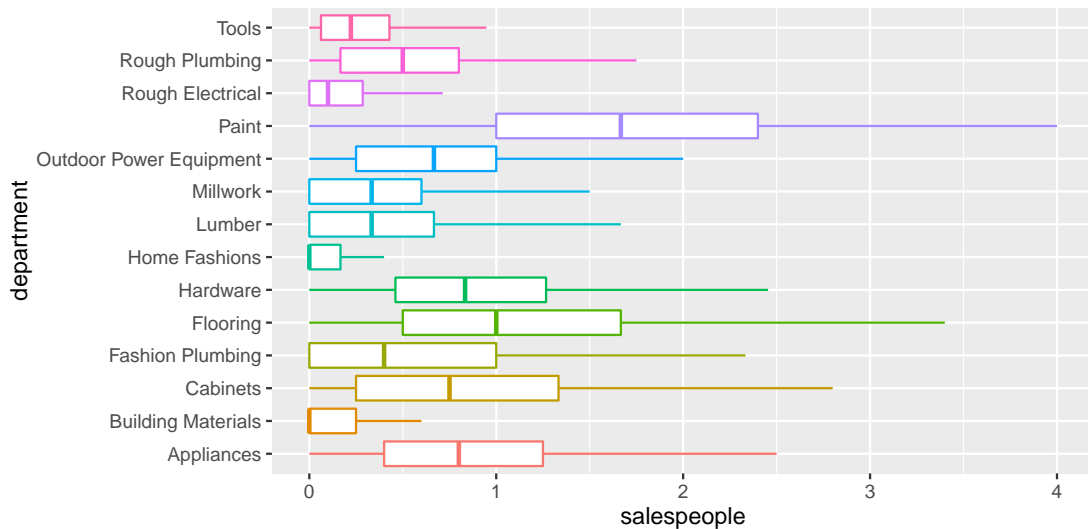


Figura 1.12: Distribución de número promedio de vendedores por departamento.

En la figura 1.13 se muestra la distribución del número promedio de clientes presentes en cada departamento, donde el departamento *Paint* es el que presenta una mayor presencia de clientes, lo que coincide con el departamento con mayor presencia de vendedores. Los departamentos que lo siguen en la cantidad de clientes son *Hardware* y *Rough Plumbing*, que en promedio presentan entre 1 y 3 clientes, sin embargo no son departamentos con un alto número de vendedores, lo que indicaría una alta proporción de clientes que no están siendo atendidos.




Figura 1.13: Distribución de número promedio de clientes por departamento.

De las figuras 1.11, 1.12 y 1.13 se desprende que existe cierta diferencia entre el comportamiento de los departamentos, por ejemplo, *Flooring* presenta un flujo de clientes considerable, pero esto no se ve traducido en una alta cantidad de transacciones, a diferencia de *Tools*, donde el flujo es menor, pero las transacciones son considerablemente mayores.

Capítulo 2

Análisis econométrico

En este capítulo se desarrollan distintos modelos econométricos que explican la cantidad de transacciones que se efectúan en los departamentos de la tienda durante un periodo de 30 minutos. Estos modelos se estiman utilizando el método Bayesiano, con el objetivo de encontrar el efecto de las variables más relevantes para el negocio y a su vez descubrir las variaciones de estos efectos entre los distintos departamentos dentro de la tienda. La mayoría de las variables utilizadas en estos modelos se describen en la sección 1.2.

2.1. Especificación del modelo econométrico

Es lógico pensar que la cantidad de transacciones dependen del número de clientes (C_{itf}) que se encuentren dentro del departamento, ya que es probable que estos clientes tengan la disposición de comprar algún producto de este departamento. Sin embargo, la cantidad de clientes varía considerablemente entre departamentos, como se puede apreciar en el *boxplot* de la figura 1.13, por lo anterior, es muy distinto que se presenten 3 clientes en el departamento "Paint", cuyo promedio de clientes es 3, en comparación al departamento "Home Fashions", donde en promedio hay 0,5 clientes, siendo atípico encontrar 3 clientes o más. Para lidiar con este problema se genera la variable *Cust_Level* (CL_{itf}), que señala, con respecto a todas las observaciones del número de clientes del departamento i , en que percentil se encuentra la observación C_{itf} . Esta variable toma valores entre 1 y 4 de la forma que se explica en la tabla 2.1. De esta manera podemos controlar la cantidad de clientes presentes en el departamento en relación a lo usualmente observado dentro de él, dado que si existe una cantidad alta de clientes en relación a lo normal dentro del departamento i , por ejemplo $CL_{itf} = 4$, entonces es esperable que aumenten las transacciones. Por lo tanto se tiene una variable que es comparable entre departamentos que puede ser usada en la estimación de los modelos, ya que incorpora dentro de su construcción la variabilidad existente en el número de clientes.

CL	percentil de C
1	25 %
2	50 %
3	75 %
4	100 %

Tabla 2.1: Definición de la variable CL según el percentil en que se encuentre la variable C .

Descrito lo anterior, se propone un modelo de conteo en donde las transacciones $ntrx_{itf}$ siguen un proceso de *Poisson*, en el cual su media, denotada por λ_{itf} , es explicada por la cantidad de vendedores S_{itf} y el nivel de clientes CL_{itf} presentes en el departamento i , en el periodo t , en la fecha f . También depende de un vector denotado por X_{itf} que contiene un conjunto de variables de control que se explicitan más adelante, en la sección 3.1.1.

Este primer modelo se caracteriza con las siguientes ecuaciones:

$$ntrx_{itf} \sim Poisson(\lambda_{itf}) \quad (2.1)$$

$$\mathbb{E}(ntrx_{itf}) = \lambda_{itf} \quad (2.2)$$

$$\ln(\lambda_{itf}) = \beta_o + \sum_{p=2}^4 \alpha_p \mathbf{1}_{\{CL_{itf}=p\}} + \gamma S_{itf} + \theta X_{itf} + \varepsilon_{itf} \quad (2.3)$$

En el modelo presentado, se realiza la transformación de $\ln(\lambda_{itf})$, debido a que la tasa de un proceso de *Poisson* no puede ser negativa.

Se utiliza un parámetro α_p para cada posible valor de la variable CL_{itf} , con $p \in \{1, 2, 3, 4\}$, en la ecuación no se incorpora α_1 , ya que para poder identificar estos parámetros se fija el nivel de clientes más bajo en 0. Al incorporar un parámetro por cada nivel de clientes se captura un posible efecto no lineal de esta variable, este parámetro se multiplica por la función indicatriz que toma el valor 1 cuando p es igual a la variable CL_{itf} , para que sólo se considere el α_p correspondiente.

Por otro lado γ captura el efecto que tiene el número de vendedores sobre la tasa de las transacciones, además θ es un vector con los parámetros asociados a las variables de control y ε_{itf} es el término de error.

Sin embargo la variable S_{itf} presenta problemas de endogeneidad, por lo que el parámetro γ será un estimador inconsistente. Este problema ocurre debido a que, es muy probable que clientes con altas intenciones de compra busquen a vendedores para poder encontrar el producto que desean, por lo tanto periodos con una gran cantidad de este tipo de clientes, tendrán un error más grande al igual que el número de vendedores confundiendo el efecto causal que se busca estimar, entonces:

$$\mathbb{E}(S^t \varepsilon) \neq 0$$

Para solucionar el problema de endogeneidad se utilizó el método de función de control (*Control Function*[11]). Este método se puede utilizar en modelos no lineales, como *Poisson*,

siendo muy adaptable cuando la variable endógena, en este caso S_{itf} , es continua. Sea Z el vector de variables exógenas¹, en cuyo primer elemento contiene un 1, entonces se escribe S en forma reducida de la siguiente manera:

$$\begin{aligned} S_{itf} &= \delta Z_{itf} + \theta' X_{itf} + u_{itf} \\ \mathbb{E}(Z^t u) &= 0 \end{aligned} \quad (2.4)$$

Donde X sigue siendo el mismo conjunto de variables de control utilizadas en la ecuación 2.3 y u_{itf} es el error asociado.

Dado que Z es exógena la endogeneidad de S se manifiesta si u está correlacionado con ε , entonces se puede descomponer ε en dos términos:

$$\varepsilon_{itf} = \rho u_{itf} + \nu_{itf} \quad (2.5)$$

En el primer término, el parámetro ρ captura la correlación existente entre ε y u , además por construcción $\mathbb{E}(u, \nu) = 0$, como consecuencia $\mathbb{E}(S, \nu) = 0$. Luego se reemplaza 2.5 en 2.3 y se obtiene:

$$\ln(\lambda_{itf}) = \beta_o + \sum_{p=2}^4 \alpha_p \mathbf{1}_{\{CL_{itf}=p\}} + \gamma S_{itf} + \theta X_{itf} + \rho u_{itf} + \nu_{itf} \quad (2.6)$$

En esta nueva ecuación se utiliza u_{itf} como variable explicativa de la tasa de transacciones y ν_{itf} es el nuevo error. Aún falta solucionar que u_{itf} es el error de la ecuación 2.4 y este error jamás se observa, por lo que como primer paso se debe estimar los parámetros de dicha ecuación y reemplazar:

$$u_{itf} \approx \hat{u}_{itf} = S_{itf} - (\hat{\delta} Z_{itf} + \hat{\theta}' X_{itf}) \quad (2.7)$$

Finalmente se reemplaza \hat{u}_{itf} en 2.6, obteniendo:

$$\begin{aligned} \ln(\lambda_{itf}) &= \beta_o + \sum_{p=2}^4 \alpha_p \mathbf{1}_{\{CL_{itf}=p\}} + \gamma S_{itf} + \theta X_{itf} + \rho \hat{u}_{itf} + \omega_{itf} \\ \omega_{itf} &= \nu_{itf} + \rho[(\hat{\delta}_{itf} - \delta_{itf}) Z_{itf} + (\hat{\theta}' - \theta') X_{itf}] \end{aligned} \quad (2.8)$$

Se denota *Modelo 1*, al modelo explicado por la ecuaciones 2.1, 2.2, 2.4, 2.5, 2.7 y 2.8

2.2. Extensión del modelo econométrico

Si bien es cierto el *Modelo 1* da una primera aproximación al efecto del número de vendedores que buscamos, parámetro necesario para poder realizar una asignación eficiente de la

¹El conjunto de variables exógenas se explican en la sección 3.1.1

fuerza de venta. Sin embargo, es útil estudiar otros posibles efectos que el primer modelo no considera. A continuación se presenta una lista de modelos que incorporan distintos efectos que son interesante considerar, en pro del objetivo de este trabajo, estos modelos sólo varían con respecto al *Modelo 1* en la ecuación 2.8:

- *Modelo 2:* Es relevante comprobar si existe heterogeneidad entre departamentos sobre el efecto de la cantidad de vendedores presentes, de esta manera es posible detectar en qué departamentos los vendedores son más efectivos en el sentido de generar más transacciones y en cuales no lo son tanto. Es posible que distintos tipos de clientes visiten diferentes departamentos, para este caso se pueden clasificar en dos categorías, clientes que necesitan un vendedor y los que no, por ejemplo, considere el departamento "*Home Fashions*", esta sección contiene distintos tipos de productos dirigidos a la decoración del hogar, por lo que sus clientes necesitarán que un empleado les presente todos los distintos modelos del producto que estén buscando para barajar todas las posibilidades y finalmente decidirse por alguno. En cambio el departamento "*Building Materials*", es una sección que contiene materiales para construcción, por lo que sus clientes, en su gran mayoría, son personas especialistas en construcción, los cuales conocen el material que necesitan y no requieren mayormente la asistencia de algún vendedor.

Entonces para incorporar la heterogeneidad explicada anteriormente, se reemplaza el parámetro " γ " de la ecuación 2.8, por γ_i con $i \in \text{Departamentos}$, es decir, un parámetro por cada departamento, resultando:

$$\ln(\lambda_{itf}) = \beta_o + \sum_{p=2}^4 \alpha_p \mathbf{1}_{\{CL_{itf}=p\}} + \gamma_i S_{itf} + \theta X_{itf} + \rho \hat{u}_{itf} + \omega_{itf} \quad (2.9)$$

- *Modelo 3:* En el mismo sentido, se estima una heterogeneidad en el efecto del número de vendedores en las transacciones que depende del horario, por las mismas razones explicadas en el modelo anterior, un cliente que sea especialista o que trabaje en cierto rubro, por lo que no necesitará asistencia de un vendedor, es probable que visite la tienda durante la mañana. En cambio un cliente que no sea especialista, probablemente visite la tienda durante la tarde. Para capturar este efecto, se agrega para cada departamento un parámetro, asociado al número de vendedores para cada turno. Se definen dos turnos, se denota mañana ("*M*") antes de las 12:00 horas y tarde ("*T*") después de las 12:00 horas. El modelo queda de la siguiente manera:

$$\ln(\lambda_{itf}) = \beta_o + \sum_{p=2}^4 \alpha_p \mathbf{1}_{\{CL_{itf}=p\}} + \gamma_{iT} \mathbf{1}_{\{t \in T\}} S_{itf} + \gamma_{iM} \mathbf{1}_{\{t \in M\}} S_{itf} + \theta X_{itf} + \rho \hat{u}_{itf} + \omega_{itf} \quad (2.10)$$

- *Modelo 4:* En el presente modelo se pretende estimar el efecto de la interacción entre S_{itf} y CL_{itf} . Es posible que los vendedores tengan un efecto mayor cuando hay un nivel de clientes más alto, ya que hay una mayor cantidad de clientes a los cuales atender. A continuación se presenta el modelo:

$$\ln(\lambda_{itf}) = \beta_o + \sum_{p=2}^4 \alpha_p \mathbf{1}_{\{CL_{itf}=p\}} + \gamma_{iT} \mathbf{1}_{\{t \in T\}} S_{itf} + \gamma_{iM} \mathbf{1}_{\{t \in M\}} S_{itf} + \kappa CL_{itf} S_{itf} + \theta X_{itf} + \rho \hat{u}_{itf} + \omega_{itf} \quad (2.11)$$

- *Modelo 5:* En este modelo se testeará heterogeneidad interdepartamental para el efecto incorporado en el *Modelo 4*, es decir a la interacción entre CL_{itf} y S_{itf} . Por lo tanto se estima un parámetro κ por departamento, resultando:

$$\begin{aligned} \ln(\lambda_{itf}) = & \beta_o + \sum_{p=2}^4 \alpha_p \mathbf{1}_{\{CL_{itf}=p\}} + \gamma_{iT} \mathbf{1}_{\{t \in T\}} S_{itf} + \gamma_{iM} \mathbf{1}_{\{t \in M\}} S_{itf} + \kappa_i CL_{itf} S_{itf} \\ & + \theta X_{itf} + \rho \hat{u}_{itf} + \omega_{itf} \end{aligned} \quad (2.12)$$

- *Modelo 6:* Es interesante además estudiar un posible efecto de saturación en el número de vendedores, es decir, estudiar si el efecto marginal de agregar vendedores cambia a medida que el número de vendedores crece, por ejemplo, es probable que el efecto de agregar 1 vendedor al departamento, si anteriormente no habían vendedores, sea mayor en comparación a agregar un vendedor cuando antes de él ya habían 5 empleados. Para capturar este efecto se incorpora el cuadrado del número de vendedores², S_{itf}^2 :

$$\begin{aligned} \ln(\lambda_{itf}) = & \beta_o + \sum_{p=2}^4 \alpha_p \mathbf{1}_{\{CL_{itf}=p\}} + \gamma_{iT} \mathbf{1}_{\{t \in T\}} S_{itf} + \gamma_{iM} \mathbf{1}_{\{t \in M\}} S_{itf} + \kappa_i CL_{itf} S_{itf} + \pi S_{itf}^2 \\ & + \theta X_{itf} + \rho \hat{u}_{itf} + \omega_{itf} \end{aligned} \quad (2.13)$$

- *Modelo 7:* En el efecto incorporado en el modelo anterior, es interesante estudiar si existe diferencias entre departamentos, por lo que se reemplaza π por π_i , es decir un parámetro por departamento:

$$\begin{aligned} \ln(\lambda_{itf}) = & \beta_o + \sum_{p=2}^4 \alpha_p \mathbf{1}_{\{CL_{itf}=p\}} + \gamma_{iT} \mathbf{1}_{\{t \in T\}} S_{itf} + \gamma_{iM} \mathbf{1}_{\{t \in M\}} S_{itf} + \kappa_i CL_{itf} S_{itf} + \pi_i S_{itf}^2 \\ & + \theta X_{itf} + \rho \hat{u}_{itf} + \omega_{itf} \end{aligned} \quad (2.14)$$

- *Modelo 8:* En este modelo se estudia el efecto conjunto entre la interacción del nivel de clientes con el número de vendedores y el efecto cuadrático del número de vendedores, pero sin diferencia entre departamentos:

$$\begin{aligned} \ln(\lambda_{itf}) = & \beta_o + \sum_{p=2}^4 \alpha_p \mathbf{1}_{\{CL_{itf}=p\}} + \gamma_{iT} \mathbf{1}_{\{t \in T\}} S_{itf} + \gamma_{iM} \mathbf{1}_{\{t \in M\}} S_{itf} + \kappa CL_{itf} S_{itf} + \pi S_{itf}^2 \\ & + \theta X_{itf} + \rho \hat{u}_{itf} + \omega_{itf} \end{aligned} \quad (2.15)$$

- *Modelo 9:* Finalmente, bajo los mismo supuestos que en el *Modelo 2*, se agrega una heterogeneidad en el efecto del número de vendedores que diferencia a los días laborales (de lunes a viernes) versus los fin de semanas (sábado y domingo). Para estimar este efecto se agrega un parámetro γ para los días de la semana y otro para los días de fin de semana, para identificar estos nuevos parámetros se utiliza "S" para los días laborales

²Para evitar posibles problemas de interpretación $S_{itf}^2 = S_{itf} * S_{itf}$

y para los fin de semana "F". Además se define wk como el conjunto que contiene a los días de fin de semana.

$$\begin{aligned}
\ln(\lambda_{itf}) = & \beta_o + \sum_{p=2}^4 \alpha_p \mathbf{1}_{\{CL_{itf}=p\}} + \gamma_{iTF} \mathbf{1}_{\{t \in T \wedge f \in wk\}} S_{itf} + \gamma_{iMF} \mathbf{1}_{\{t \in M \wedge f \in wk\}} S_{itf} \\
& + \gamma_{iTS} \mathbf{1}_{\{t \in T \wedge f \notin wk\}} S_{itf} + \gamma_{iMS} \mathbf{1}_{\{t \in M \wedge f \notin wk\}} S_{itf} + \kappa_i CL_{itf} S_{itf} \\
& + \theta X_{itf} + \rho \hat{u}_{itf} + \omega_{itf}
\end{aligned} \tag{2.16}$$

Capítulo 3

Resultados empíricos y discusión

En este capítulo se presentan los resultados empíricos de los modelos presentados en el capítulo anterior y la discusión de ellos.

3.1. Variables de control y exógenas

3.1.1. Controles

Los controles incorporados en los modelos presentados en la sección 2.1.

Específicamente los controles considerados son:

- Día de la semana (*day*): Indica el tipo de día, es decir, lunes, martes, miércoles, etc.
- Departamento(*dept*): Un efecto fijo por cada departamento de la tienda.
- Feriados(*holiday*): Indica si un día fue festivo en Estados Unidos. Por ejemplo, “Presidents Day”, “Independence Day”, entre otros.
- hora(*hour*): Para controlar por la hora, desde las 8 hasta 20 horas.
- Semana(*week*): Se incorpora un control para cada semana, de esta forma se puede capturar una tendencia no lineal a través del tiempo en las transacciones.

3.1.2. Variables exógenas

Para utilizar el método de función de control (que repara el problema de endogeneidad) en la ecuación 2.4 se utilizaron dos variables exógenas:

- *scheduled* (sc_{itf}): Horas hombres de vendedores calendarizadas para el periodo t , en el departamento i , en la fecha f .

- *actual_hours* (ah_{itf}): Horas hombres de vendedores que realmente estuvieron disponibles, es decir, que asistieron en el periodo t , en el departamento i , en la fecha f .

Estas variables afectan la cantidad de vendedores en un departamento, durante un periodo, en una fecha específica. Ya que evidentemente, si en la tienda está calendarizado un número de vendedores, para ese departamento, es probable que esos vendedores estén presentes. Así como también será afectado por el ausentismo de los vendedores, el cual está reflejado en *actual_hours* (ah_{itf}). Además estas dos variables no tienen ningún tipo de reacción ante las posibles fluctuaciones en el número de clientes que se observe, por lo que estas variables no son afectadas por los problemas que causan la endogeneidad de S_{itf} . Por lo antes mencionado estas dos variables son relevantes y exógenas, por lo que pueden ser utilizadas como instrumentos.

3.2. Estimación

La estimación de los modelos se realiza a través del método Jerárquico Bayesiano.

La jerarquía es utilizada para aquellos modelos en que el efecto del número de vendedores es diferente en cada departamento, por lo tanto para obtener un parámetro individual por departamento se considera que todos estos tienen un *prior* en común, que es la información global de la tienda, es decir, se considera que el efecto de vendedores en las transacciones en toda la tienda es informativo para poder estimar el efecto particular por cada departamento. Por otro lado, para aquellos modelos en que la heterogeneidad en el efecto del número de vendedores también depende de la hora del día y/o si es fin de semana o no, se considera una jerarquía por cada jornada y también por cada tipo de día. Entonces la jerarquía se puede expresar de la siguiente manera:

$$\gamma_{ijd} \sim N(\bar{\gamma}_{jd}, V_{\bar{\gamma}_{jd}}), \quad j \in \{M, T\}, \quad d \in \{F, S\}$$

Donde $\bar{\gamma}_{jd}$ y $V_{\bar{\gamma}_{jd}}$ corresponden, respectivamente, a la media y desviación estándar de los parámetros entre departamentos para cada jornada j y tipo de día d .

Las distribuciones de los *hiper-priors* se presentan a continuación:

$$\bar{\gamma}_{jd} \sim N(0, 100) \quad j \in \{M, T\}, \quad d \in \{F, S\}$$

$$V_{\bar{\gamma}_{jd}} \sim U(0, 30) \quad j \in \{M, T\}, \quad d \in \{F, S\}$$

También se consideró una jerarquía en los modelos que incorporan heterogeneidad en el efecto de la interacción entre el nivel de clientes CL y el número de vendedores S , capturado por el parámetro κ_i . Por otro lado, en los modelos en que el efecto cuadrático del número de vendedores, π_i , varía entre departamentos. La jerarquía se expresa de la siguiente manera:

$$\kappa_i \sim N(\bar{\kappa}, V_{\bar{\kappa}})$$

$$\pi_i \sim N(\bar{\pi}, V_{\bar{\pi}})$$

Donde la distribución de los *hiper-priors* son:

$$\bar{\kappa}, \bar{\pi} \sim N(0, 100)$$

$$V_{\bar{\kappa}}, V_{\bar{\pi}}, \sim U(0, 30)$$

Para todos los demás parámetros se utilizan *priors* planos, con la finalidad de que sean poco informativos. En específico se utilizó una distribución $N(0, 100)$.

Para estimar estos modelos se utilizó el software Winbugs¹, que es una herramienta que utiliza el método *MCMC* con *Gibbs Sampling*[9] para poder obtener las distribuciones *posteriori* de los parámetros y realizar las inferencias buscadas. La configuración de las cadenas de markov utilizadas considera un total de 100.000 iteraciones, de las cuales se descartan las primeras 30.000, para alcanzar el estado estacionario de la cadena y se guardan los resultados cada 100 iteraciones con el fin de evitar correlaciones entre una iteración y la siguiente.

3.3. Resultados

En la tabla 3.1 se comparan los modelos presentados bajo el criterio DIC², en la cual los modelos con mejor criterio de selección son *modelo 6* y *modelo 7* (menor DIC es mejor) con un DIC igual a 103.071,9, seguido por el *modelo 5* con 103.128, luego por el *modelo 3* con 103.156. Ante la igualdad entre el *modelo 6* y *7* se selecciona el *modelo 6* debido a que posee una menor cantidad de parámetros siendo más simple para trabajar. Cabe recordar que el *modelo 6* considera heterogeneidad en el efecto del número de vendedores entre departamentos y dependiente del turno, además de heterogeneidad entre departamentos para la interacción entre el nivel de clientes y el número de vendedores, finalmente incorpora el efecto cuadrático del número de vendedores, sin considerar heterogeneidad en este parámetro.

Modelo	DIC
1	103.321,1
2	103.229
3	103.156
4	103.332,8
5	103.128
6	103.071,9
7	103.071,9
8	103.382,5
9	103.867,5

Tabla 3.1: Criterio DIC para los modelos estimados.

Los resultados de la estimación de todos los modelos son presentados en el apéndice B.1.

¹<http://www.mrc-bsu.cam.ac.uk/software/bugs/>

²Deviance information criterion[1] es un criterio para comparar modelos, está diseñado especialmente para modelos jerárquicos bayesianos estimados a través de MCMC

En la tabla 3.2 se presenta el valor de los parámetros estimados para el *modelo 6*, por otro lado la cadena del método MCMC alcanza la convergencia para todos los parámetros relevantes, es decir, todos los que se presentan en la tabla antes mencionada. Sin embargo, para algunas variables de control no se alcanza la convergencia, este problema se puede atribuir a que el modelo no fue capaz de identificar el efecto de todos los controles que se incorporaron, pero logró identificar la gran mayoría de ellos. En el anexo B.2 se muestran los *trace-plots* que comprueban la convergencia de los parámetros de interés.

Tabla 3.2: Resultados *modelo 6*

Variable	Media posteriori	sd	Variable	Media posteriori	sd
CL_1	0*	0	sales[1,M]	0.08804	0.07724
CL_2	0.09973*	0.009592	sales[1,T]	0.1745*	0.06625
CL_3	0.1779*	0.01031	sales[2,M]	0.3251*	0.08799
CL_4	0.2733*	0.01362	sales[2,T]	0.07625	0.08132
$CL \times S_1$	0.01537	0.01722	sales[3,M]	0.1808*	0.06457
$CL \times S_2$	0.004397	0.02229	sales[3,T]	0.3876*	0.0571
$CL \times S_3$	-0.06405*	0.01593	sales[4,M]	0.118	0.07337
$CL \times S_4$	-0.02026	0.01787	sales[4,T]	0.1743*	0.06843
$CL \times S_5$	-0.00187	0.01244	sales[5,M]	0.1777*	0.05577
$CL \times S_6$	0.01161	0.007779	sales[5,T]	0.1799*	0.05578
$CL \times S_7$	-0.0171	0.02568	sales[6,M]	0.1235*	0.03885
$CL \times S_8$	-0.01193	0.01329	sales[6,T]	0.1243*	0.03793
$CL \times S_9$	-0.0341*	0.01864	sales[7,M]	0.01019	0.1371
$CL \times S_{10}$	0.01735*	0.008257	sales[7,T]	0.2399*	0.1017
$CL \times S_{11}$	-0.01639*	0.004044	sales[8,M]	0.3159*	0.05581
$CL \times S_{12}$	-0.02274	0.0197	sales[8,T]	0.1304*	0.04852
$CL \times S_{13}$	-0.04077*	0.01024	sales[9,M]	0.3268*	0.07207
$CL \times S_{14}$	0.0005004	0.01578	sales[9,T]	0.1662*	0.06831
<i>Intercept1</i>	-2.908*	0.2915	sales[10,M]	0.1056*	0.04074
	Control Function:		sales[10,T]	0.1262*	0.04022
ρ	-0.1349*	0.02834	sales[11,M]	0.2291*	0.03555
<i>Intercept2</i>	-0.2225	0.4827	sales[11,T]	0.2054*	0.03455
<i>scheduled</i>	0.02169*	0.009338	sales[12,M]	0.07123	0.08372
<i>actual_hour</i>	0.1499*	0.009466	sales[12,T]	0.2198*	0.07167
	Hiper-prior		sales[13,M]	0.2267*	0.04388
$V_{\bar{\gamma}_M}$	0.1293*	0.0448	sales[13,T]	0.2973*	0.04392
$V_{\bar{\gamma}_T}$	0.1146*	0.03622	sales[14,M]	0.08827	0.06218
$V_{\bar{\kappa}}$	0.03033*	0.008905	sales[14,T]	0.04627	0.05975
$\bar{\gamma}_M$	0.1697*	0.0529	sales2	-0.005013	0.00307
$\bar{\gamma}_T$	0.1832*	0.04824			
$\bar{\kappa}$	-0.01279	0.01064			

Significance levels : * : 5%

Con los parámetros asociados a la variable CL se comprueba que existe un efecto creciente y lineal, lo que se puede apreciar en la figura 3.1, recordar que CL_1 se fijó en cero como referencia. Entonces mientras mayor sea el percentil de clientes en el departamento mayor serán las transacciones esperadas, resultado que concuerda con la intuición de a mayor cantidad de clientes mayor venta.

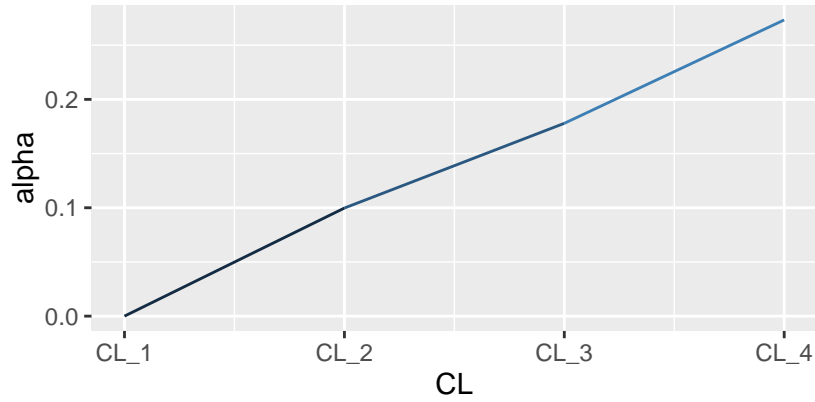


Figura 3.1: Efecto estimado para el nivel de clientes (α).

Es interesante destacar, con respecto al efecto del número de vendedores en las transacciones, que existe heterogeneidad entre departamentos, siendo para todos ellos un efecto positivo, es decir, a mayor cantidad de vendedores mayores son las transacciones esperadas. Además algunos departamentos presentan distinto comportamiento dependiendo de la jornada. En la figura 3.2 se puede apreciar la dispersión que existe en este efecto, además del comportamiento para el mismo departamento según la jornada. Por lo tanto, se pudo detectar una heterogeneidad entre departamentos y un comportamiento diferente según la jornada, debido a las razones expuestas en la especificación del modelo. Por ejemplo, el departamento 7 que corresponde a "Home Fashions", un departamento donde se venden productos de decoración para el hogar, se observa que durante la tarde el efecto de los vendedores es mucho mayor que en la mañana, ya que la gran mayoría de personas que buscan este tipo de productos trabajan en la mañana y pueden comprar en la tarde, donde requerirán la atención de los vendedores.




Figura 3.2: Efecto del número de vendedores sobre el número de transacciones, en función de departamento y jornada (γ).

Por otro lado, en la interacción de CL con S se incorpora heterogeneidad entre departamentos. Es importante notar que en este caso CL se utilizó como una variable continua, porque de lo contrario, la cantidad de parámetros a estimar para este efecto son demasiados, cantidad de niveles multiplicado por número de departamentos. Se puede observar en la figura 3.3 que si existe heterogeneidad, curiosamente sólo hay 3 departamentos en que este efecto es positivo (1, 6 y 10), por lo tanto en general, a mayor nivel de clientes el efecto principal del número de vendedores se ve disminuido, esto posiblemente debido a un efecto de saturación dentro de los departamentos, ya que una gran masas de individuos dentro del mismo departamento causa molestia a los clientes, viendo afectado el número de transacciones.




Figura 3.3: Efecto sobre el número de transacciones de la interacción entre nivel de clientes y número de vendedores por departamento (κ).

Esto también se ve reflejado en el parámetro asociado a la variables S^2 , siendo este negativo, aportando a la idea de saturación pero en este caso teniendo en consideración solamente a los vendedores. Llegando incluso a existir una cantidad suficiente de vendedores que al agregar uno más no aporta valor, de hecho puede llegar a disminuir las transacciones.

Finalmente, en las figuras 3.4 y 3.5 se muestra el impacto porcentual en las transacciones según los vendedores y el nivel de clientes, se toman como ejemplo los departamento 2 y 7. En estos gráficos se puede dimensionar el impacto de las variables estudiadas dentro del rendimiento de la tienda. Una posible interpretación es la siguiente, para el departamento 2 en la tarde para un día cualquiera, si el nivel de clientes es 2 entonces incorporar 2 vendedores aumentarán las transacciones en un 25 % aproximadamente, si por el contrario no se asignaran vendedores las ventas aumentan en un 12,5 %. Por otro lado, si el nivel de clientes fuera 4, entonces agregar 4 vendedores tendría un aumento del 75 % aproximadamente. El incremento porcentual mencionado anteriormente toma como referencia el nivel de clientes 1 y ningún vendedor asignado, es decir, las ventas promedio que tiene un día x en una hora dada en ese departamento, estas ventas promedio aumentan porcentualmente según la configuración que se tenga (cantidad de vendedores y clientes). Cabe destacar que en el departamento 7 durante la mañana para todos los niveles de clientes, agregar un vendedor más (sin importar la cantidad que haya) el incremento de las ventas será menor en comparación a que ningún vendedor atienda.





Figura 3.4: Incremento porcentual de las ventas para el departamento 2 en cada turno, según el número de vendedores y el nivel de clientes



(a) Depto 7 turno mañana

(b) Depto 2 turno tarde

Figura 3.5: Incremento porcentual de las ventas para el departamento 7 en cada turno, según el número de vendedores y el nivel de clientes

Capítulo 4

Simulación de políticas de asignación eficiente de vendedores

A continuación, utilizando los parámetros estimados en el capítulo 3, se estudia el efecto en el incremento de transacciones que genera una asignación eficiente de los empleados, donde se consideran todas las variables presentadas en el mencionado capítulo. Además se calcula el rendimiento de distintos tipos de políticas de atención, para poder descubrir el potencial valor de capacitar a los vendedores para que adquieran los conocimientos necesarios con el fin de atender a los clientes en distintos departamentos, de esta manera la fuerza de ventas obtiene una mayor flexibilidad en sus movimientos dentro de la tienda, ya que pueden ayudar a los clientes en una mayor cantidad de departamentos.

En primera instancia se calculan las transacciones esperadas que logra una política completamente restrictiva, donde los vendedores sólo pueden atender a un departamento, para luego comparar el rendimiento de esta configuración con otras políticas donde se incorpora mayor flexibilidad de atención. Como instrumento de medición del rendimiento de cada configuración, se utiliza el número esperado de transacciones.

4.1. Heurística de asignación eficiente

La heurística aplicada en la asignación eficiente de vendedores en cada periodo es una heurística *Greedy* que busca maximizar la esperanza del número de transacciones, donde la variable de decisión es la cantidad de vendedores asignados a cada departamento dado todas las demás variables utilizadas en el *modelo 6* del capítulo 2. Cabe recordar que se considera el cuartil del número promedio de clientes, el departamento, el día, la hora, entre otras variables. La lógica que sigue esta heurística es que en cada periodo de 30 minutos se asignan vendedores de uno en uno al departamento que presente el más alto incremento marginal en el número de transacciones por la adición de un vendedor, de esta forma asignar todos los vendedores disponibles en ese periodo dentro de la tienda.

Sea D el conjunto de departamentos y $(G_n)_{n=1}^{N_{grupos}}$ una partición de D , donde N_{grupos} es

la cantidad de subconjuntos de departamentos definidos según la política¹ de atención que se esté utilizando. Para cada fecha disponible en las observaciones se define lo siguiente, T el conjunto de periodos de 30 minutos, denotamos con $s \in \{Mañana, Tarde\}$ al turno al cual pertenece el periodo de 30 minutos que se está evaluando, $disp_{t, G_n}$ la disponibilidad de vendedores, en el periodo $t \in T$ y subconjunto G_n , al cual pertenece el departamento simulado. Además SP_{it} es el número de vendedores asignados al departamento i en el periodo t , $Smin_{it}$ y $Smax_{it}$ son respectivamente el mínimo y máximo de vendedores permitidos en el departamento i , periodo t . Δtrx_i denota al incremento marginal de la esperanza de las transacciones del departamento i por agregar un vendedor más. Finalmente se denota por ET a la función que calcula las transacciones esperadas que dependen del número de vendedores y todas las variables de control utilizadas en el modelo θ . Es importante mencionar que por temas de espacio en el pseudocódigo, presentado a continuación, sólo se evalúa esta función en el número de vendedores ya que es el único término que varía, se da por entendido que se le entregan todos los demás argumentos necesarios.

```

1: for  $t \in T$  do
2:    $SP_{it} = Smin_{it} \forall i \in D$ 
3:   for  $n = 1$  to  $N_{grupos}$  do
4:      $\Delta trx_i = 0 \forall i \in G_n$ 
5:     while  $disp_{t, G_n} > \sum_{i \in G_n} SP_{it}$  do
6:       for  $i \in G_n$  do
7:         if  $SP_{it} < Smax_{it}$  then
8:            $\Delta trx_i = ET(SP_{it} + 1) - ET(SP_{it})$ 
9:         end if
10:      end for
11:      Sea  $k^* \in G_n$  donde  $\Delta trx_{k^*} \geq \Delta trx_i \forall i \in G_n$ 
12:       $SP_{k^*t} = SP_{k^*t} + 1$ 
13:       $\Delta trx_i = 0 \forall i \in G_n$ 
14:    end while
15:  end for
16: end for

```

4.2. Especificaciones generales de las simulaciones

Para medir el número esperado que logra la asignación eficiente de vendedores y la política de atención utilizada, se simulan las transacciones de la tienda utilizando los datos disponibles, que fueron descritos en el capítulo 1.

Al inicio de cada periodo de 30 minutos se decide, a partir de la heurística de asignación, cuantos vendedores posicionar en cada uno de los departamentos de la tienda, estos vendedores estarán disponibles en su departamento asignado por 30 minutos, momento en el cuál se vuelven a reasignar todos los empleados. Al inicio del periodo la heurística utiliza todos los

¹Las políticas consisten en definir una cantidad de subgrupos de departamentos, donde un vendedor asignado a un subgrupo sólo puede atender a clientes que esté dentro de los departamentos pertenecientes al subgrupo.

datos que se conocen *a priori* (hora, fecha, día de la semana, turno, entre otros) y captura el número de clientes que están presentes en cada departamento en ese instante, dato que se puede obtener de las cámaras instaladas en la tienda. Luego de tomada la decisión, se calculan las ventas esperadas que logra la asignación considerando el número promedio de clientes que se observaron en cada departamento durante el periodo.

Por otro lado, se tuvieron las siguientes consideraciones generales:

- Se simula el número de transacciones en periodos de 30 minutos de manera discreta.
- Para un subconjunto G_n de departamentos de la tienda, se considera una disponibilidad de vendedores por fecha y periodo de 30 minutos, es decir, todos estos empleados son asignados a ese subgrupo G_n . Para obtener esto, se calcula para cada departamento dentro del subconjunto, el promedio de vendedores que hubo esa fecha durante el turno² correspondiente, luego se suma el promedio de todos los departamentos en el subconjunto y esto es utilizado como la disponibilidad de vendedores para ese día, en ese periodo y en ese subconjunto. El número de vendedores que hubo disponible en cada departamento, en el día y periodo de 30 minutos es obtenido de la variable *actual_hour_{it}*. Recordar que la variable está indexada por departamento y periodo.
- Los vendedores sólo pueden ser asignados en los departamentos que pertenezcan al subgrupo designado para ese vendedor.
- Para no extrapolar los resultados de las estimaciones de manera excesiva, se evita incorporar una mayor cantidad de vendedores que los observados en los datos disponibles, para esto se restringe a que los vendedores asignados no pueden ser menor ni mayor al mínimo y máximo número de vendedores observados en el departamento, hora y día que se esté simulando, por ejemplo, se calculó el máximo y mínimo de vendedores observados en “*Appliances*” a las 8:00 horas de todos los días viernes.
- Las simulaciones se corrieron bajo los datos disponibles expuestos en el capítulo 1.

4.3. Caso base

Con el fin de tener un punto de referencia, se simula un escenario en que cada vendedor es asignado a un sólo departamento, es decir, atiende a clientes que estén dentro de su zona sin poder moverse a otras secciones de la tienda, por lo tanto, es una situación totalmente inflexible. Para este caso, el hecho de que los vendedores se asignen a un departamento es equivalente a decir que hay 14 subgrupos, uno por cada departamento, entonces $N_{grupos} = 14$. Por lo tanto, la solución de la heurística de asignación es trivial, porque cada subgrupo G_n contiene un elemento, como resultado el vendedor es asignado a ese único elemento. Finalmente la cantidad de vendedores designados a cada departamento $i \in D$ es igual al mínimo entre el máximo permitido y la disponibilidad de vendedores:

$$SP_{it} = \min\{disp_{t,G_n}, Smax_{it}\}$$

²Se consideraron dos turnos, desde 8:00 a 12:00 horas y desde 12:01 hasta 20:00 horas, llamados mañana y tarde respectivamente.

Es relevante mencionar que $disp_{t,G_n}$ y $Smax_{it}$ de cada departamento o, en este caso, cada subgrupo se calculó de la forma explicada en la sección 4.2.

4.4. Grupos

Para incorporar una mayor flexibilidad en la política de atención, se asumirá que los vendedores están capacitados para atender en más de un departamento, a diferencia de lo que se presentó en la sección 4.3 donde los empleados permanecían en sólo una zona. Por lo tanto los grupos de departamentos definidos deben contener más de un elemento, mientras más departamentos contenga el grupo existe una mayor flexibilidad en la atención, ya que pueden ayudar a los clientes presentes en todos los departamentos de ese subgrupo. En este sentido se presentan distintas políticas donde se va incorporando paulatinamente mayor flexibilidad.

Los grupos de departamentos serán definidos según la distribución espacial dentro de la tienda, es decir, se agrupan a departamentos que sean colindantes³. Recordar que hay 14 departamentos en la tienda estudiada. Esta definición de los grupos busca que no haya diferencia entre la cantidad de departamentos de cada grupo, en otras palabras, la cardinalidad de los G_n sean parecidas. Como consecuencia la variable N_{grupos} está inversamente relacionada con la flexibilidad en la atención, ya que a menor número de grupos, más elementos están contenidos en estos grupos, por ejemplo, si $N_{grupos} = 14$ cada grupo contiene 1 departamentos lo que implica poca flexibilidad, por otro lado si $N_{grupos} = 2$ los grupos contienen 7 departamentos, por lo tanto una mayor flexibilidad en el movimiento de los empleados. Se simularon políticas en donde se va disminuyendo N_{grupos} a medida que se incorpora flexibilidad, en concreto los valores utilizados para N_{grupos} fueron 14, 7, 6, 5, 3, 2 y 1. Los departamentos que se asignan a cada grupo en en cada política, se pueden apreciar en Apéndice C.1.

4.5. Resultados

En la tabla ?? se presentan las transacciones esperadas para cada una de las políticas simuladas y el incremento porcentual en las transacciones con respecto al escenario con menor flexibilidad correspondiente a 14 grupos, este escenario es utilizado como caso base según se explicó en la sección 4.3. En esta tabla se aprecia que las transacciones incrementan considerablemente a medida que la flexibilidad aumenta, sólo con pasar de 14 a 7 grupos, lo que es equivalente a decir que los empleados pasan de atender 1 a 2 departamentos, el incremento en transacciones esperadas es igual a 2,4 %, incremento que es mucho más importante si consideramos el caso extremo en que los vendedores pudieran atender en cualquier departamento, lo que es la mayor flexibilidad posible con $N_{grupos} = 1$, donde el incremento alcanza un 11,5 %. Sólo como referencia el total de transacciones en los datos disponibles es de 114.673, además es importante recalcar que se consideró la misma dotación de vendedores que se dispone actualmente en la tienda.

³La distribución de los departamentos se puede apreciar en el plano presentado en la sección A.1

N_{grupos}	$E(transacciones)$	incremento % c/r a caso base
14	123.538	0 %
7	126.042	2,02 %
6	131.700	6,60 %
5	133.359	7,95 %
3	134.514	8,88 %
2	135.573	9,74 %
1	137.625	11,40 %

Tabla 4.1: Tabla que reporta las transacciones esperadas para cada política definida según la cantidad de grupos, además se presenta el incremento porcentual con respecto a la política con 14 grupos.




Figura 4.1: Incremento porcentual de las transacciones según la cantidad de grupos con respecto al caso base.

En la figura 4.1 se gráfica el incremento porcentual en las transacciones esperadas según el número de grupos con respecto al caso base. Se puede apreciar que el aumento en las transacciones es más marcado en los primeros escenarios, es decir, de pasar de inflexibilidad a un poco más de movilidad, luego en los siguientes escenarios el aumento comienza a estabilizarse.

Capítulo 5

Conclusión

En este trabajo se utilizan datos provenientes del procesamiento de videos de cámaras de seguridad de una tienda de retail ferretero, con estos datos se conoce la cantidad de vendedores y clientes que hay en cada una de las secciones de la tienda. Complementando esta información con los datos del punto de venta, de lo que se obtiene la cantidad de transacciones que ocurren en cada departamento, en específico cada transacción de la tienda que contenía a lo menos un producto del departamento “*i*” era asignada a dicho departamento, por lo tanto una transacción puede ser asignada a más de un departamento. Con esto, utilizando el método Jerárquico Bayesiano, se estudia el efecto que tienen los vendedores en la cantidad de transacciones que ocurren en cada departamento.

Se encontró que el efecto de los vendedores varía entre departamentos, esta heterogeneidad se explica por la naturaleza de los productos que se venden en cada departamento y el tipo de clientes que visitan la tienda. Lo último se ve con mayor claridad al observar que el efecto de los vendedores dentro del mismo departamento varía dependiendo de la hora del día, es decir, para algunos departamentos el efecto cambia significativamente si es antes o después de las 12:00 horas, esto implica que el tipo de cliente que visita la tienda es distinto en la mañana y en la tarde, por ejemplo el departamento 7 presenta un efecto en la mañana de 0,0109 y en la tarde de 0,2399, es decir, un vendedor más aumenta las transacciones un 1 % en la mañana y un 27 % en la tarde. Este departamento es "Home Fashions", una probable explicación es que en la mañana el tipo de clientes que visitan el departamento son personas que trabajan en este ámbito por lo que no necesitan la asistencia de los vendedores, ya que tienen muy claro lo que comprarán, por el contrario en la tarde el tipo de clientes son familias que buscan productos para su hogar, por lo que la atención de los vendedores es necesitada.

Con respecto a la heterogeneidad entre departamentos, se observa que el efecto varía considerablemente, por ejemplo, en la mañana en el departamento 7 el impacto en las transacciones de incorporar un vendedor más es de un aumento del 1 %, en cambio en el departamento 9 incorporar un vendedor más implica un incremento en un 38 %. En la jornada de la tarde, el departamento 14 incrementa sus transacciones en un 4.7 % al aumentar en un vendedor y el departamento 3 aumenta sus ventas en un 47 %. Por lo tanto los vendedores tienen un efecto distinto a lo largo de la tienda y en distintas jornadas, debido a esto, una decisión importante y no trivial es la ubicación que deben tener los vendedores a lo largo del día. Es importante

destacar que el parámetro asociado al número de vendedores, aunque varía de departamento en departamento, es siempre mayor o igual a 0. En esta misma línea, se descubrió que existe un efecto de saturación, es decir, aumentar de 0 a 1 vendedores tiene un efecto mayor que incrementar de 3 a 4 vendedores, este estudio indica que, por ejemplo, para el departamento 3 en la tarde (departamento con el mayor impacto de los vendedores) el aumentar a 8 a 9 vendedores pasa a tener un impacto negativo en las transacciones.

Se comprueba que el número de vendedores presenta problemas de endogeneidad, ya que, al utilizar la función de control como método para solucionar este problema se muestra que el parámetro asociada a la función de control (ρ) es negativo y estadísticamente significativo, si no se corrige este problema el efecto asociado a los vendedores se subestimaría. Por otro lado, se esperaba que el efecto de la cantidad de clientes que están presentes en los departamentos tuvieran un efecto no lineal en las transacciones, sin embargo, se encontró que este efecto es lineal.

Al obtener estos resultados del análisis econométrico, se dispone de manera empírica del efecto de una gran cantidad de variables que explican la variación en las transacciones que ocurren en la tienda, por esta razón se considera apropiado estudiar el impacto que tendría una asignación eficiente de la fuerza de ventas en tiempo real. Para lograr esto, en primer lugar se desarrolló una heurística que decide la ubicación de los vendedores cada 30 minutos, teniendo en consideración la cantidad de clientes que hay en cada departamento, la dotación de empleados disponibles y todas las demás variables de control utilizadas en el análisis econométrico. Esta heurística se considera del tipo "*greedy*" y busca la maximización de las transacciones.

Finalmente, utilizando la heurística antes mencionada y a través de herramientas de simulación, se estimó el valor de incorporar vendedores que sean capaces de atender en más de un departamento, es decir, invertir en la capacitación de la fuerza de venta de tal forma que adquieran los conocimientos suficientes para poder brindar una buena asistencia a los clientes en distintos departamentos. Aumentar la capacidad de lo empleados de atender en más de un departamento permite al tomador de decisiones tener mayor flexibilidad al momento de ubicar la fuerza de venta a lo largo de la tienda. Los resultados de la simulación indican que las transacciones pueden aumentar de manera significativa al aumentar la flexibilidad, considerando como caso base el escenario donde los vendedores sólo pueden atender a un departamento, las transacciones aumentan en un 2,02 % y 6,6 % si los vendedores pudieran atender en dos departamentos y tres departamentos respectivamente, llegando a aumentar en un 11,4 % si los vendedores fueran capaces de atender en todos los departamentos de la tienda. Estos resultados indican que la inversión en la capacitación de los vendedores es recomendable, considerando el uso de la heurística detallada en la sección 4.1.

Para complementar este trabajo, la estimación econométrica se puede perfeccionar incorporando variables que son relevantes al momento de estimar el número de transacciones que ocurren, como por ejemplo el precio de los productos u ofertas a nivel de departamento o tienda. Por otro lado, se aconseja testear si otro modelo de conteo es capaz de estimar de mejor manera el número de transacciones, por ejemplo un modelo *Binomial Negativo* que brinda mayor flexibilidad que el modelo de *Poisson* al permitir que la varianza de las transacciones sea mayor a la esperanza de ellas. Por otro lado, el proceso de asignación de vendedores puede

ser mejorado de distintas maneras. Una de ellas es mejorar la heurística, ya que esta es en cierto sentido miope, por ejemplo, la heurística comienza con todos los departamentos sin vendedores y se fija en el incremento marginal de las transacciones por agregar un vendedor, es decir, pasar de 0 a 1 vendedor, dado que el efecto de los vendedores no es lineal este algoritmo puede ignorar soluciones en las que en un departamento pasar de 0 a 1 vendedores no influye en las transacciones, pero pasar de 3 a 4 vendedores si tenga un impacto considerable, entonces por la naturaleza del algoritmo a este departamento jamás se le asignará un vendedor siendo por esta razón imposible encontrar la solución en que se le asignen 4 vendedores. También es posible incorporar mayor eficiencia en la creación de los conjuntos de departamentos, donde los vendedores son asignados a un grupo y estos pueden atender a las personas dentro de los departamentos pertenecientes al grupo y no en los demás, utilizando cadenas largas cerradas (Jordan y Graves 1995[2]) para lograr asignar a los vendedores polifuncionales a cada departamento de forma de minimizar los costos de sobredotación y subdotación del personal, en otras palabras, las cadenas largas cerradas permiten una flexibilidad suficiente para responder a la variabilidad de la demanda entre departamentos, minimizando el costo de la capacitación de los vendedores.

Bibliografía

- [1] Tomohiro Ando. *Bayesian model selection and statistical modeling*. CRC Press, 2010.
- [2] William C Jordan and Stephen C Graves. Principles on the benefits of manufacturing process flexibility. *Management Science*, 41(4):577–594, 1995.
- [3] Saravanan Kesavan, Vinayak Deshpande, and Hyun Seok Lee. Increasing sales by managing congestion in self-service environments: Evidence from a field experiment. *Available at SSRN 2523680*, 2014.
- [4] Vidya Mani, Saravanan Kesavan, and Jayashankar M Swaminathan. Estimating the impact of understaffing on sales and profitability in retail stores. *Production and Operations Management*, 24(2):201–218, 2015.
- [5] Andrés Musalem, Marcelo Olivares, and Ariel Schilkrut. Retail in high definition: Monitoring customer assistance through video analytics. 2016.
- [6] Serguei Netessine, Marshall Fisher, and Jayanth Krishnan. Labor planning, execution, and retail store performance: An exploratory investigation. *Execution, and Retail Store Performance: An Exploratory Investigation (January 3, 2010)*, 2010.
- [7] Olga Perdikaki, Saravanan Kesavan, and Jayashankar M Swaminathan. Effect of traffic on sales and conversion rates of retail stores. *Manufacturing & Service Operations Management*, 14(1):145–162, 2012.
- [8] Fabio Pinna and Stephan Seiler. Consumer search: Evidence from path-tracking data. 2014.
- [9] P. E. Rossi, G. M. Allenby, and R. McCulloch. *Bayesian Statistics and Marketing*. 2005.
- [10] Zeynep Ton. The effect of labor on profitability: The role of quality. *Harvard Business School Technology & Operations Mgt. Unit Research Paper*, (09-040), 2009.
- [11] Jeff Wooldridge. What's new in econometrics? lecture 6: Control functions and related methods, 2007.

Apéndice A

Descripción de los datos

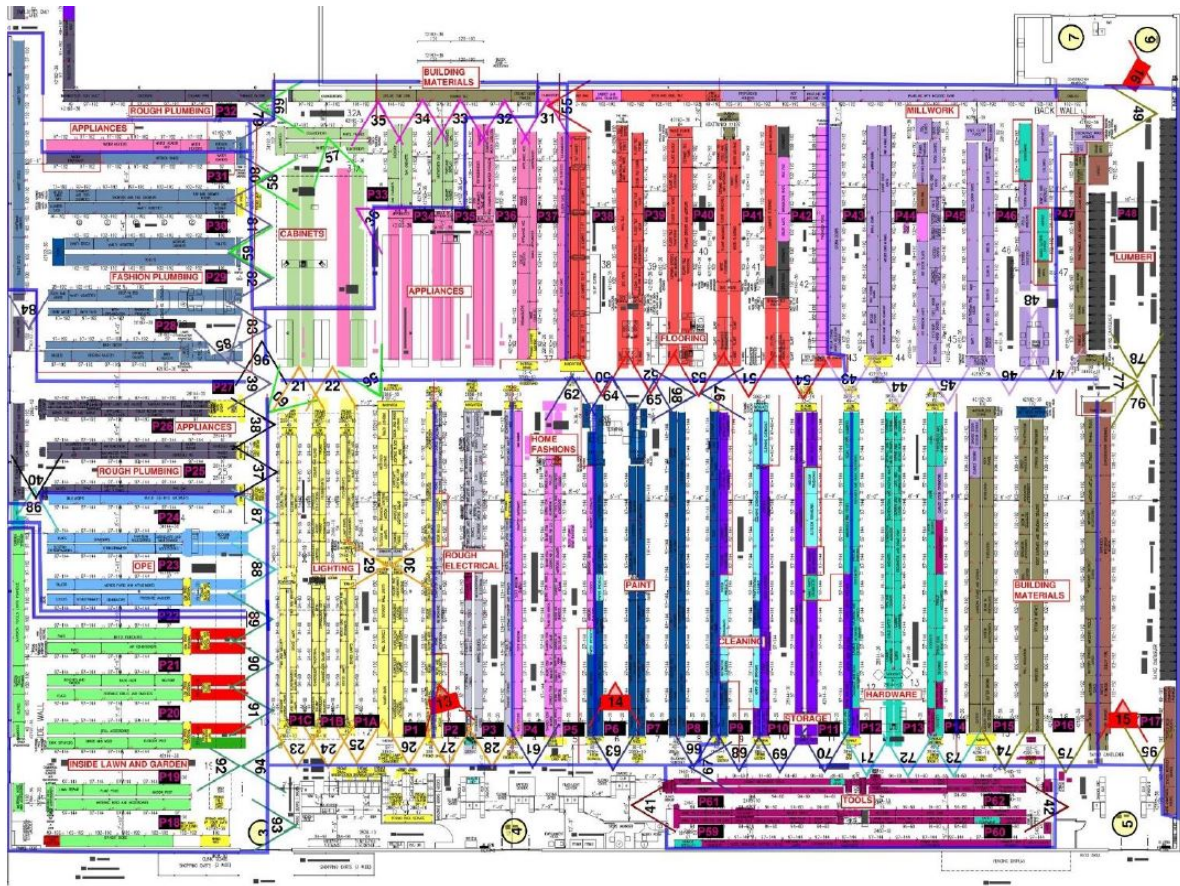


Figura A.1: Plano de la tienda, cada color representa a un departamento.

Apéndice B

Estimación

B.1. Resultado modelos

B.1.1. Modelo 1

Tabla B.1: Resultados *modelo 1*

Variable	Media posteriori	desv. est.
CL_1	0	0
CL_2	0,09509*	0,009714
CL_3	0,1671*	0,009281
CL_4	0,2561*	0,01003
<i>Intercept1</i>	-2,627*	0,4048
sales	0,1267*	0,0269
Control Function		
ρ	-0,1192*	0,02724
<i>Intercept2</i>	-0,3064	0,3755
<i>scheduled</i>	0,02172*	0,009438
<i>actual_hour</i>	0,1493*	0,009554

Significance levels : * : 5%

B.1.2. Modelo 2

Tabla B.2: Resultados *modelo 2*

Variable	Media posteriori	desv, est	Variable	Media posteriori	desv, est
CL_1	0	0	Control Function		
CL_2	0,09654*	0,009214	ρ	-0,1206*	0,0292
CL_3	0,1687*	0,009644	<i>Intercept2</i>	2,26*	0,7363
CL_4	0,2575*	0,00988	<i>scheduled</i>	0,02156*	0,009148
<i>Intercept1</i>	-0,9317*	0,603	<i>actual_hour</i>	0,1491*	0,009669
sales[1]	0,1358*	0,03867	Hiper-prior		
sales[2]	0,1439*	0,0377	$V_{\bar{\gamma}}$	0,02938*	0,01425
sales[3]	0,1472*	0,03552	$\bar{\gamma}$	0,1269*	0,03059
sales[4]	0,1012*	0,03899			
sales[5]	0,137*	0,03378			
sales[6]	0,1349*	0,03095			
sales[7]	0,12*	0,04366			
sales[8]	0,1429*	0,03435			
sales[9]	0,1337*	0,03771			
sales[10]	0,1422*	0,03052			
sales[11]	0,1231*	0,02912			
sales[12]	0,1101*	0,03871			
sales[13]	0,1224*	0,03147			
sales[14]	0,08037*	0,03743			

Significance levels : * : 5 %

B.1.3. Modelo 3

Tabla B.3: Resultados *modelo 3*

Variable	Media posteriori	desv, est	Variable	Media posteriori	desv, est
CL_1	0*	0	sales[1,M]	0,09351	0,0555
CL_2	0,09506*	0,009711	sales[1,T]	0,1743*	0,04583
CL_3	0,1675*	0,009626	sales[2,M]	0,3193*	0,06354
CL_4	0,2549*	0,009637	sales[2,T]	0,1027*	0,05029
<i>Intercept1</i>	-3,225*	0,4358	sales[3,M]	0,00827	0,05171
	Control Function		sales[3,T]	0,2105*	0,03772
ρ	-0,1365*	0,02758	sales[4,M]	0,05557	0,05589
<i>Intercept2</i>	2,918*	0,5972	sales[4,T]	0,1151*	0,0443
<i>scheduled</i>	0,02254*	0,009376	sales[5,M]	0,1556*	0,03871
<i>actual_hour</i>	0,1488*	0,009888	sales[5,T]	0,155*	0,03589
	Hiper-prior		sales[6,M]	0,1519*	0,02934
$V_{\bar{\gamma}_M}$	0,1245*	0,03808	sales[6,T]	0,1537*	0,03082
$V_{\bar{\gamma}_T}$	0,05257*	0,01755	sales[7,M]	-0,03292	0,1236
$\bar{\gamma}_M$	0,1259*	0,04362	sales[7,T]	0,1624*	0,0632
$\bar{\gamma}_T$	0,1392*	0,03355	sales[8,M]	0,273*	0,03824
			sales[8,T]	0,1042*	0,03674
			sales[9,M]	0,2358*	0,04851
			sales[9,T]	0,09993*	0,04642
			sales[10,M]	0,1496*	0,03001
			sales[10,T]	0,1693*	0,03042
			sales[11,M]	0,1486*	0,0286
			sales[11,T]	0,1303*	0,02842
			sales[12,M]	0,00009261	0,06576
			sales[12,T]	0,152*	0,0474
			sales[13,M]	0,09872*	0,03165
			sales[13,T]	0,1653*	0,03159
			sales[14,M]	0,09665*	0,03811
			sales[14,T]	0,06712	0,0389

Significance levels : * : 5 %

B.1.4. Modelo 4

Tabla B.4: Resultados *modelo 4*

Variable	Media posteriori	desv, est	Variable	Media posteriori	desv, est
CL_1	0*	0	sales[1,M]	0,1277*	0,06064
CL_2	0,09963*	0,009082	sales[1,T]	0,208*	0,0482
CL_3	0,1801*	0,01052	sales[2,M]	0,3514*	0,0655
CL_4	0,2798*	0,01206	sales[2,T]	0,1318*	0,04931
$CL \times S$	-0,01221*	0,003507	sales[3,M]	0,04553	0,05282
<i>Intercept1</i>	-2,024*	0,6317	sales[3,T]	0,2403*	0,04004
	Control Function		sales[4,M]	0,08591	0,05943
ρ	-0,1348*	0,02939	sales[4,T]	0,1497*	0,04461
<i>Intercept2</i>	-0,7479*	0,2892	sales[5,M]	0,1912*	0,04249
<i>scheduled</i>	0,02158*	0,009778	sales[5,T]	0,1938*	0,03846
<i>actual_hour</i>	0,1497*	0,009379	sales[6,M]	0,1855*	0,03334
	Hiper-prior		sales[6,T]	0,1863*	0,03364
$V_{\bar{\gamma}_M}$	0,1219*	0,03751	sales[7,M]	0,002269	0,1302
$V_{\bar{\gamma}_T}$	0,05279*	0,01678	sales[7,T]	0,1898*	0,06194
$\bar{\gamma}_M$	0,1569*	0,04999	sales[8,M]	0,306*	0,04221
$\bar{\gamma}_T$	0,1719*	0,03489	sales[8,T]	0,1319*	0,03949
			sales[9,M]	0,2663*	0,05316
			sales[9,T]	0,1317*	0,0487
			sales[10,M]	0,183*	0,03406
			sales[10,T]	0,1993*	0,03246
			sales[11,M]	0,1871*	0,03228
			sales[11,T]	0,1664*	0,03106
			sales[12,M]	0,02976	0,06974
			sales[12,T]	0,1819*	0,04993
			sales[13,M]	0,132*	0,0354
			sales[13,T]	0,197*	0,03439
			sales[14,M]	0,1246*	0,04456
			sales[14,T]	0,09444*	0,03998

Significance levels : * : 5 %

B.1.5. Modelo 5

Tabla B.5: Resultados *modelo 5*

Variable	Media posteriori	desv, est	Variable	Media posteriori	desv, est
CL_1	0*	0	sales[1,M]	0,07938	0,07749
CL_2	0,1008*	0,009377	sales[1,T]	0,1654*	0,06697
CL_3	0,18*	0,01058	sales[2,M]	0,3228*	0,08383
CL_4	0,2764*	0,01305	sales[2,T]	0,08193	0,07348
$CL \times S_1$	0,01329	0,018	sales[3,M]	0,1405*	0,05814
$CL \times S_2$	0,001037	0,01992	sales[3,T]	0,3319*	0,04529
$CL \times S_3$	-0,05572*	0,01442	sales[4,M]	0,1016	0,07074
$CL \times S_4$	-0,01967	0,0172	sales[4,T]	0,1522*	0,06179
$CL \times S_5$	-0,003306	0,01115	sales[5,M]	0,1677*	0,05185
$CL \times S_6$	0,0105	0,007426	sales[5,T]	0,1701*	0,0502
$CL \times S_7$	-0,01667	0,02421	sales[6,M]	0,115*	0,03912
$CL \times S_8$	-0,01328	0,01289	sales[6,T]	0,1167*	0,03848
$CL \times S_9$	-0,03243*	0,01768	sales[7,M]	0,003873	0,1378
$CL \times S_{10}$	0,01624*	0,007983	sales[7,T]	0,2217*	0,08946
$CL \times S_{11}$	-0,01728*	0,004018	sales[8,M]	0,3105*	0,05763
$CL \times S_{12}$	-0,02033	0,01881	sales[8,T]	0,126*	0,04994
$CL \times S_{13}$	-0,04019*	0,00959	sales[9,M]	0,3129*	0,06888
$CL \times S_{14}$	-0,00183	0,01505	sales[9,T]	0,1495*	0,06729
<i>Intercept1</i>	0,06294	0,4197	sales[10,M]	0,09529*	0,04159
	Control Function		sales[10,T]	0,1172*	0,03981
ρ	-0,1349*	0,02943	sales[11,M]	0,2067*	0,03292
<i>Intercept2</i>	0,3544	0,5054	sales[11,T]	0,1841*	0,03163
<i>scheduled</i>	0,02206*	0,009712	sales[12,M]	0,05553	0,08668
<i>actual_hour</i>	0,1494*	0,009931	sales[12,T]	0,1982*	0,06849
	Hiper-prior		sales[13,M]	0,2155*	0,04587
$V_{\bar{\gamma}_M}$	0,1284*	0,04327	sales[13,T]	0,2841*	0,04615
$V_{\bar{\gamma}_T}$	0,09952*	0,02803	sales[14,M]	0,08824	0,06531
$V_{\bar{\kappa}}$	0,02764*	0,007941	sales[14,T]	0,04666	0,05985
$\bar{\gamma}_M$	0,1562*	0,05131			
$\bar{\gamma}_T$	0,1658*	0,04477			
$\bar{\kappa}$	-0,01243	0,009585			

Significance levels : * : 5 %

B.1.6. Modelo 6

Tabla B.6: Resultados *modelo 6*

Variable	Media posteriori	desv, est	Variable	Media posteriori	desv, est
CL_1	0*	0	sales[1,M]	0,08804	0,07724
CL_2	0,09973*	0,009592	sales[1,T]	0,1745*	0,06625
CL_3	0,1779*	0,01031	sales[2,M]	0,3251*	0,08799
CL_4	0,2733*	0,01362	sales[2,T]	0,07625	0,08132
$CL \times S_1$	0,01537	0,01722	sales[3,M]	0,1808*	0,06457
$CL \times S_2$	0,004397	0,02229	sales[3,T]	0,3876*	0,0571
$CL \times S_3$	-0,06405*	0,01593	sales[4,M]	0,118	0,07337
$CL \times S_4$	-0,02026	0,01787	sales[4,T]	0,1743*	0,06843
$CL \times S_5$	-0,00187	0,01244	sales[5,M]	0,1777*	0,05577
$CL \times S_6$	0,01161	0,007779	sales[5,T]	0,1799*	0,05578
$CL \times S_7$	-0,0171	0,02568	sales[6,M]	0,1235*	0,03885
$CL \times S_8$	-0,01193	0,01329	sales[6,T]	0,1243*	0,03793
$CL \times S_9$	-0,0341*	0,01864	sales[7,M]	0,01019	0,1371
$CL \times S_{10}$	0,01735*	0,008257	sales[7,T]	0,2399*	0,1017
$CL \times S_{11}$	-0,01639*	0,004044	sales[8,M]	0,3159*	0,05581
$CL \times S_{12}$	-0,02274	0,0197	sales[8,T]	0,1304*	0,04852
$CL \times S_{13}$	-0,04077*	0,01024	sales[9,M]	0,3268*	0,07207
$CL \times S_{14}$	0,0005004	0,01578	sales[9,T]	0,1662*	0,06831
<i>Intercept1</i>	-2,908*	0,2915	sales[10,M]	0,1056*	0,04074
	Control Function:		sales[10,T]	0,1262*	0,04022
ρ	-0,1349*	0,02834	sales[11,M]	0,2291*	0,03555
<i>Intercept2</i>	-0,2225	0,4827	sales[11,T]	0,2054*	0,03455
<i>scheduled</i>	0,02169*	0,009338	sales[12,M]	0,07123	0,08372
<i>actual_hour</i>	0,1499*	0,009466	sales[12,T]	0,2198*	0,07167
	Hiper-prior		sales[13,M]	0,2267*	0,04388
$V_{\bar{\gamma}_M}$	0,1293*	0,0448	sales[13,T]	0,2973*	0,04392
$V_{\bar{\gamma}_T}$	0,1146*	0,03622	sales[14,M]	0,08827	0,06218
$V_{\bar{\kappa}}$	0,03033*	0,008905	sales[14,T]	0,04627	0,05975
$\bar{\gamma}_M$	0,1697*	0,0529	sales2	-0,005013	0,00307
$\bar{\gamma}_T$	0,1832*	0,04824			
$\bar{\kappa}$	-0,01279	0,01064			

Significance levels : * : 5 %

B.1.7. Modelo 7

Tabla B.7: Resultados *modelo 7*

Variable	Media posteriori	desv, est	Variable	Media posteriori	desv, est
CL_1	0*	0	sales[10,T]	0,1569*	0,04497
CL_2	0,09957*	0,008989	sales[11,M]	0,2229*	0,03933
CL_3	0,177*	0,01047	sales[11,T]	0,1998*	0,03805
CL_4	0,2721*	0,01287	sales[12,M]	0,07267	0,0839
$CL \times S_1$	0,01526	0,01874	sales[12,T]	0,2211*	0,06986
$CL \times S_2$	0,006627	0,02235	sales[13,M]	0,2292*	0,04919
$CL \times S_3$	-0,0602*	0,0161	sales[13,T]	0,2984*	0,0491
$CL \times S_4$	-0,016	0,01777	sales[14,M]	0,09751	0,06193
$CL \times S_5$	-0,0004971	0,01107	sales[14,T]	0,05556	0,06011
$CL \times S_6$	0,01123	0,007285	sales2[1]	-0,005641	0,01422
$CL \times S_7$	-0,01601	0,02491	sales2[2]	-0,01712	0,02021
$CL \times S_8$	-0,0131	0,01326	sales2[3]	-0,001894	0,005031
$CL \times S_9$	-0,03269	0,01786	sales2[4]	-0,01901	0,01379
$CL \times S_{10}$	0,01941*	0,008428	sales2[5]	-0,008462	0,01012
$CL \times S_{11}$	-0,01633*	0,004176	sales2[6]	0,003456	0,01094
$CL \times S_{12}$	-0,02076	0,01915	sales2[7]	-0,01039	0,01792
$CL \times S_{13}$	-0,03991*	0,01046	sales2[8]	0,003219	0,01389
$CL \times S_{14}$	0,00006106	0,01522	sales2[9]	-0,003557	0,01571
<i>Intercept1</i>	-1,952*	0,2264	sales2[10]	-0,01892*	0,01004
sales[1,M]	0,09604	0,0763	sales2[11]	-0,003267	0,004485
sales[1,T]	0,1804*	0,06894	sales2[12]	-0,007287	0,01644
sales[2,M]	0,3307*	0,08827	sales2[13]	-0,00528	0,009768
sales[2,T]	0,07921	0,08178	sales2[14]	-0,008982	0,01545
sales[3,M]	0,1636*	0,07163		Control Function:	
sales[3,T]	0,3594*	0,07057	ρ	-0,1378*	0,03008
sales[4,M]	0,1412	0,07427	<i>Intercept2</i>	0,5728	0,4086
sales[4,T]	0,2014*	0,07083	<i>scheduled</i>	0,02135*	0,00939
sales[5,M]	0,191*	0,05745	<i>actual_hour</i>	0,1491*	0,009222
sales[5,T]	0,1926*	0,05578		Hiper-prior	
sales[6,M]	0,1092*	0,04683	$V_{\bar{\gamma}_M}$	0,1251*	0,04073
sales[6,T]	0,1108*	0,04602	$V_{\bar{\gamma}_T}$	0,1079*	0,03346
sales[7,M]	0,01642	0,138	$V_{\bar{\kappa}}$	0,02964*	0,008563
sales[7,T]	0,2445*	0,1016	$V_{\bar{\pi}}$	0,01405*	0,0089
sales[8,M]	0,3049*	0,06254	$\bar{\gamma}_M$	0,1743*	0,05137
sales[8,T]	0,1227*	0,05439	$\bar{\gamma}_T$	0,1825*	0,04548
sales[9,M]	0,3228*	0,07048	$\bar{\kappa}$	-0,012	0,01066
sales[9,T]	0,1661*	0,06826	$\bar{\pi}$	-0,007475	0,007216
sales[10,M]	0,1413*	0,04745			

Significance levels : * : 5 %

B.1.8. Modelo 8

Tabla B.8: Resultados *modelo 8*

Variable	Media posteriori	desv, est	Variable	Media posteriori	desv, est
CL_1	0*	0	sales[1,M]	0,1356*	0,05892
CL_2	0,09981*	0,009086	sales[1,T]	0,2104*	0,04903
CL_3	0,1797*	0,009893	sales[2,M]	0,3592*	0,06586
CL_4	0,2801*	0,01206	sales[2,T]	0,1313*	0,0484
$CL \times S$	-0,01232*	0,003547	sales[3,M]	0,04773	0,05095
sales2	-0,0009779	0,002871	sales[3,T]	0,2469*	0,04234
<i>Intercept1</i>	-1,864*	0,2339	sales[4,M]	0,09698	0,05903
	Control Function:		sales[4,T]	0,1514*	0,04529
ρ	-0,1366*	0,02921	sales[5,M]	0,196*	0,04358
<i>Intercept2</i>	2,559*	1,179	sales[5,T]	0,1973*	0,03946
<i>scheduled</i>	0,02227*	0,009512	sales[6,M]	0,1912*	0,03385
<i>actual_hour</i>	0,1491*	0,009461	sales[6,T]	0,1905*	0,03367
	Hiper-prior		sales[7,M]	0,007487	0,1265
$V_{\bar{\gamma}_M}$	0,1239*	0,03971	sales[7,T]	0,1973*	0,06421
$V_{\bar{\gamma}_T}$	0,05585*	0,01862	sales[8,M]	0,31*	0,04187
$\bar{\gamma}_M$	0,1655*	0,04847	sales[8,T]	0,135*	0,03851
$\bar{\gamma}_T$	0,1753*	0,03521	sales[9,M]	0,271*	0,05129
			sales[9,T]	0,1328*	0,04708
			sales[10,M]	0,1878*	0,0339
			sales[10,T]	0,2042*	0,03289
			sales[11,M]	0,1945*	0,03351
			sales[11,T]	0,1733*	0,0321
			sales[12,M]	0,03866	0,06704
			sales[12,T]	0,1874*	0,04783
			sales[13,M]	0,1364*	0,03467
			sales[13,T]	0,2016*	0,03375
			sales[14,M]	0,1272*	0,0401
			sales[14,T]	0,09497*	0,03938

Significance levels : * : 5 %

B.1.9. Modelo 9

Tabla B.9: Resultados *modelo 9*

Variable	Media posteriori	desv, est	Variable	Media posteriori	desv, est
CL_1	0*	0	sales[3, T, F]	0,3115*	0,06762
CL_2	0,1003*	0,00951	sales[4, M, S]	0,1472*	0,0671
CL_3	0,1803*	0,0105	sales[4, M, F]	0,1409	0,08819
CL_4	0,2761*	0,01283	sales[4, T, S]	0,1954*	0,05405
$CL \times S_1$	0,007218	0,01441	sales[4, T, F]	0,1353	0,08465
$CL \times S_2$	0,001901	0,01782	sales[5, M, S]	0,1934*	0,04992
$CL \times S_3$	-0,05035*	0,0137	sales[5, M, F]	0,1416*	0,06181
$CL \times S_4$	-0,02669	0,0143	sales[5, T, S]	0,1914*	0,04737
$CL \times S_5$	-0,003022	0,0108	sales[5, T, F]	0,1681*	0,05666
$CL \times S_6$	0,004837	0,007573	sales[6, M, S]	0,1249*	0,03823
$CL \times S_7$	-0,01853	0,02209	sales[6, M, F]	0,1842*	0,04196
$CL \times S_8$	-0,009277	0,01222	sales[6, T, S]	0,1334*	0,03702
$CL \times S_9$	-0,02509	0,01461	sales[6, T, F]	0,1683*	0,04275
$CL \times S_{10}$	0,01007	0,007403	sales[7, M, S]	0,04611	0,125
$CL \times S_{11}$	-0,015*	0,003995	sales[7, M, F]	0,1811	0,107
$CL \times S_{12}$	-0,02552	0,01655	sales[7, T, S]	0,1919*	0,07703
$CL \times S_{13}$	-0,04193*	0,01062	sales[7, T, F]	0,2921*	0,1289
$CL \times S_{14}$	-0,008102	0,01311	sales[8, M, S]	0,2707*	0,05756
<i>Intercept1</i>	-2,226*	0,5665	sales[8, M, F]	0,3463*	0,07387
	Control Function:		sales[8, T, S]	0,1196*	0,04681
ρ	-0,1459*	0,02769	sales[8, T, F]	0,1558*	0,05886
<i>Intercept2</i>	0,6391	0,634	sales[9, M, S]	0,2987*	0,06255
<i>scheduled</i>	0,0229*	0,009387	sales[9, M, F]	0,2453*	0,07465
<i>actual_hour</i>	0,1486*	0,009654	sales[9, T, S]	0,1935*	0,05986
	Hiper-prior		sales[9, T, F]	0,06618	0,08569
$V_{\bar{\gamma}_{MS}}$	0,1124*	0,04109	sales[10, M, S]	0,1169*	0,03777
$V_{\bar{\gamma}_{MF}}$	0,09579*	0,03887	sales[10, M, F]	0,1655*	0,0454
$V_{\bar{\gamma}_{TS}}$	0,08204*	0,02609	sales[10, T, S]	0,1397*	0,0369
$V_{\bar{\gamma}_{TF}}$	0,123*	0,03776	sales[10, T, F]	0,1679*	0,04353
$V_{\bar{\kappa}}$	0,02466*	0,007747	sales[11, M, S]	0,2107*	0,03102
$\bar{\gamma}_{MS}$	0,1642*	0,04443	sales[11, M, F]	0,2117*	0,03165
$\bar{\gamma}_{MF}$	0,2033*	0,04572	sales[11, T, S]	0,2029*	0,03024
$\bar{\gamma}_{TS}$	0,189*	0,04083	sales[11, T, F]	0,1677*	0,03134
$\bar{\gamma}_{TF}$	0,1758*	0,05025	sales[12, M, S]	0,03155	0,0864
$\bar{\kappa}$	-0,01461	0,009097	sales[12, M, F]	0,2031*	0,08038
sales[1, M, S]	0,09248	0,06986	sales[12, T, S]	0,221*	0,06235
sales[1, M, F]	0,1711*	0,07419	sales[12, T, F]	0,1997*	0,08738
sales[1, T, S]	0,2315*	0,05652	sales[13, M, S]	0,2037*	0,04449
sales[1, T, F]	0,1272	0,07315	sales[13, M, F]	0,2817*	0,05334
sales[2, M, S]	0,3017*	0,07753	sales[13, T, S]	0,2536*	0,04518
sales[2, M, F]	0,2744*	0,1033	sales[13, T, F]	0,3831*	0,05062
sales[2, T, S]	0,1159	0,06753	sales[14, M, S]	0,1122	0,05542
sales[2, T, F]	0,0896	0,0961	sales[14, M, F]	0,1627*	0,0615
sales[3, M, S]	0,1466*	0,05881	sales[14, T, S]	0,1199*	0,05156
sales[3, M, F]	0,144	0,07705	sales[14, T, F]	0,05348	0,0613
sales[3, T, S]	0,33*	0,04535			

Significance levels : * : 5%

B.2. Convergencia




Figura B.1: trace-plot CL_2




Figura B.2: trace-plot CL_3




Figura B.3: trace-plot CL_4




Figura B.4: trace-plot $CL \times S_1$




Figura B.5: trace-plot $CL \times S_2$




Figura B.6: trace-plot $CL \times S_3$




Figura B.7: trace-plot $CL \times S_4$




Figura B.8: trace-plot $CL \times S_5$




Figura B.9: trace-plot $CL \times S_6$




Figura B.10: trace-plot $CL \times S_7$




Figura B.11: trace-plot $CL \times S_8$




Figura B.12: trace-plot $CL \times S_9$




Figura B.13: trace-plot $CL \times S_{10}$




Figura B.14: trace-plot $CL \times S_{11}$




Figura B.15: trace-plot $CL \times S_{12}$




Figura B.16: trace-plot $CL \times S_{13}$




Figura B.17: trace-plot $CL \times S_{14}$




Figura B.18: trace-plot Intercept1




Figura B.19: trace-plot ρ




Figura B.20: trace-plot *Intercept2*




Figura B.21: trace-plot *scheduled*




Figura B.22: trace-plot *actual_hour*




Figura B.23: trace-plot $V_{\gamma M}$




Figura B.24: trace-plot $V_{\gamma T}$




Figura B.25: trace-plot $V_{\bar{\kappa}}$




Figura B.26: trace-plot $\bar{\gamma}_M$




Figura B.27: trace-plot $\bar{\gamma}_T$




Figura B.28: trace-plot $\bar{\kappa}$




Figura B.29: trace-plot $sales[1, M]$




Figura B.30: trace-plot $sales[1, T]$




Figura B.31: trace-plot $sales[2, M]$




Figura B.32: trace-plot $sales[2, T]$




Figura B.33: trace-plot $sales[3, M]$




Figura B.34: trace-plot $sales[3, T]$




Figura B.35: trace-plot $sales[4, M]$




Figura B.36: trace-plot $sales[4, T]$




Figura B.37: trace-plot $sales[5, M]$




Figura B.38: trace-plot $sales[5, T]$




Figura B.39: trace-plot $sales[6, M]$




Figura B.40: trace-plot $sales[6, T]$




Figura B.41: trace-plot $sales[7, M]$




Figura B.42: trace-plot $sales[7, T]$




Figura B.43: trace-plot $sales[8, M]$




Figura B.44: trace-plot $sales[8, T]$




Figura B.45: trace-plot $sales[9, M]$




Figura B.46: trace-plot $sales[9, T]$




Figura B.47: trace-plot $sales[10, M]$




Figura B.48: trace-plot $sales[10, T]$




Figura B.49: trace-plot $sales[11, M]$




Figura B.50: trace-plot $sales[11, T]$




Figura B.51: trace-plot $sales[12, M]$




Figura B.52: trace-plot $sales[12, T]$




Figura B.53: trace-plot $sales[13, M]$




Figura B.54: trace-plot $sales[13, T]$




Figura B.55: trace-plot $sales[14, M]$




Figura B.56: trace-plot $sales[14, T]$




Figura B.57: trace-plot $sales^2$

Apéndice C

Simulación

C.1. Distribución de la tienda según N_{grupos}

C.1.1. $N_{grupos} = 14$

Para este caso cada departamentos corresponde a un grupo.

C.1.2. $N_{grupos} = 7$

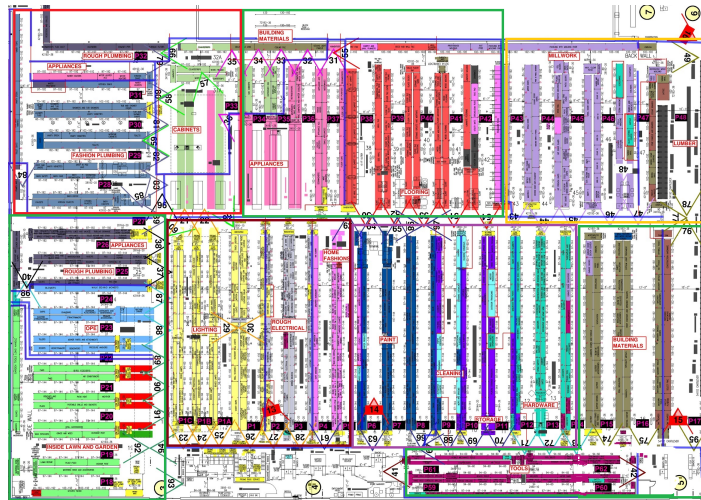


Figura C.1: Definición de grupos para $N_{grupos} = 7$

C.1.3. $N_{grupos} = 6$

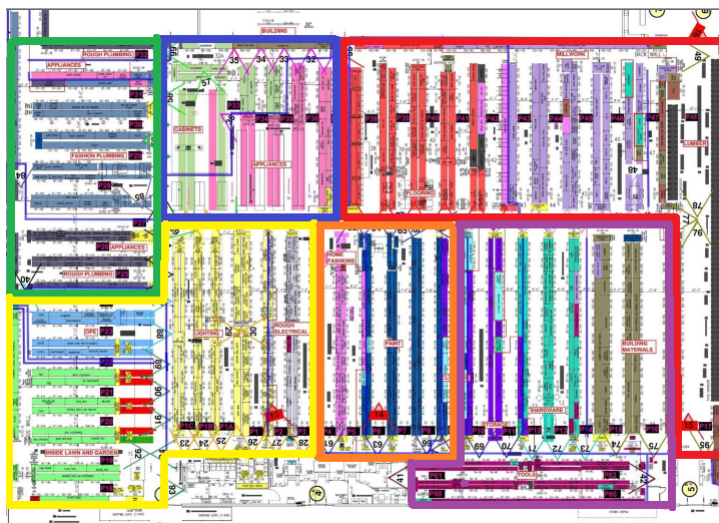


Figura C.2: Definición de grupos para $N_{grupos} = 6$

C.1.4. $N_{grupos} = 5$

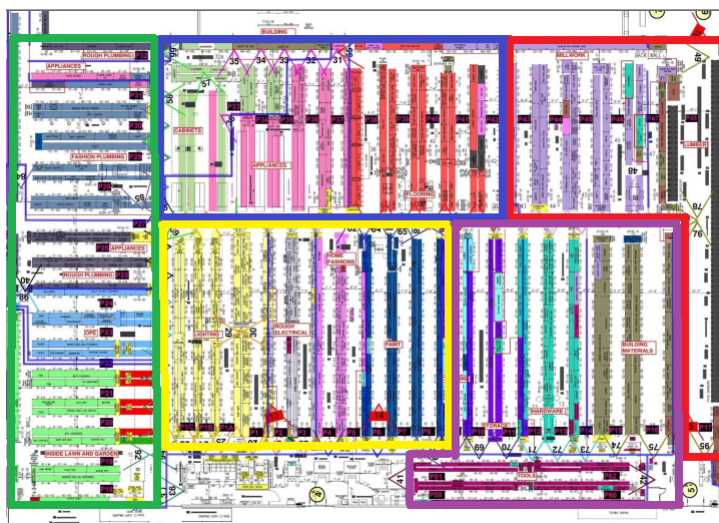


Figura C.3: Definición de grupos para $N_{grupos} = 5$

C.1.5. $N_{grupos} = 3$

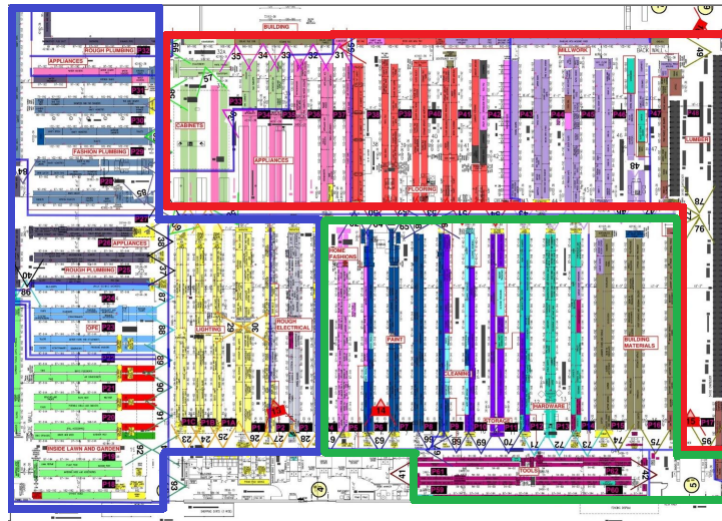


Figura C.4: Definición de grupos para $N_{grupos} = 3$

C.1.6. $N_{grupos} = 2$

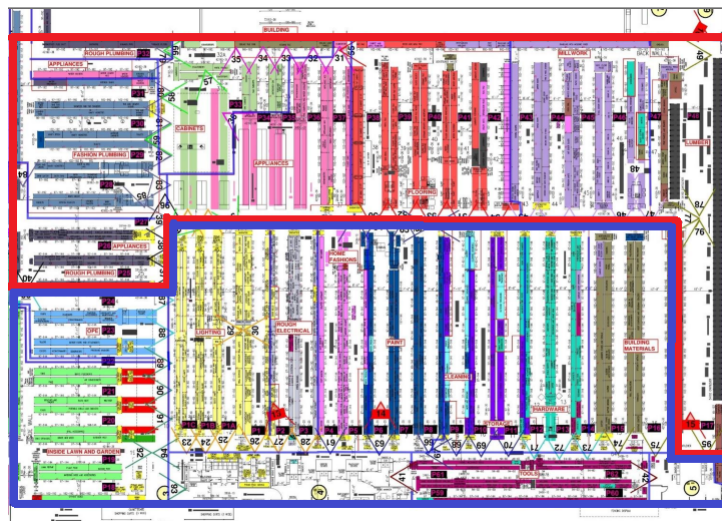


Figura C.5: Definición de grupos para $N_{grupos} = 2$

C.1.7. $N_{grupos} = 1$

En este caso hay un sólo grupo, por lo tanto todos los departamentos de la tienda pertenecen a este grupo.