

Detección de Faltantes de Mercadería en Góndolas de Supermercado utilizando información del punto de venta¹

Juan Sainz, Máximo Bosch, Richard Weber
Departamento de Ingeniería Industrial, Universidad de Chile

Vicente Benito
Rendic Hermanos S.A.

Resumen

La principal causante de faltantes de mercadería en góndolas (FMG) en supermercados es la deficiente calidad de la información almacenada en los sistemas de inventario.

En el presente trabajo se propone un modelo de clasificación que determine si un producto se encuentra en estado de FMG. El modelo no ocupa información de inventario sino básicamente los datos generados por los puntos de venta.

El proyecto consta de un levantamiento de información, pre-procesamiento de datos y pruebas de modelos de redes neuronales Multi-Layer Perceptron. Los resultados indican que es posible detectar eventos de quiebre de stock en góndolas a través de la información transaccional, facilitando de esta forma la detección temprana de productos en estado faltante.

1. Introducción

Un continuo aumento de la cantidad de SKU (*stock keeping units*) en las salas de venta de los supermercados ha traído consigo una mayor propuesta de valor para los clientes, pero también ha generado nuevas problemáticas. Debido a esto, se ha vuelto mucho más latente e importante el problema de los faltantes de mercadería en góndolas (FMG) de supermercados. Un FMG corresponde a un SKU que pertenece al mix de productos de la sala de venta, pero que no se encuentra disponible dentro de ella. Diversos estudios muestran que los FMG generan costos, los cuales están asociados a la pérdida de fidelidad a una marca, costo por venta no realizada e imagen de la cadena de supermercados.

El Primer Estudio Nacional de FMG determinó que el porcentaje de SKU en estado FMG en Chile es del 15% [Universidad de Chile 2004], lo que implica costos directos estimados en 150 millones de dólares al año. El 74.3% de los eventos FMG se producen por desajustes de inventario, es decir, porque los sistemas de información no representan la situación real del supermercado.

En la literatura se definen seis reacciones posibles cuando un comprador se ve enfrentado a un FMG [Campo et al. 2003], estas son: Busca el producto en otra sala el mismo día, Cambia de formato y/o variedad sin cambiar la marca, Aplaza la compra hasta una próxima visita regular al supermercado, Cancela o aplaza la compra por un período largo de tiempo, Compra un sustituto perteneciente a otra categoría de productos o Compra un producto de otra marca perteneciente a la misma categoría de productos.

La reacción de un comprador ante un FMG depende de la naturaleza del producto (Emocional o Funcional) y del valor de marca [Sloot et al. 2002].

¹ Estudio financiado por proyecto FONDEF D03I1057

El objetivo del presente estudio es la formulación de modelos que detecten eventos FMG mediante el análisis de la información transaccional generada en los puntos de venta (POS, por sus siglas en inglés). La idea principal es que cada producto posee patrones de comportamiento característicos cuyo análisis permite detectar un estado FMG. En los próximos capítulos se detalla la metodología y resultados del estudio, así como también posibles futuras líneas de investigación.

2. Planteamiento del problema y justificación

La necesidad de plantear un modelo que sea capaz de detectar productos faltantes mediante la información transaccional proviene de las problemáticas asociadas a la utilización de la información presente en el sistema de inventario de cada sala. La información almacenada en el sistema de inventario corresponde al stock presente en bodega más sala de ventas (agregado).

La medición continua mediante observaciones realizadas por personal de la cadena por un lado es impracticable debido a la alta cantidad de SKU que pertenecen al mix de productos de una sala de ventas de un supermercado. La determinación exacta de la oferta en góndola a través de la tecnología RFID (*radio frequency identification*) por otro lado es todavía demasiado cara y no se provee su aplicación masiva en los próximos 10 años por lo menos. Por lo anterior, se plantea el objetivo de facilitar las labores de detección de faltantes dentro de la sala de ventas mediante la utilización de modelos que consideren la evolución de las ventas, pues puede mejorar el tiempo de respuesta y focalizar de mejor manera el trabajo del personal del supermercado.

3. Información disponible para la construcción de los modelos

3.1 Adquisición de la información

El estudio se realizó en la sala de ventas del Supermercado Deca Balmaceda, ubicado en la ciudad de La Serena, propiedad de la cadena Rendic Hermanos S.A. Posee 18 cajas y 2.500 metros cuadrados.

Se analizaron las siguientes 9 subcategorías con un total de 364 SKUs: Aceite de oliva, Aceite vegetal, Detergente en polvo, Jurel (conserva), Mayonesa, Sal, Salsa de tomate, Servilleta y Sopa.

El período de adquisición de la información es de 35 días consecutivos, comenzando el 13 de Abril de 2005. Cada día posee 12 observaciones (intervalos de una hora) de ventas y estado FMG de los SKU. El estado FMG de los productos, en intervalos de una hora, se registró mediante la revisión continua (12 horas al día) realizada por un grupo de estudiantes universitarios. La información de unidades vendidas, en intervalos de una hora, se realizó mediante reportes generados a través del servidor/controlador de cajas. Los reportes son almacenados en un archivo con formato estándar.

3.2 Caracterización de eventos FMG

Con la información ya mencionada es posible caracterizar los eventos FMG que se experimentan durante el período en estudio.

El porcentaje de SKU en estado FMG varía entre 1.92% y 7.28%, el promedio es igual a 3.7%, mientras que la mediana es 3,4%.

Se aprecian ciertas variaciones en el nivel FMG en función de la hora y día de observación. Sin embargo, la variación del nivel FMG en función de la hora no es significativa. Con respecto al nivel FMG en función del día, se aprecia que los días sábado, domingo y lunes presentan mayores niveles FMG que los demás días de la semana. Esto puede deberse a características específicas de los procedimientos de reposición del supermercado en análisis.

La duración de eventos FMG corresponde al tiempo que un SKU se encuentra en estado FMG. 76 de los 260 eventos FMG (29.2%) poseen una duración mayor a 8 horas. 50.8% de los eventos FMG duran 3 o menos horas en ese estado.

4. Planteamiento de los modelos

Se plantean dos enfoques distintos para desarrollar modelos de detección de FMG, cada uno de ellos cumple con un objetivo particular e importante. El primer enfoque es determinar la capacidad de clasificación del tipo de modelo planteado; cuantificar la capacidad de reacción del modelo ante eventos específicos (duración) de FMG permite entender la efectividad en la clasificación y la relevancia de las variables de entrada propuestas. También, se utiliza este enfoque para realizar la selección de variables. El segundo enfoque es determinar la eficiencia y la eficacia del modelo planteado en la operación normal de la sala de ventas, es decir, cuantificar el impacto inmediato que el modelo tendría si se implementara en la sala de ventas en estudio.

4.1 Selección de variables

La selección de variables de entrada se realiza mediante la cuantificación del aporte que cada grupo de ellas tiene en el poder de clasificación en el modelo planteado. Los grupos de variables son: Ventas del SKU en análisis, Ventas de la subcategoría a la que pertenece el SKU en análisis, Participación histórica del SKU en la subcategoría, Día y Hora del momento en análisis. El modelo planteado obtuvo el mejor rendimiento utilizando todas las variables disponibles.

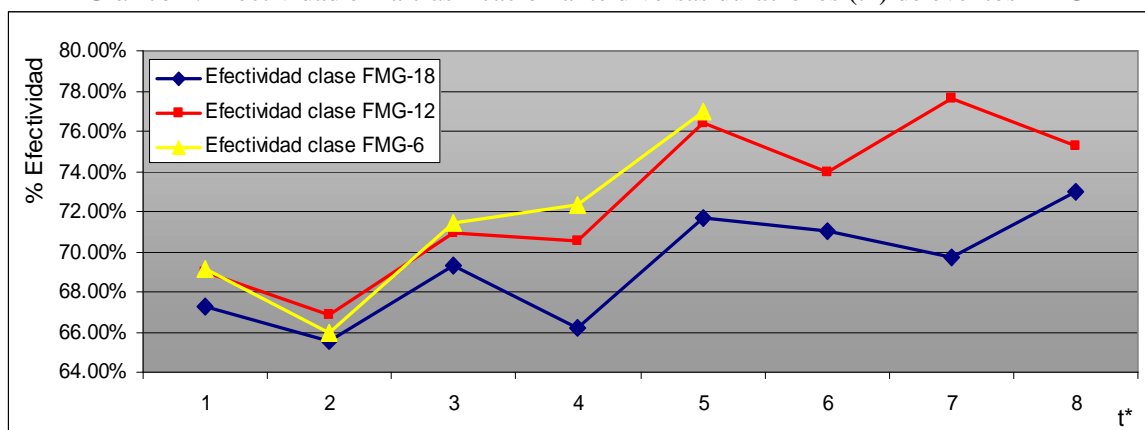
4.2 Modelos de detección de faltantes de mercadería en góndolas

Se propone un modelo de clasificación binaria que asigne un SKU en un momento determinado a una de las clases FMG / No FMG. Para llevar a cabo dicha clasificación, se construyen y prueban modelos de redes neuronales MLP con las siguientes características: Cantidad de neuronas de entrada en función del intervalo de tiempo en observación (T) del SKU y la subcategoría a la que pertenece, una variable asociada a la participación de mercado histórica y variables dummy asociadas al instante de clasificación, es decir $2 \cdot T + 1 + 12 + 7$ variables de entrada, $\frac{1}{2} \cdot$ neuronas de entrada igual a neuronas escondidas y una neurona de salida. Se aplicó la herramienta Matlab (versión 6.5) para el entrenamiento y la aplicación de la red. A continuación se muestran los resultados asociados.

Resultados de modelos de clasificación ante eventos específicos de FMG

Los resultados se expresan en Efectividad y Eficiencia en la clasificación. Estas pueden variar en función de la duración de los eventos FMG y del intervalo de observación en análisis T. Es intuitivo pensar que a mayor duración de un evento FMG, mejor rendimiento en la clasificación, tendencia que se comprueba con los resultados. Se probaron 3 intervalos de observación (18, 12 y 6 horas), obteniéndose resultados similares para $T=12$ y $T=6$.

Gráfico 1: Efectividad en la clasificación ante diversas duraciones (t^*) de eventos FMG




Resultados de modelos de clasificación en instantes específicos de operación normal de la sala de ventas

La efectividad de los modelos varía en función de la cantidad de intervalos que se analizan (T) y el instante (t) en que se realiza la clasificación. En general, para T=2 la efectividad es notoriamente inferior (comparativamente); para los modelos que analizaron registros con T=4 también se observan rendimientos inferiores. Para modelos formulados con T igual o mayor a 6 no se identifican grandes diferencias, en este sentido, se puede afirmar que la eficacia no mejora significativamente al aumentar la cantidad de tiempo en análisis desde T=6.

La efectividad está estrechamente ligada con el nivel de actividad del supermercado, lo cual es lógico ya que la clasificación de los SKU está basada en la evolución de unidades vendidas para períodos inmediatamente anteriores al instante t en análisis.

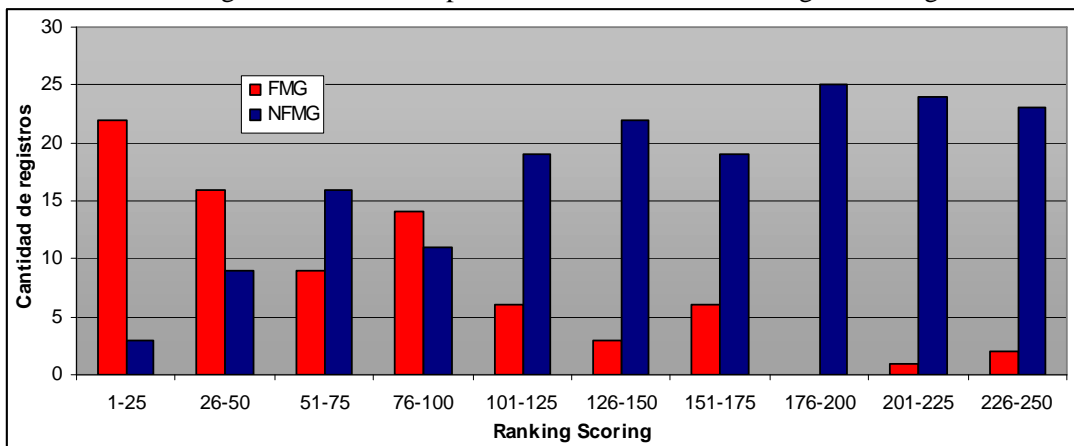
Gráfico 2: Efectividad en la clasificación ante diversos instantes (t) de la operación del supermercado



4.3 Aplicación de los modelos

Para la aplicación parece muy útil el siguiente *scoring* basado en los resultados de los modelos. El modelo asigna un grado de pertenencia a cada registro para las 2 clases FMG/No FMG. Ordenando los registros por este grado de pertenencia a la clase FMG se pueden analizar los errores y aciertos a la clase FMG, determinando hasta qué posición en el listado de *scoring* es necesario revisar los productos en las góndolas. A continuación se presenta un ejemplo para T=8 y t=22, es decir una revisión a las 22 horas considerando las 8 horas anteriores.

Gráfico 3: Registros clasificados por clase en función del ranking de scoring FMG



Se ve claramente que muchos de los registros con alto grado de pertenencia a la clase FMG (las barras a la izquierda) efectivamente pertenecen a la clase FMG. Análogamente, entre los registros con alto grado de pertenencia a la clase No FMG (barras a la derecha) se encuentran muchos que efectivamente no representan el fenómeno de faltantes.

5. Conclusiones

El rendimiento de los modelos cambia dependiendo del tiempo que ha pasado desde que un SKU se encuentra en estado FMG, lo que obviamente se produce debido a que se experimentan intervalos de tiempo sin venta mayores. Los modelos enfocados a la operación normal del supermercado también poseen rendimientos diferentes en función del instante de evaluación y clasificación de los SKU, encontrándose que la clasificación en instantes inmediatamente posteriores a ventanas de tiempo con bajos niveles de venta producen menores rendimientos en comparación a las clasificaciones realizadas inmediatamente después de un intervalo de alta demanda.

Se evaluaron los errores en la clasificación, identificándose que, en general, los modelos mantienen su capacidad de clasificación para la mayoría de las subcategorías estudiadas.

La utilización de Scoring FMG se plantea como la mejor manera de implementar operativamente un modelo de estas características, esto porque asegura el uso eficiente de los recursos disponibles para la revisión de los productos en las góndolas, asegurando la más alta eficiencia y eficacia en los primeros SKU de la lista (ranking).

Los modelos diseñados pueden tener efectos considerables en la gestión de abastecimiento de las salas de supermercado. La detección de faltantes también puede ayudar a minimizar los errores de stock de inventario, ya que ante la identificación de un SKU en estado FMG, el paso lógico es solucionar el problema que lo ha causado, el cual muy probablemente sea un error en el sistema de stock teórico.

6. Futuras investigaciones

La incorporación de nuevas variables (precios, promociones, etc.) permitiría mejorar la capacidad de clasificación de los modelos planteados. También, la aplicación de otras clases de modelos de clasificación.

Una futura aplicación posible es la utilización de esta clase de modelos para generar nuevas metodologías orientadas a mejorar los pronósticos de demanda actualmente utilizados en la industria del retail [Aburto, Weber 2006], incorporando filtros a aquellos intervalos de tiempo que no presentan ventas y que muy probablemente no se hayan generado por una baja en la demanda, sino más bien porque corresponden a eventos FMG.

7. Agradecimientos

El desarrollo de esta investigación fue posible gracias al apoyo y colaboración de la cadena de supermercados Rendic Hnos S.A. y del proyecto Fondef “Desarrollo de Tecnologías de Gestión para aumentar la Productividad de Cadenas de Abastecimiento de Industrias de Consumo Masivo: Aplicación al Caso Supermercados; D03I1057.

8. Referencias

Aburto, L., Weber, R. (2006): Improved Supply Chain Management based on Hybrid Demand Forecasts. Applied Soft Computing, Elsevier, in press, available online at www.elsevier.com/locate/asoc

AcNielsen, Child (2004): Cambios en el Mercado Chileno 2004: Entendiendo al Consumidor.

Andersen T., Martinez T. (1999), Cross Validation and MLP Architecture Selection, IEEE International Joint Conference on Neural Networks IJCNN'99.

Campo, K., Gijbrecchts, E. & Nisol, P. (2003), The impact of stock-out on whether, how much and what to buy, International Journal of Research in Marketing 20, 273-286.

Davey, N., Hunt, S.P., Frank, R.J. (1997), Time Series Prediction and Neural Networks, Journal of Intelligent and Robotic Systems, 312000, 91-103.

Kooistra, A., (1999). De vreselijke verspilling (The huge waste), Foodmagazine, 55 (5), 20-25.

Universidad de Chile: Las cifras de quiebres de stock en Chile, Revista LYD tech (N°27 Enero-Febrero 2005) 28-38.