

**UNIVERSIDAD DE CHILE  
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS  
DEPARTAMENTO DE INGENIERIA INDUSTRIAL**

**MODELO PREDICTIVO DE QUIEBRES DE STOCK EN UN SUPERMERCADO**

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

**TRINIDAD FIGUEROA GOSTIN**

PROFESOR GUÍA:  
LUIS ABURTO LAFOURCADE

MIEMBRO DE LA COMICIÓN:  
RICHARD WEBER HAAS  
ALEJANDRA PUENTE CHANDIA

SANTIAGO DE CHILE  
OCTUBRE 2009

RESUMEN DE LA MEMORIA  
PARA OPTAR AL TÍTULO DE  
INGENIERO CIVIL INDUSTRIAL  
POR : TRINIDAD FIGUEROA G.  
FECHA: 06/10/09  
PROF. GUIA: SR. LUIS ABURTO

## **MODELO PREDICTIVO DE QUIEBRES DE STOCK EN UN SUPERMERCADO**

La presente memoria se centra en el problema de los faltantes de mercadería en góndola (FMG). Este es un índice que refleja el porcentaje de veces en el cual un cliente, al asistir a la sala por un determinado producto, no lo encuentra. En Chile alcanza un 15% aproximadamente, en cambio en Estados Unidos un 8% solamente.

El problema se traduce en que el 60% de las veces que un cliente se ve enfrentado a dicha situación, no realiza la compra, o la próxima vez que necesite dicho producto no volverá a esa sala a buscarlo. Esto provoca ventas perdidas, y también afecta negativamente la imagen del supermercado.

El proyecto consiste en un modelo de predicción de quiebres de stock para un supermercado. El estudio se hizo para una sala de un supermercado mayorista y se analizaron dos categorías de esta sala, una de alta rotación (Leches Líquidas) y otra de baja (Pañales Desechables).

Se hicieron mediciones del stock diario en góndola para cuatro categorías (las dos antes mencionadas, más margarinas y leches en polvo) con esto se obtuvo el valor de lo que sería la variable dependiente (disponibilidad, vale 1 si existe quiebre de stock en un día-producto y 0 en caso contrario). Las variables predictivas fueron derivadas de los datos transaccionales.

Se construyeron modelos de árboles de decisión y regresión logística para cada categoría, y se compararon para ver cuál era el mejor. En el caso de Leches Líquidas, el mejor modelo predijo el 56% de los quiebres de stock con una efectividad del 50% y para Pañales Desechables, un 46% con una efectividad del 78%.

El resultado final es un modelo de predicción para cada categoría y recomendaciones para la generalización de estos modelos sobre otras categorías, como también un esquema con los pasos a seguir para la implementación de los modelos en el supermercado.

## ÍNDICE

<b>1. ANTECEDENTES GENERALES</b> .....	<b>4</b>
1.1 La industria de los supermercados en Chile .....	4
1.2 Productos Faltantes en Góndola .....	5
<b>2. DEFINICIÓN DEL PROYECTO</b> .....	<b>7</b>
2.1 Descripción del proyecto y justificación.....	7
2.2 Objetivos .....	10
2.3 Metodología .....	10
2.4 Alcances.....	11
2.5 Entregables.....	11
2.6 Marco Conceptual .....	12
<b>3. DESARROLLO METODOLÓGICO</b> .....	<b>16</b>
3.1 Descripción de la sala de estudio .....	16
3.2 Análisis y elección de categorías a estudiar .....	16
3.3 Medición en sala.....	19
3.4 Información Disponible.....	20
<b>4. MODELOS PREDICTIVOS DE QUIEBRES DE STOCK</b> .....	<b>22</b>
4.1 Objetivos de los modelos .....	22
4.2 Elección de las variables .....	22
4.3 Descripción y elección de los modelos de predicción .....	23
4.3.1 Elección del modelo para Leches líquidas .....	26
4.3.2 Elección del modelo para Pañales Desechables.....	32
4.4 Generalización de los modelos.....	37
<b>5. METODOLOGÍA PARA LA IMPLEMENTACIÓN DE LOS MODELOS</b> .....	<b>40</b>
<b>6. CONCLUSIONES</b> .....	<b>41</b>
<b>8. BIBLIOGRAFÍA Y FUENTES DE INFORMACIÓN</b> .....	<b>43</b>
<b>9. ANEXOS</b> .....	<b>45</b>
9.1 Anexo 1: Indicadores de disponibilidad por categoría .....	45
9.2 Anexo 2: Resultados medición en sala .....	46
9.3 Anexo 3: Modelos Margarinas y Leche en polvo.....	54

## 1. ANTECEDENTES GENERALES

### 1.1 La industria de los supermercados en Chile

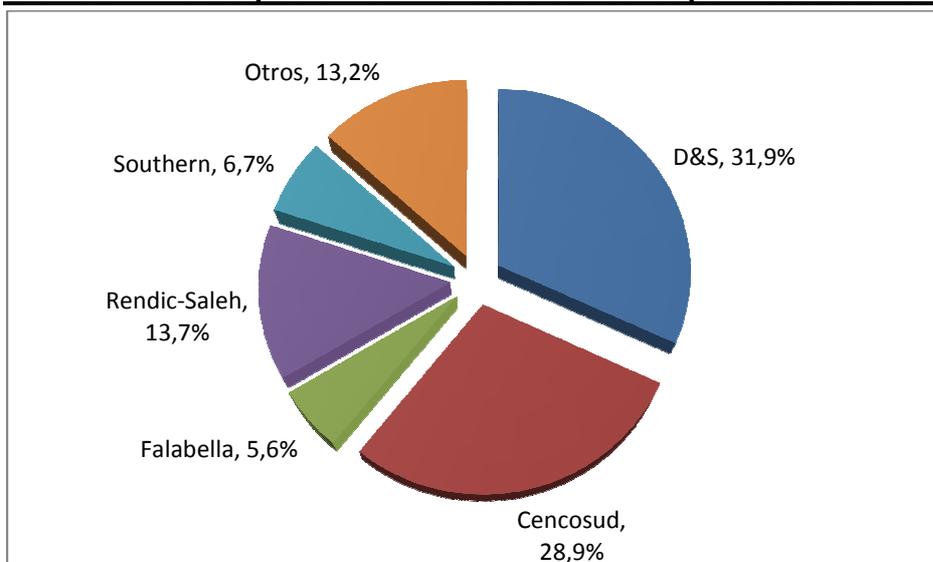
Los supermercados están inmersos en la industria del retail. Esta industria es muy importante para el país ya que aporta con un 21% del PIB y produjo un total de ventas por alrededor de US\$ 30.000 MM (año 2006) [12].

Actualmente los supermercados en Chile están en un período de concentración, cada día hay más supermercados a lo largo del país. En efecto, para Enero de 2008 existían 814 salas, lo que en un año llegaron a ser 935 salas (Enero 2009) [11].

Hoy en día, las principales cadenas de supermercados son D&S (Líder y Ekono), Cencosud (Jumbo y Santa Isabel), Falabella (Tottus), Rendic-Saleh (Unimarc, Deca, Bryc) y Southern.

Sus participaciones de mercado para lo que fue el 2008 son las siguientes:

**Grafico 1: Participacion de mercado de los Supermecados 2008**



Fuente: Memoria anual D&S 2008

## 1.2 Productos Faltantes en Góndola

Un faltante de mercadería en góndola (FMG) corresponde a un SKU (Stock Keeping Unit) que pertenece al mix de productos ofertados en la sala de ventas, pero que no se encuentra disponible en la góndola designada en un determinado momento.

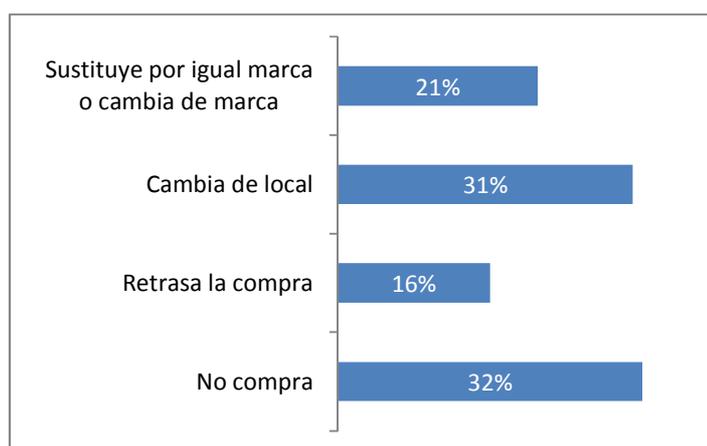
En los últimos años se ha producido un gran aumento en la cantidad de SKU ofrecidos por las distintas salas de ventas. En un supermercado mediano la cantidad de SKU puede ser del orden de 20.000 mientras que en un Hipermercado puede llegar hasta 100.000. Esto se debe a que los consumidores son cada vez más exigentes por lo que se necesita un mayor surtido de productos para poder satisfacerlos. El manejo de todos estos SKU's se ha vuelto un proceso complejo y es muy difícil mantener los productos en stock y disponibles en la góndola.

En Chile, el último estudio de FMG realizado el año 2005, muestra que el índice de FMG a nivel país es de un 14,5%, en otras palabras, es el porcentaje de las veces que un cliente asiste a una sala, no encuentra el producto que está buscando<sup>1</sup>.

Este porcentaje de FMG le cuesta a la industria alrededor del 10% de las ventas anuales, es decir que si la industria en el 2006 facturó US\$6.800 millones al año, los FMG provocan una total de US\$ 680 millones de ventas perdidas.

Por parte de los consumidores las reacciones frente a un FMG se pueden apreciar en el siguiente gráfico:

**Grafico 2: Reacciones de los consumidores frente a un FMG**



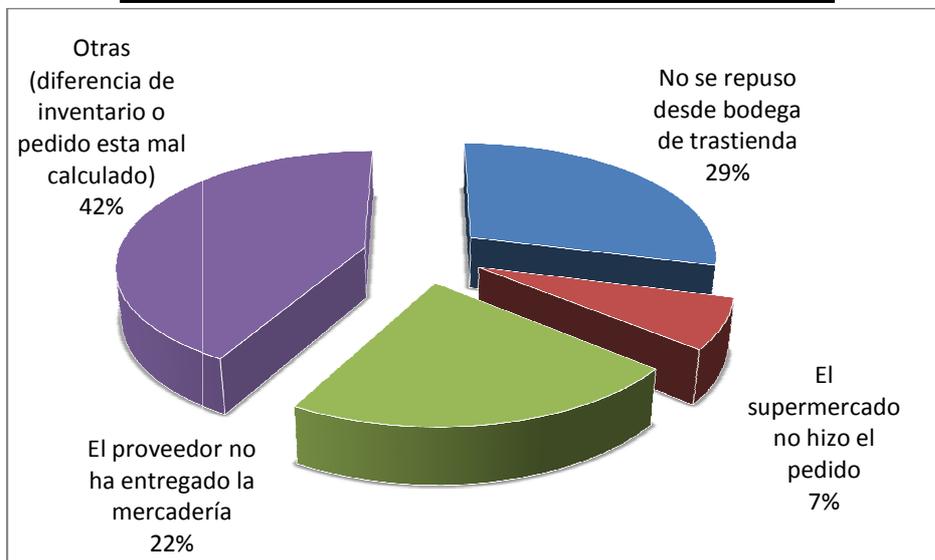
Fuente: Revista GS1 Marzo 2006

Los principales responsables de los FMG son las salas de ventas, ya que el 78% de las causas por las cuales se producen estos sucesos son problemas en la misma tienda, como por ejemplo desajustes de inventario debido a que los sistemas de información no

<sup>1</sup> Fuente: Revista GS1 Marzo 2006

representan la situación real del supermercado o que no se repuso desde la bodega a la sala. Sólo el 22% es por parte del resto de la cadena de distribución.

**Grafico 3: Causas FMG Genéricas en Chile 2005**



Fuente: Revista GS1, marzo 2006

## 2. DEFINICIÓN DEL PROYECTO

### 2.1 Descripción del proyecto y justificación

El presente trabajo de título, se desarrolla dentro del tema de disponibilidad de SKU's en góndola, en particular para un supermercado mayorista.

El problema que abordará será la existencia de FMG durante el horario de ventas de la sala en estudio.

Ante la presencia de un "faltante de mercadería en góndola", existen distintas respuestas posibles de parte de los consumidores: cambio de marca, tipo o tamaño, búsqueda del producto en otra tienda, aplazamiento de la compra (volver otro día por el producto) y cancelación de la compra. Dados estos posibles escenarios, el resultado de ellos se puede traducir en: pérdida de clientes, reducción de ventas, decaimiento en la imagen de la cadena, etc.

En Chile, el nivel de FMG alcanzó un 14,5% en 2005 en supermercados [7], lo que se traduce que dicha cantidad, del total de veces que un cliente asistió a una sala de este tipo de formato, no encontró el SKU que estaba buscando. Se estima que este problema le cuesta un 10% de sus ventas a la cadena [7]. En la tabla 1, se puede apreciar un estudio más detallado de costos asociados a quiebres de stock, para la industria chilena de supermercados[4].

**Tabla 1: Costos asociados a quiebres de stock para la industria chilena de supermercados**

<b>Costos Directos</b>	Retailer	MMUS\$ 65
	Proveedor	MMUS\$ 85
	Total	MMUS\$ 150
<b>Costos Indirectos</b>	Imagen	MMUS\$ 280
<b>Costo consumidor</b>		MMUS\$ 270

Fuente: Revista GS1 Marzo 2006

Actualmente, la cadena de supermercado en estudio, al igual que el resto de la industria, posee sistemas de control de inventarios, por lo tanto a priori, se puede tender a pensar en una utilización de la información de dichas herramientas para la solución del problema. Pero existe una problemática en su uso, ya que estos muestran cual es el stock en la sala de ventas completa, toma en cuenta lo que hay en bodega mas lo que hay en la góndola, lo que hace muy difícil saber la verdadera cantidad disponible en

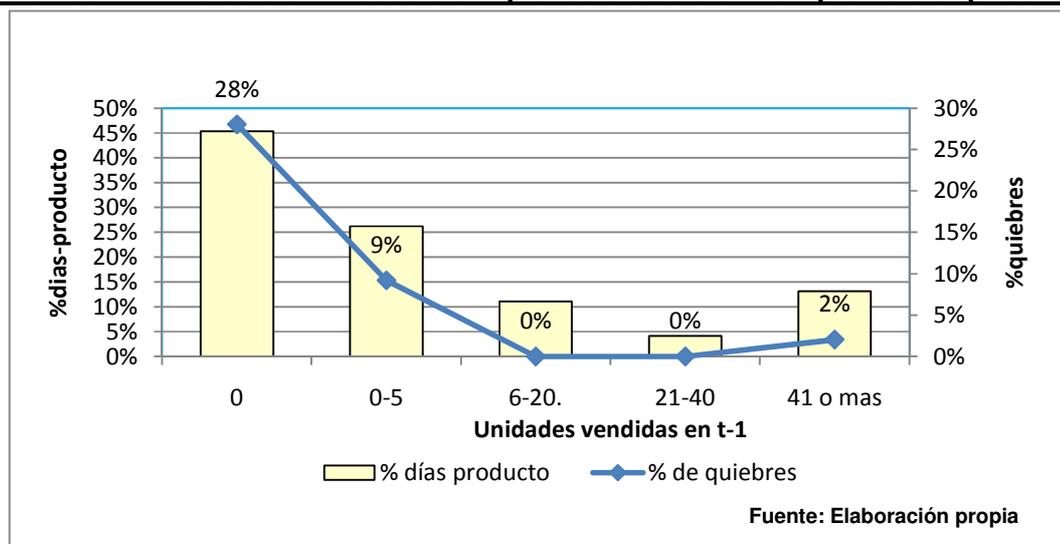
góndola para cada SKU. A esto se suma que por lo general los datos de inventario son poco confiables ya que existe merma, robo y desajustes de inventarios.

Por todo lo anterior, será necesario utilizar información que contenga el comportamiento de compra de los clientes. Éstos pueden ser detectados a través de información recopilada por el POS (Point of Sale). De esta manera, sería posible determinar la presencia de un SKU en estado FMG mediante un modelo que considere variables derivadas del POS.

A través de la detección de quiebres de stock se puede calcular un nivel de servicio para los SKU de cada categoría y de esta manera obtener un promedio general de cada categoría y tener una visión global de lo que está sucediendo y cuáles son las categorías con problemas.

Actualmente en el supermercado, se utiliza la siguiente metodología para detectar los FMG: si las ventas en un día fueron cero para un SKU, entonces se asume que existirá quiebre de stock al día siguiente.

**Gráfico 4 : Evaluación método simple de detección temprana de quiebres**



El gráfico 4, fue construido a partir de los datos recolectados en la medición realizada por el alumno para una categoría.

En cada barra de dicho gráfico, se aprecia el porcentaje del total de días-productos en que las unidades vendidas fueron 0 (primera barra) en t-1. La línea punteada corresponde al porcentaje real medido de quiebres en t para cada "barra". Así vemos que para el primer caso, donde hubo un 45% de días-productos con ventas igual a cero, el modelo actual del supermercado, hubiese pronosticado un 45% de quiebres para el día siguiente, siendo que el valor real que existieron fue un 28%. Entonces se aprecia inmediatamente la existencia de un error de parte de este modelo. Además, se

encontraron quiebres para otros días-productos en que sus ventas no fueron cero el día anterior ( $9\% + 2\% = 11\%$ ), los cuales el modelo actual no hubiese detectado.

**Tabla 2: Tabla de contingencia modelo simple**

	Predicción		
Real	No quiebre	Quiebre	Eficiencia
No quiebre	388	244	61%
Quiebre	20	95	83%
Eficacia	95%	28%	

Fuente: Elaboración propia

En la tabla anterior se puede apreciar que si bien se detectan una gran cantidad de quiebres (eficiencia 83%), la eficacia es de un 28%, esto quiere decir que de todos los registros que se dicen quiebres solo el 28% lo son realmente.

Por todo lo anterior, es necesario un nuevo modelo para predecir los FMG. Que pronostique con una mayor eficiencia y eficacia los quiebres de stock, minimizando los costos asociados que conlleva la reposición en falso<sup>2</sup> y las de ventas pérdidas por este concepto.

El proyecto consistirá en un principio, en definir cuáles serán las categorías a estudiar, ya que cada una se comporta de forma diferente. Se elegirán dos de ellas, una de alta y otra de baja rotación. Serán analizadas con distintos modelos de predicción, a partir de datos transaccionales de ventas facilitados por el supermercado, sumado a mediciones de stock en góndolas a ser realizadas personalmente por el alumno durante un período determinado de tiempo. Para posteriormente comparar los resultados obtenidos para cada modelo, con el fin de verificar cual de ellos se adecua de mejor manera a la categoría en estudio.

En resumen, el problema es detectar en qué momento ocurrirá un evento FMG, dicho en otras palabras, cuando un SKU no estará disponible en la góndola. Es importante la solución de este problema dados los altos costos en que se ven afectados los actores involucrados (retailer, proveedores, consumidores, etc.). La forma de resolver esta situación, será a partir de modelos de predicción computacionales, así obtener finalmente un modelo que entregue en sus “outputs” pronósticos de cuándo ocurrirá el FMG, cosa de poder anticiparse a él y evitarlo.

<sup>2</sup> “reposición en falso” se refiere a cuando se envía a una persona a reponer el FMG, cuando el SKU no se encuentra en dicho estado.

## 2.2 Objetivos

- **Objetivo General**

Construir un modelo para detectar quiebres de stock para distintas categorías en un supermercado mediante sus datos transaccionales.

- **Objetivos Específicos**

- Comparación de los roles de las distintas categorías.
- Identificar las variables derivadas del POS que ayuden a predecir los FMG.
- Evaluar y comparar los distintos modelos que se pueden aplicar al caso en estudio.
- Determinar qué modelo predice mejor los FMG para cada categoría minimizando los costos asociados a los errores de predicción.
- Evaluar la capacidad de generalización de los modelos para otras categorías.
- Definir una metodología para la implementación de los modelos.

## 2.3 Metodología

La metodología a seguir será la siguiente:

1. Analizar la información del punto de venta.

Conocer con qué información se cuenta y la forma en qué está organizada, para poder analizar las características de las ventas, cantidad y estacionalidades, como también para conocer el surtido de la tienda y la importancia que cada categoría tiene para el supermercado.

2. Definir las categorías a analizar.

La elección de categorías se hará de tal manera que las categorías seleccionadas sean de gran importancia para el supermercado (presencia alta en boletas) y que una sea de alta rotación de inventario y otra de baja.

### 3. Medición en sala.

Se realizarán mediciones diarias de cantidad de stock en góndola por sku para las categorías en estudio, esta sería la variable dependiente para los modelos. Esto durante un período de 9 días.

### 4. Procesamiento de la información.

Esta etapa tiene por propósito tener todos los datos necesarios ordenados y listos para poder utilizarlos en el modelamiento posterior, utilizando técnicas de limpieza de datos.

### 5. Desarrollo y evaluación de modelos preliminares.

Se desarrollarán modelos de predicción con árboles de decisión y regresión logística para cada categoría en estudio.

6. Comparación de los distintos modelos para cada categoría, para luego decidir cuál es el que más se adecúa. Para esto se calcularán los costos de los errores de pronósticos de cada modelo y también indicadores como la eficiencia y eficacia.

7. Aplicación de los modelos a otras categorías para ver su capacidad de generalización.

## 2.4 Alcances

- Este estudio se hará sólo para una sala en particular, dejando fuera la aplicación a otras salas.
- Se estudiarán sólo dos categorías en las cuales se aplicarán dos tipos de modelos para luego definir cuál es el que mejor se adapta a cada categoría.
- No se estudiará lo relacionado con la cadena de suministro del supermercado. Manteniendo con esto al margen la relación con los proveedores, el tipo de bodegas, etc.

## 2.5 Entregables

- Variables derivadas del POS que ayudan a predecir los quiebres de stock.
- Modelos de predicción de quiebres para las categorías en análisis.
- Metodología para implementar los modelos propuestos.

## 2.6 Marco Conceptual

Para el desarrollo de esta memoria se utilizarán datos transaccionales de la tienda como input para los modelos a utilizar.

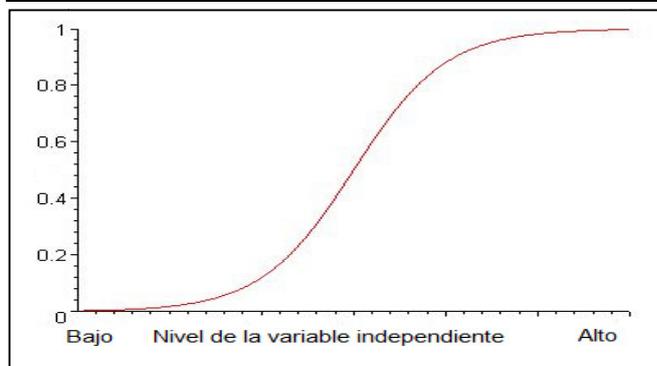
Se ha decidido utilizar modelos de minería de datos como árboles de decisión y regresión logística binaria.

### 1. Regresión Logística:

La regresión logística [16] es una técnica estadística multivariante que predice directamente la probabilidad de ocurrencia de un determinado suceso. Su aplicación es principalmente para variables independientes dicotómicas.

Para definir una relación acotada entre 0 y 1 la regresión logística utiliza una relación supuesta entre las variables dependientes que recuerda a una curva de "S". Para niveles muy bajos de la variable independiente la probabilidad se aproxima a cero. Según crece la variable independiente, la probabilidad crece a lo largo de la curva, pero como la pendiente empieza a decrecer para cierto nivel de la variable independiente, la probabilidad se acercara a 1 pero si llegar a excederlo

**Grafico 5: Forma de la relación logística entre las variables independiente y dependiente[16]**



Matemáticamente el modelo es de la siguiente forma:

$$f(z) = \frac{1}{1 + e^{-z}} \quad (\text{Probabilidad de ocurrencia del evento})$$

$$z = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_K X_K$$

El vector de parámetros se estima a través de la función de máxima verosimilitud.

## 2. Arboles de decisión:

Un modelo de árbol de decisión[14] consiste en un conjunto de reglas para dividir una gran población heterogénea, en grupos más pequeños y homogéneos con respecto a una variable objetivo particular.

La variable objetivo suele ser categórica y el árbol de decisiones o bien se utiliza para calcular la probabilidad de que un determinado registro pertenezca a cada una de las categorías, o para clasificar un registro mediante la asignación a la clase más probable. Los árboles de decisión también se pueden utilizar para estimar el valor de una variable continua, aunque hay otras técnicas más adecuadas para esa tarea.

Los árboles de decisión están formados por 3 componentes:

- **Nodo:** es un punto de unión en donde se debe tomar una decisión
- **Rama:** Es un arco de conexión entre los nodos.
- **Hoja:** es un nodo terminal (sin hijos)

Existen principalmente tres tipos de medidas que se suelen utilizar para evaluar si las subdivisiones de un árbol están aportando al resultado final de este y de esta manera también tener un parámetro de corte en el crecimiento del árbol.

- **Coefficiente  $\chi^2$ :**

Este coeficiente mide la asociación entre dos variables nominales u ordinales y se define como:

$$\chi^2 = \sum \sum \frac{(\eta_{ij} - \eta'_{ij})^2}{\eta'_{ij}}$$

Donde:

$\eta_{ij}$  =frecuencia observada de la celda (i,j)

$\eta'_{ij}$ =frecuencia esperada de la celda (i, j)

Valores cercanos a cero de este coeficiente indicarán que no hay asociación entre la variable fila y la variable columna. Entre mayor sea este coeficiente mayor es la asociación entre las variables analizadas.

- **Índice de Gini:**

El índice de Gini en el nodo  $t$  se define como:

$$g(t) = \sum p(i/t)^2$$

Donde  $i$  representa las distintas categorías de la clase criterio. Cuando todos los casos del nodo  $t$  pertenecen a la misma categoría, el índice de Gini toma el valor uno, se dice entonces que el nodo se vuelve puro.

Este índice es una medida de impureza en la clasificación de los datos, a medida de que se va clasificando bien el índice va tomando valores cercanos a 1.

Para “medir” la mejora de una clasificación debida a la división de los datos en dos grupos, se utiliza el siguiente criterio:

$$\Phi(s, t) = p_{iz} \cdot g(t_{iz}) + p_{de} \cdot g(t_{de})$$

Donde:

$p_{iz}$  = Proporción de casos enviados al nodo izquierdo

$p_{de}$  = Proporción de los casos enviados al nodo derecho

$g(t_{iz})$  = Valor del índice de Gini en el nodo izquierdo

$g(t_{de})$  = Valor del índice de Gini en el nodo derecho

$s$  = División propuesta.

Si el valor del índice para la división es mejor que el valor del índice para el nodo anterior entonces es recomendable hacer la división. A mayor diferencia entre estos valores mejor será la división.

- **Reducción de la Entropía o Ganancia de información:**

La entropía de un nodo se mide de la siguiente forma:

$$S(t) = \sum_i p(i/t) \cdot \log_2 p(i/t)$$

Donde:

$p(i/t)$ = proporción de registros del nodo t que pertenecen a la clase i.

La entropía de una división es la suma de las entropías de los nodos resultantes multiplicadas por el porcentaje de los registros totales que existe en cada uno de estos nodos.

Lo que se busca es la división que disminuya la entropía, o sea que produzca mayor ganancia de información.

**Tabla3: Tipos de árboles[10]**

Árbol	Tipo de variable a predecir	particiones	Medida de subdivisión
CR&T	de rango o categoría	binarias	Índice de Gini o índice binario
CHAID	de rango o categoría	puede ser no binaria	Estadístico $\chi^2$
C5	de categoría	binarias	Ganancia de información

Fuente: Manual Clementine 12.0

En la tabla 2 se pueden ver algunas de las principales características de los árboles usados por el programa Clementine.

### **3. DESARROLLO METODOLÓGICO**

#### **3.1 Descripción de la sala de estudio**

El estudio se hizo en una sala de un supermercado mayorista ubicada en la calle Concha y Toro comuna Puente Alto, Santiago.

Este supermercado cuenta con 16 sucursales en la región Metropolitana y 20 en regiones, siendo la sucursal en estudio una de las más importantes de la cadena ya que tiene el mayor monto en ventas. El último año (2008) esta sucursal aportó con un 6% del total de ventas de la cadena.

Esta sala tiene alrededor de 350 sub categorías de las cuales sólo 30 hacen el 80% de las ventas. Dentro de estas 30 categoría existen 2000 SKU aproximadamente en total.

El formato de la sala es de tipo supermercado, su tamaño es de 1200 m<sup>2</sup> aprox. y tiene 10 cajas.

#### **3.2 Análisis y elección de categorías a estudiar**

Para empezar con el estudio de los datos, se contó con una base de datos con las ventas diarias, monto total, y transacciones totales para cada SKU de la sala en estudio.

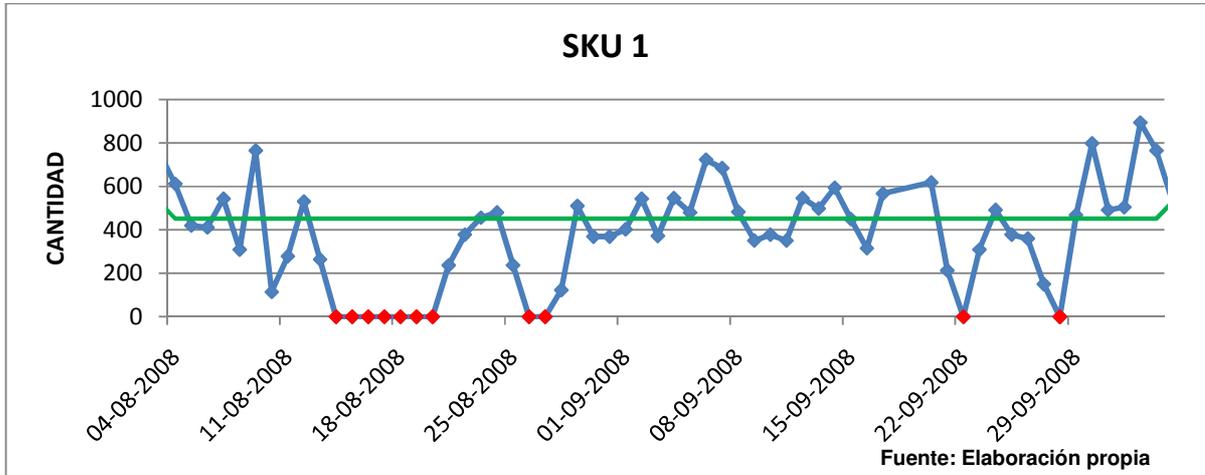
Se calcularon algunos indicadores de disponibilidad como el nivel de servicio y las ventanas de tiempo sin ventas para cada SKU, como también la variable presencia para cada categoría.

El nivel de servicio se calculó como el porcentaje de días en que la cantidad vendida era distinta de cero, mientras que la presencia para cada categoría es la cantidad de transacciones de los sku's pertenecientes a la categoría dividida por el número de transacciones totales de la sucursal.

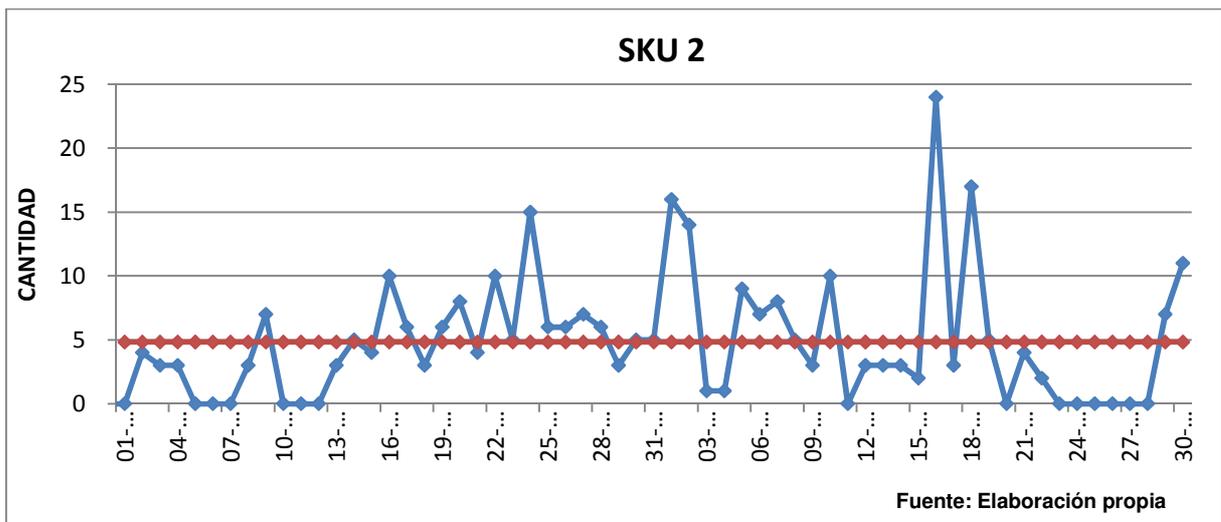
La tabla con los indicadores antes mencionados se puede encontrar en el Anexo 1.

Para el análisis se buscan dos categorías una de alta rotación y otra de baja, esto debido a que a priori se puede decir que es más fácil identificar un evento FMG en una categoría de alta rotación ya que el hecho que venda poco un día puede significar un posible quiebre, mientras que en una de baja rotación es normal que se vendan pocas unidades diarias por lo que identificar un quiebre puede ser más difícil. Esto se puede ver con más claridad en el siguiente ejemplo.

**Gráfico 6: Unidades vendidas diarias SKU1**



**Gráfico 7: Unidades vendidas diarias SKU2**



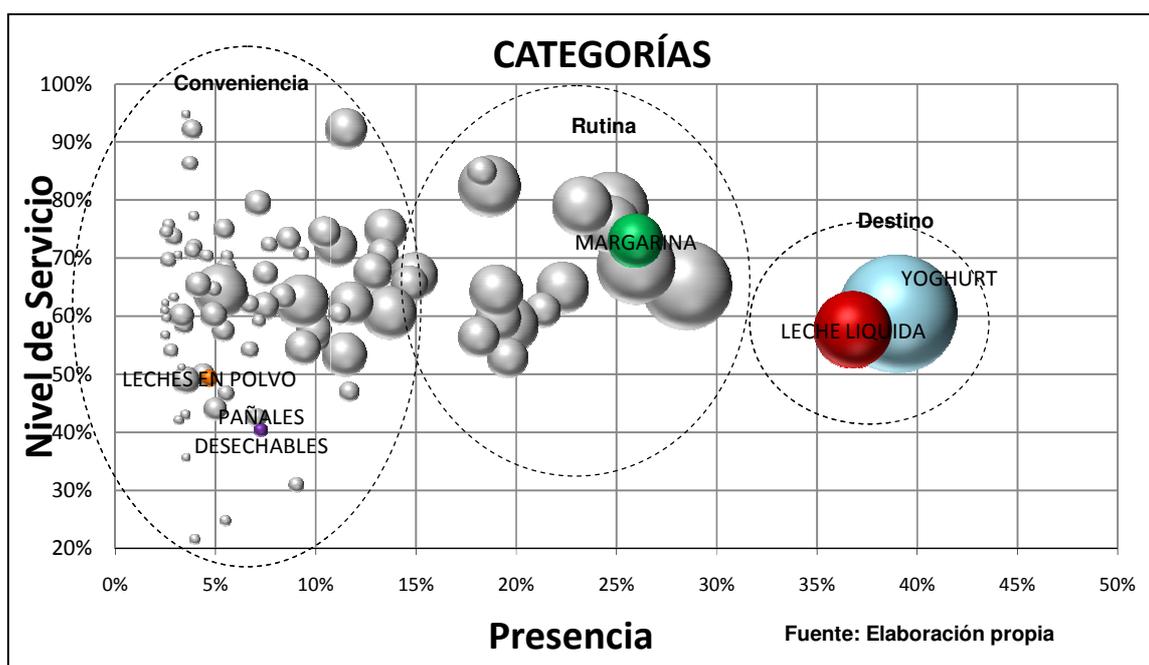
El SKU 1 pertenece a una categoría de alta rotación y en promedio vende 450 unidades diarias aprox. Por lo que se podría decir con cierta seguridad que el hecho que hayan ventas cero durante varios días consecutivos se pueda deber a que existe un quiebre de stock en la góndola.

Por otro lado el SKU 2 pertenece a una categoría de baja rotación y en promedio vende 5 unidades diarias por lo que, que un día que venda cero no es raro y es ahí donde hay un problema para identificar si eso se debe a un quiebre de stock o no.

Para la elección de las categorías a estudiar se consideró la rotación, la importancia de la categoría en el supermercado (presencia y monto total de ventas) y su nivel de servicio.

A continuación en el gráfico 8 se muestra las categorías con presencia en boleta mayor a un 3%, el tamaño de las burbujas es cantidad de unidades vendidas de cada categoría.

**Gráfico 8: Categorías con presencia mayor al 3% en la sucursal**



En éste gráfico se puede ver que la categoría Leche Líquida cumple con la condición de alta rotación ya que el tamaño de burbuja es grande y por otro lado tiene una alta presencia y un bajo nivel de servicio. Se eligió esta categoría y no Yogurt debido a que la cantidad de sku's de Yogurt es un 50% mayor que Leches Líquidas, lo que hace que en el futuro la medición en sala pueda ser muy engorrosa.

La segunda categoría elegida fue Pañales desechables, porque como se puede ver tiene baja rotación y dentro de las categorías que tienen baja rotación su presencia es alta y su nivel de servicio es muy bajo.

También se eligieron otras dos categorías, Margarina y Leches en polvo para una vez hechos los modelos de predicción de quiebres poder ver la capacidad de generalización que estos tienen frente a otras categorías con características similares.

**Tabla 4: Características categorías escogidas**

<b>Categoría</b>	<b>Rol</b>	<b>Presencia en boleta</b>	<b>Nivel de servicio promedio</b>	<b>Cantidad de sku en categoría</b>	<b>% del monto total de la sucursal</b>	<b>unidades vendidas prom diario</b>
<b>Leche Líquida</b>	Destino	37%	58%	91	6%	3345
<b>Margarina</b>	Rutina	26%	73%	46	2%	1657
<b>Pañales Desechables</b>	Conveniencia	7%	40%	43	1%	91
<b>Leche en polvo</b>	Conveniencia	5%	49%	40	1%	159

Fuente: Elaboración propia

### **3.3 Medición en sala**

Teniendo las categorías con que se trabajaría elegidas, se procedió a visitar la sala para definir cómo sería la forma de medición.

Se consultó al encargado de sala, quien afirmó que las reposiciones de los productos se efectuaban todos los días entre las 8:00 y las 14:00 horas. Por otro lado los horarios peak del supermercado (en los que había mayor cantidad de clientes) eran dos; entre las 10:30-13:00 y entre las 16:00-19:00 horas.

Por lo anterior se decidió hacer mediciones de quiebres parciales una vez al día en distintos horarios de manera de poder encontrar la mayor cantidad de quiebres posibles.

La medición consistió en registrar la cantidad de unidades de cada SKU que había en góndola.

La medición se hizo durante dos períodos. La primera medición contempló dos categorías (leches líquidas y pañales desechables) en total 134 sku´s durante 9 días hábiles. (entre el 21 de enero y el 3 de febrero de 2009).

La segunda medición contempló esta vez cuatro categorías (las dos anterior más margarinas y leches en polvo) en total 218 SKU´s. La medición se hizo durante 10 días consecutivos entre el 21y el 30 de abril de 2009.

Para las mediciones se llevó una planilla con todos los SKU's de las categorías en estudio y la medición consistía en registrar la cantidad de unidades de cada SKU que habían en góndola. Se consideraron solo aquellos productos que estaban a la vista y no aquellos que estaban escondidos entre otros, en ese caso no se contaban.

**Tabla 5: Porcentaje de días-productos con quiebres**

<b>Categorías</b>	<b>% días-producto quiebres</b>
Leches líquidas	16,26%
Pañales Desechable	16,65%
Margarinas	9,15%
Leches en polvo	10,75%

Fuente: Elaboración propia

Los resultados de la medición por SKU se pueden encontrar en el Anexo 2.

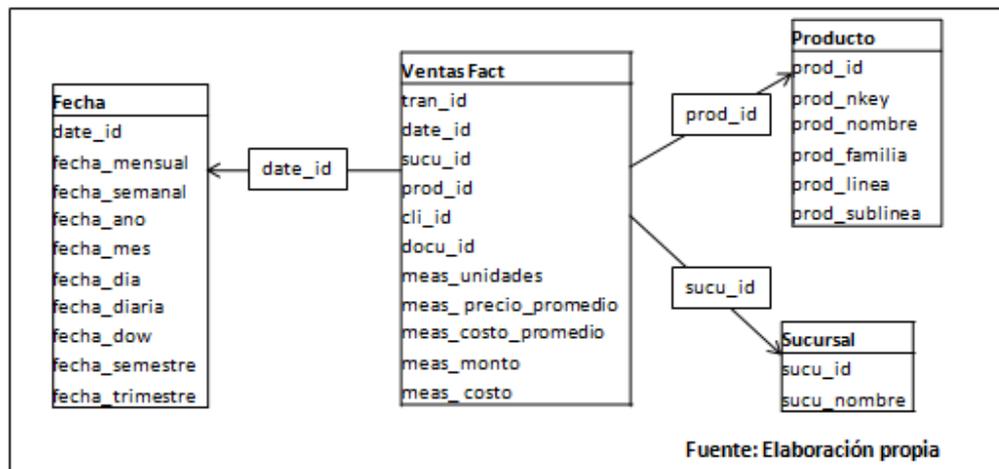
### **3.4 Información Disponible**

Como resultado de la medición en sala y la extracción de datos provenientes del POS se tienen los datos necesarios para luego poder crear los modelos predictivos de quiebres de stock.

En primer lugar se tienen los datos de la medición en sala los cuales serán la variable dependiente de los modelos (variable disponibilidad que tomará el valor 1 en caso de que exista un quiebre de stock y cero en el caso contrario), esto quiere decir que se buscara predecir ésta variable usando como variables independientes (o predictivas) las que puedan ser derivadas del POS.

Del POS se pueden obtener variables tales como la venta diaria, precio diario, categoría a la que pertenece etc. para cada SKU.

**Figura 1: modelo relacional de datos**



La figura 1 muestra todos los datos del POS con que se cuenta para el análisis.

Cabe destacar que se hizo un pre-análisis de los datos y se descartaron todos los productos que estuvieron con quiebre de stock durante todo el período de medición y además que no tuvieran ventas durante los últimos dos meses, estos serían productos que fueron eliminados del surtido pero que todavía estaban en el maestro de productos.

## 4. MODELOS PREDICTIVOS DE QUIEBRES DE STOCK

### 4.1 Objetivos de los modelos

El objetivo principal de los modelos que se mostrarán a continuación es poder predecir cuándo se producirá un quiebre de stock de manera de poder tomar medidas al respecto.

Si bien se quiere poder predecir un quiebre, estos modelos también sirven para hacer un análisis de lo que está ocurriendo con las categorías a nivel mas global, por ejemplo en una semana. Esto quiere decir detectar los quiebres que hubo durante esa semana, y poder calcular indicadores de disponibilidad (nivel de servicio, ventas perdidas etc) y comparar el desempeño de las categorías.

### 4.2 Elección de las variables

La información con que se cuenta son los datos transaccionales, proporcionados por el supermercado y los datos de la medición en sala antes mencionada.

La variable que se desea predecir, es disponibilidad para cada SKU. Esta es una variable binaria que vale uno si existe quiebre de stock o cero en caso contrario.

Para cada día producto, se calcularon las siguientes variables, todas derivadas del POS, y que pasarán a ser las variables predictivas (o variables de entrada) para los modelos.

$$[1] \text{ Unidades vendidas día anterior} = V_{t-1}$$

$$[2] \text{ Unidades vendidas mismo día semana anterior} = V_{t-7}$$

$$[3] \text{ Unidades vendidas promedio semana anterior} = \left( \frac{\sum_{s=1}^7 V_{t-s}}{7} \right)$$

$$[4] \text{ Unidades vendidas promedio últimos 30 días} = \left( \frac{\sum_{s=1}^{30} V_{t-s}}{30} \right)$$

$$[5] \text{ Crecimiento de las venta} = \frac{\text{unidades vendidas diaria promedio ultima semana}}{\text{unidades vendidas diaria promedio ultimo mes}}$$

$$[6] \text{ Coeficiente de variación de las ventas (semana anterior)} = \frac{\sigma_{semana}}{\mu_{semana}}$$

$$[7] \text{ Coeficiente de variación de las ventas (mes anterior)} = \frac{\sigma_{mes}}{\mu_{mes}}$$

[8] Historial de quiebres semanal , % días con ventas= 0 últimos 7 días

[9] Historial de quiebres mensual, % días con ventas=0 últimos 30 días

[10] Variables dummies para los días de la semana.

[11] Variables dummies para los proveedores de los SKU's. Variable que tomará el valor 1 si un sku pertenece al proveedor x y 0 sino.

Se creó una base de datos con todas las variables antes mencionadas, es decir, para cada día-producto se tiene su disponibilidad, demanda del día anterior, etc.

Se normalizaron las variables de acuerdo a la media y la varianza de cada SKU. Esto quiere decir que para cada SKU se calculó la media y desviación estándar histórica de las ventas (3 últimos meses), y se normalizó con respecto a estos valores todas las variables de ventas absolutas (unidades vendidas día anterior, semana anterior, mes anterior y mismo día semana anterior).

#### **4.3 Descripción y elección de los modelos de predicción**

Para este trabajo, se utilizaron modelos de regresión logística y árboles de decisión. La razón por la cual se optó por ellos, es por la simplicidad con que se pueden aplicar a diferentes datos una vez ya creado el modelo.

En el caso de los árboles de decisión los resultados son reglas de clasificación para quiebres, en cambio para la regresión logística, el resultado es una función de probabilidad de ocurrencia de un evento (en este caso será si existe quiebre o no).

Los modelos fueron generados mediante el programa computacional Clementine 12.0. Este ofrece una interfaz simple para el modelamiento y para la posterior comparación de los modelos, además de contar con todas las herramientas estadísticas y de análisis necesarias para este trabajo.

Para cada categoría en estudio (leches líquidas y pañales desechables) se realizaron varios modelos de arboles (CHAID, CART y C5) y uno de tipo regresión logística. Para todos los casos se hizo la prueba de hacer los modelos con y sin las variables proveedores, de esta manera se puede ver si los proveedores de cada producto tienen relación con que existan o no quiebres de éste.

El resultado que entregan los modelos, es la probabilidad de que un día-producto este en estado FMG. Es por esto, que para ver el desempeño de los modelos, es necesario fijar un parámetro de corte de la probabilidad para poder crear una tabla de confusión del modelo. Por ejemplo, si se decide que el corte será en 0,5, entonces todos los días-

producto con probabilidad mayor o igual a esta de ser quiebre, se pronosticará que lo son y el resto no.

De esta manera se puede crear un tabla de confusión para el modelo como la que se muestra en la tabla 5 en donde “1” significa quiebre y “0” no-quiebre.

**Tabla 6: Tabla de confusión**

		Pronóstico		Eficiencia
		0	1	
Real	0	a	b	$\frac{a}{a+b}$
	1	c	d	$\frac{d}{c+d}$
Eficacia		$\frac{a}{a+c}$	$\frac{d}{b+d}$	

Error tipo I (arrow pointing to cell 'b')  
 Error tipo II (arrow pointing to cell 'c')

Fuente: Elaboración Propia

A partir de la tabla 5, se definen indicadores de desempeño del modelo: eficiencia y eficacia para cada clase (quiebre y no-quiebre). La eficiencia en el caso de la clase “1” es el porcentaje de quiebres dentro del total que detecta el modelo, mientras que la eficacia es el porcentaje del total de los quiebres pronosticados lo son realmente. Esto quiere decir que cuando se predice que un día-producto se encuentra en estado de quiebre, que tan verídico es. Esto es análogo para la clase no-quiebre.

Se define como Error tipo I, cuando el modelo pronostica que un día-producto será quiebre cuando realmente no lo es. En este caso se estaría incurriendo en un costo que consiste en mandar una persona a reponer en vano.

Al mismo tiempo, el Error tipo II, se da cuando el modelo predice que un día-producto está disponible cuando realmente no lo está. Este error llevaría a un costo de ventas perdidas.

Cada vez que se varía el corte de la probabilidad, se tiene asociado un costo total distinto, por lo que se puede graficar una curva de costos y encontrar el corte en donde este se minimiza. Se tendrán curvas de costos para cada uno de los modelos propuestos y el elegido será aquel que presente el menor costo asociado.

Para la estimación de los costos de las ventas perdidas (Error tipo II), se supuso que si existía quiebre en un producto, entonces lo que se dejaría de ganar sería:

Venta perdida = Monto promedio diario SKU \* %Margen supermercado \* Índice de ventas perdidas por FMG

Donde:

- Monto promedio diario SKU = es el promedio de los montos históricos diario (últimos tres meses) de los días-productos que tuvieron venta distinta de cero, para cada una de las categorías.
- % margen supermercado = margen por ventas del supermercado.
- Índice de ventas pérdidas x FMG = representa el porcentaje de los consumidores que no compran al momento de encontrarse con un quiebre de stock. (32%[7]).

**Tabla 7: Monto promedio diario por SKU por categoría**

Categoría	Monto promedio diario x sku
Leche Liquida	\$ 28,000
Pañales Desechable	\$ 11,500
Margarina	\$ 16,000
Leche en polvo	\$ 7,000

Fuente: Elaboración Propia

**Tabla 8: Valor venta perdida por categoría**

Categoría	Valor venta perdida
Leche Liquida	\$ 717
Pañales Desechable	\$ 294
Margarina	\$ 410
Leche en polvo	\$ 179

Fuente: Elaboración Propia

Para el costo de Error tipo I, se hace el supuesto que para que un SKU esté siempre disponible, el reponedor tendría que revisarlo 3 veces en un día. En tiempo serían 15 minutos diarios sólo en ese SKU. Por lo que el costo asociado a este tipo de error sería el valor de 1/4 hora-hombre. (\$350 aproximado). Entonces:

Costo total = Error tipo I \* Costo (1/4)HH + Error tipo II \* Costo ventas perdidas

#### 4.3.1 Elección del modelo para Leches líquidas

Se corrieron distintos modelos de Árboles de Decisión y Regresión Logística con los datos de esta categoría. En este caso se contaba con 1594 registros (días - producto) los cuales se separaron en dos particiones: una de entrenamiento y otra de prueba. La primera con el 80% de los datos y la segunda con el 20% restante.

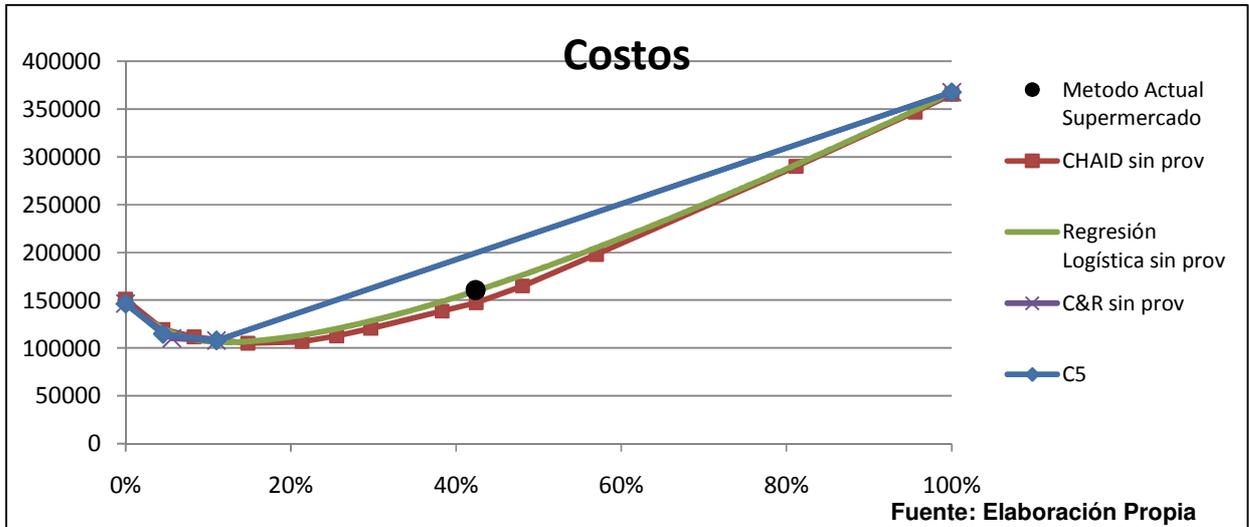
**Tabla N° 9: Características de los modelos de tipo “Árboles de Decisión”**

LECHES LÍQUIDAS	Árboles		
Características	CHAID sin proveedores	C&R Sin proveedores	C5 sin proveedores
Profundidad	3	2	4
N° de registros	1263	1263	1263
Mínima cantidad de registros en nodo parental	4%	3%	3%
Mínima cantidad de registros en nodo hijo	3%	2%	2%
Criterio de separación	Método CHAID : Pearson	Medida de impureza: Gini	Information Gain
Variable a predecir	Quiebre	Quiebre	Quiebre
Variables predictivas usadas	Unidades Vendidas día anterior, Unidades vendidas promedio semana anterior, Desviación estándar ventas semana anterior, % días venta=0 últimos 7 días, % días venta=0 últimos 30 días	Desv/Med últimos 30 días % días venta=0 últimos 7 días	Unidades Vendidas día anterior, % días venta=0 últimos 7 días

Fuente: Elaboración Propia

Para elegir el mejor modelo para esta categoría, se graficaron las curvas de costos para todos ellos. Posteriormente, se procedió a encontrar el punto en que se minimice el costo de errar en el pronóstico para cada uno.

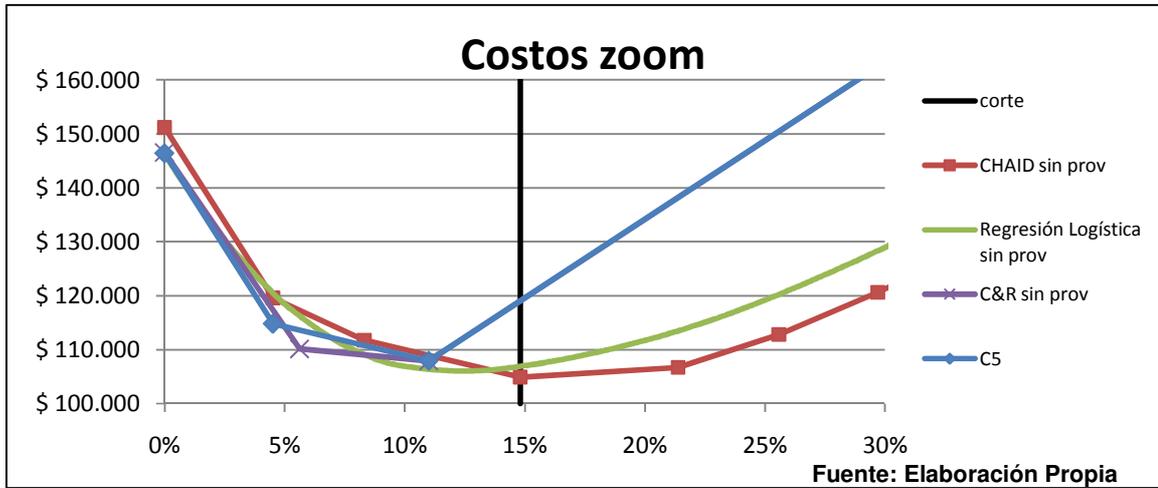
**Grafico 9: Curva de costos modelos leches liquidas**



El gráfico 9 muestra el costo monetario que generan los errores de predicción de cada modelo en particular versus el porcentaje de todos los datos que cada uno de ellos pronostica que son quiebres. Por ejemplo, si se dice que el 20% del total de los datos con mayor probabilidad serán quiebres, entonces para el modelo CHAID sin proveedores (curva roja), el costo asociado será \$100.000 aproximadamente.

El punto negro que aparece en el gráfico anterior, corresponde al modelo actual aplicado por el supermercado. Consiste en que si el día anterior no hubo ventas de un SKU determinado, entonces al día siguiente existirá un quiebre para éste. Este modelo predice que el 43% de los registros son quiebres, siendo que la tasa real de quiebres de los datos es 16,67%, lo que habla que el modelo tiende a pronosticar una gran cantidad de quiebres cuando en verdad no lo son, lo que genera un costo monetario extra (debido a la ocurrencia de errores tipo I).

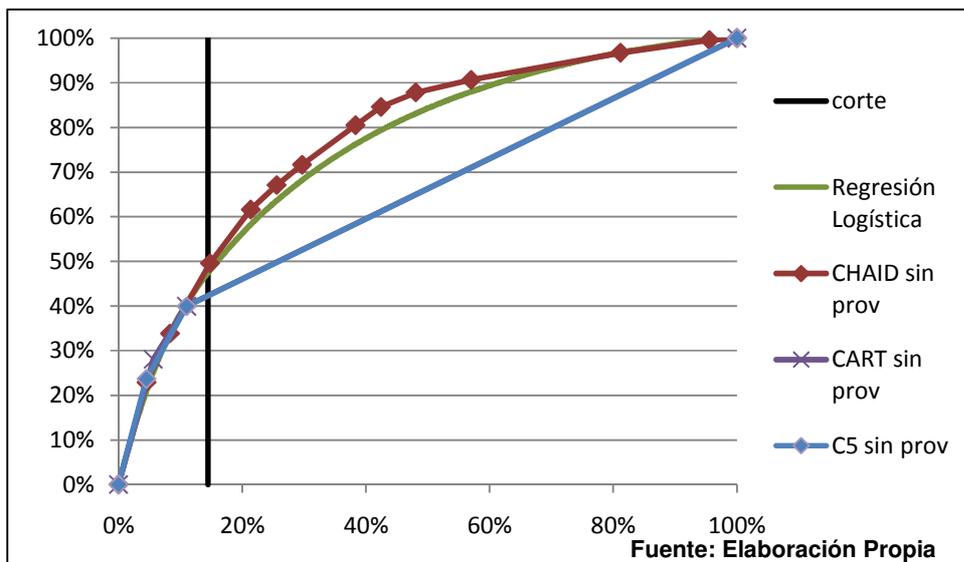
**Gráfico 10: Curva de costos modelos leches liquidas**



El gráfico 10 consiste en una ampliación del gráfico 8. En él, se puede apreciar qué punto minimiza los costos para cada modelo. En este caso, este valor se encuentra en (14,8%, \$104.919) que corresponde al árbol CHAID sin proveedores (curva roja).

Para que el modelo prediga que un 14,8% de los registros sean quiebres, entonces el parámetro de corte para la probabilidad debe ser 32% (para el modelo CHAID sin proveedores).

**Gráfico 11: Curva de ganancia del modelo escogido**



En el gráfico anterior, se puede ver la ganancia de los modelos, dependiendo de la cantidad de registros que se definan como quiebres. El corte que se hace es en el mismo valor del eje X que en el gráfico de costos (14,48%). La ganancia del modelo CHAID ese punto es de un 51%, esto quiere decir que si el modelo predice como quiebre a el 14,48% de los registros con mayor probabilidad de quiebre, entonces encontrará el 51% de los quiebres totales.

**Tabla 10: Resumen modelos**

Partición de Entrenamiento					
Modelo	Costo	Clase: Quiebre		Clase: No-Quiebre	
		Eficiencia	Eficacia	Eficiencia	Eficacia
CHAID sin prov	\$ 99,435	51%	56%	92%	91%
Reg Logistica sin prov	\$ 100,309	48%	59%	94%	90%
C5	\$ 107,241	40%	59%	95%	89%
CART sin prov	\$ 107,241	40%	59%	95%	89%
Modelo actual	\$ 160,609	79%	30%	65%	94%

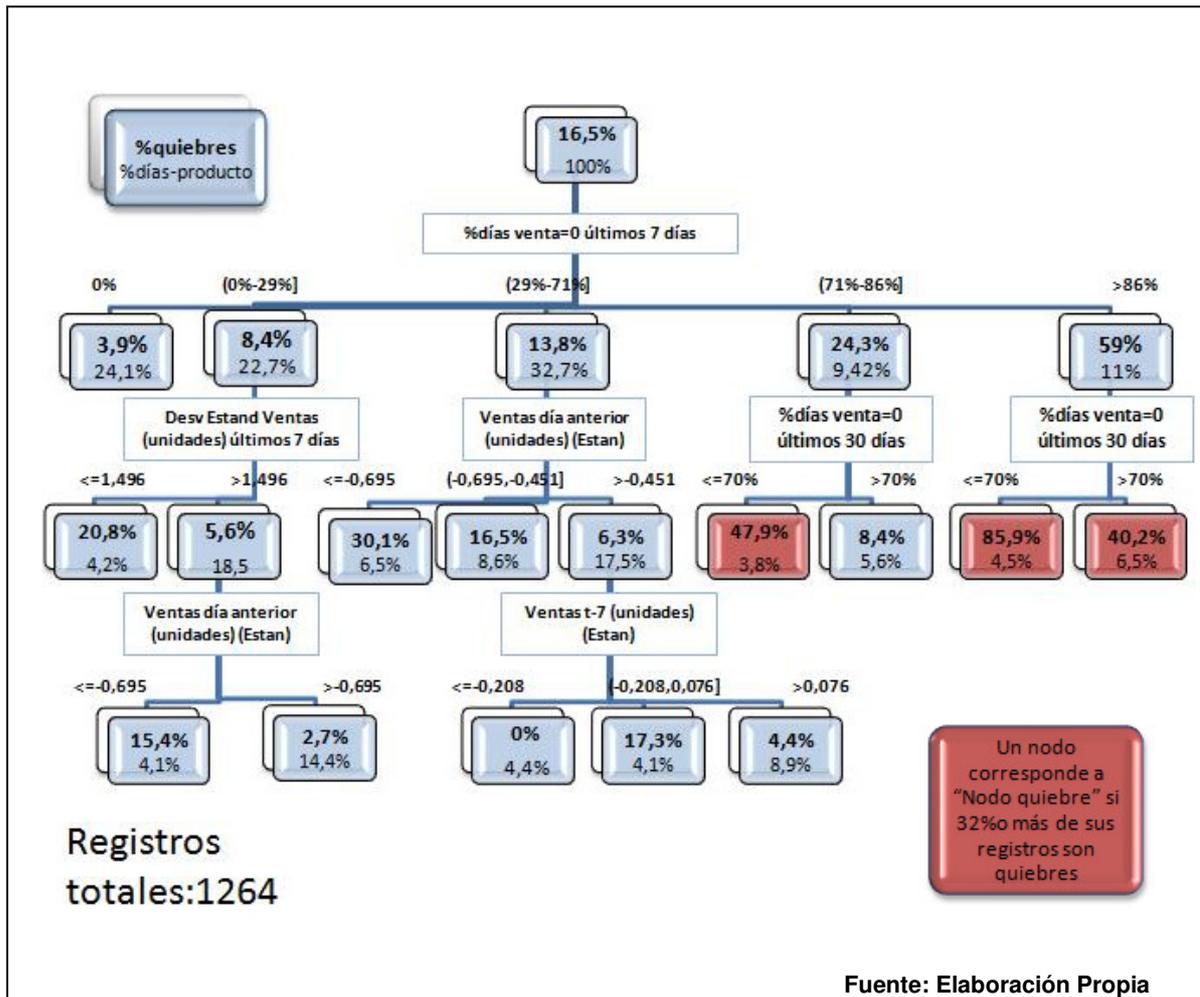
Partición de Prueba					
Modelo	Costo	Clase: Quiebre		Clase: No-Quiebre	
		Eficiencia	Eficacia	Eficiencia	Eficacia
CHAID sin prov	\$ 29,053	53%	49%	89%	90%
Reg Logistica sin prov	\$ 29,490	45%	52%	92%	89%
C5	\$ 28,448	45%	56%	93%	89%
CART sin prov	\$ 28,448	45%	56%	93%	89%
Modelo actual	\$ 45,432	75%	29%	63%	93%

Fuente: Elaboración Propia

En la tabla 9 se puede ver la eficiencia y eficacia para ambas clases (quiebre y no quiebre) en el punto que minimiza el costo para cada modelo. El valor de los costos para los modelos propuestos se mueven en torno a \$29.000 aproximadamente (partición de prueba), mientras que el costo del modelo actual del supermercado es bastante más alto (\$45.432, un 56% más costoso).

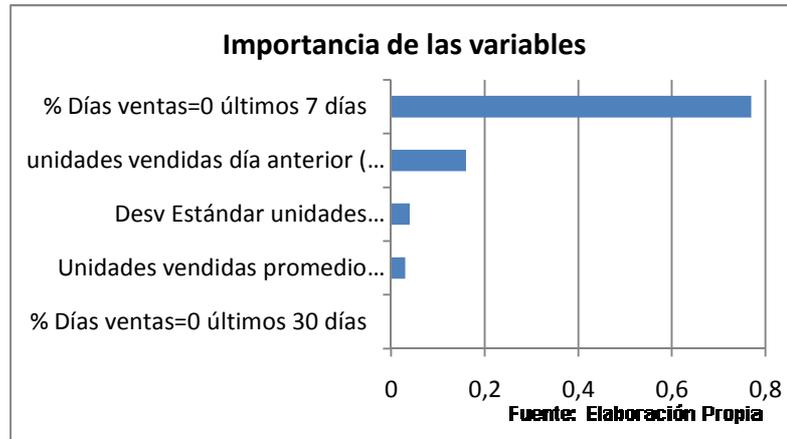
Finalmente, el modelo escogido para esta categoría fue el árbol CHAID que no incluye las variables de proveedores, debido a que el costo de los errores se minimiza.

**Diagrama 2: Árbol Final Leches Líquidas**



El diagrama 2 muestra el modelo final para leches líquidas. Se puede observar que las hojas que finalmente son definidas como quiebres, tienen valores de la variable “días venta=0 últimos 7 días” mayores a 71%, lo cual habla que todos los quiebres que se detectan son de SKU que no han tenido ventas en varios días de la última semana, por lo que se infiere que son productos con mala reposición o baja rotación.

**Gráfico 12: Importancia de las variables**



El gráfico 12 se obtiene a partir del modelamiento en el software Clementine. En él, se puede analizar la importancia relativa de las variables. La variable más relevante para la predicción es “% Días venta=0 ultimos 7 días”, tal cual cómo se había indicado en el análisis del diagrama anterior.

**Tabla 11:Tablas de confusión modelo final**

**Partición de Entrenamiento**

Real	Predicción		Eficiencia
	0	1	
0	977	82	92%
1	99	105	51%
<b>Eficacia</b>	91%	56%	

% de registros que se predicen quiebre

= 15%

% quiebres totales = 16%

**Partición de Prueba**

Real	Predicción		Eficiencia
	0	1	
0	245	30	89%
1	26	29	53%
<b>Eficacia</b>	90%	49%	

% de registros que se predicen quiebre

= 18%

% quiebres totales = 17%

Fuente: Elaboración Propia

Analizando la eficiencia y eficacia para ambas particiones de la Tabla 10, en el caso de predicción de la clase 1 (quiebres) se puede apreciar que el modelo no detecta varios casos de quiebre al momento de ejecutarse, pero los casos que sí predice, los realiza con una alta probabilidad de ocurrencia.

#### 4.3.2 Elección del modelo para Pañales Desechables.

Para esta categoría se corrieron cuatro modelos: 3 árboles de decisión y una regresión logística.

Se midieron 786 registros, los cuales se dividieron en una partición de entrenamiento y otra de prueba para realizar la predicción. Cada una de la misma forma que en la categoría leches líquidas. ( 80% y 20% del tamaño total de la muestra).

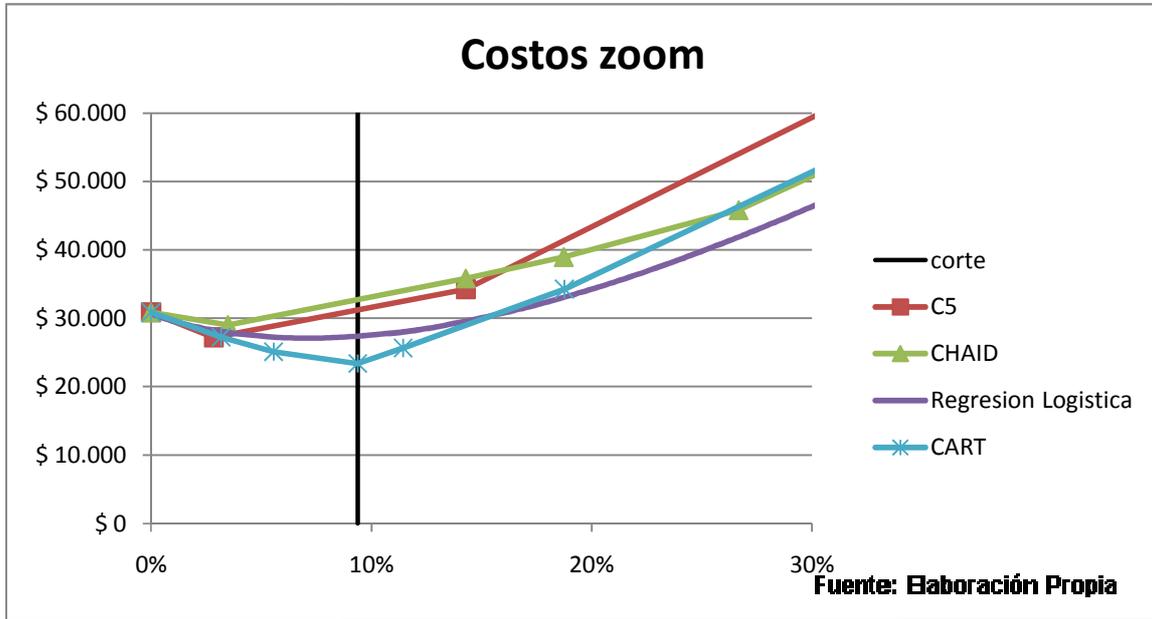
**Tabla N° 12: Características de los modelos de tipo “Árboles de Decisión”**

PAÑALES DESECHABLES	Árboles de Decisión		
Características	CHAID	C&R	C5
Profundidad	2	4	3
N° de registros	630	630	630
Mínima cantidad de registros en nodo parental	4%	3%	3%
Mínima cantidad de registros en nodo hijo	3%	2%	2%
Criterio de separación	Método CHAID : Pearson	Medida de impureza: Gini	Information Gain
Variable a predecir	Quiebre	Quiebre	Quiebre
Variables predictivas usadas	Desv/med últimos 7 días, Proveedor 1, Proveedor 2, Proveedor 3, Unidades vendidas promedio últimos 30 días	Desv/med últimos 7 días, Proveedor 3, Proveedor 2, Unidades vendidas promedio últimos 7 días, Unidades vendidas promedio últimos 30 días, Desviación estándar ventas últimos 30 días, Desv/med últimos 30 días	Proveedor3, Unidades Vendidas promedio últimos 30 días, % días venta=0ultimos 7 días

Fuente: Elaboración Propia **32**

Siguiendo la metodología empleada en la categoría anterior, se buscó minimizar los costos en los errores de pronóstico de cada modelo.

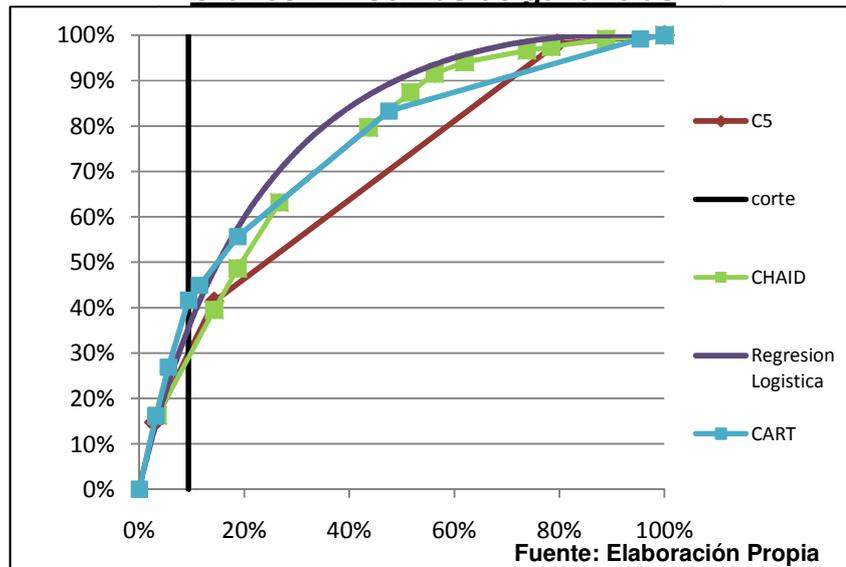
**Gráfico 13 : Costo error de pronóstico**



El punto en que se minimizan los costos es (9,38% , \$23.370) correspondiente al modelo CART (curva azul del gráfico).

Para que el modelo prediga que un 9,38% de los registros sean quiebres, entonces el parámetro de corte para la probabilidad debe ser 50% (para el modelo CART).

**Gráfico 14: Curvas de ganancias**



Para esta categoría el modelos escogido tiene una ganancia del 44% para el corte del 9,38%, por lo tanto si el modelo predice que el 9,38% de los registros con mayor probabilidad de quiebre se definirán como quiebres, entonces se encuentran el 44% de los quiebres totales.

**Tabla 13: Resumen modelos**

Partición de Entrenamiento					
Modelo	Costo	Clase: Quiebre		Clase: No-Quiebre	
		Eficiencia	Eficacia	Eficiencia	Eficacia
CART	\$ 21,857	44%	78%	98%	90%
Reg Logistica	\$ 26,479	33%	67%	97%	88%
C5	\$ 26,860	15%	89%	100%	85%
CHAID sin prov	\$ 24,855	23%	89%	99%	87%
Modelo actual	\$ 113,874	89%	23%	39%	95%

Partición de Prueba					
Modelo	Costo	Clase: Quiebre		Clase: No-Quiebre	
		Eficiencia	Eficacia	Eficiencia	Eficacia
CART	\$ 5,157	46%	80%	98%	90%
Reg Logistica	\$ 7,268	23%	60%	97%	86%
C5	\$ 6,521	19%	83%	99%	86%
CHAID sin prov	\$ 6,174	19%	100%	100%	86%
Modelo actual	\$ 25,972	96%	25%	44%	98%

Fuente: Elaboración Propia

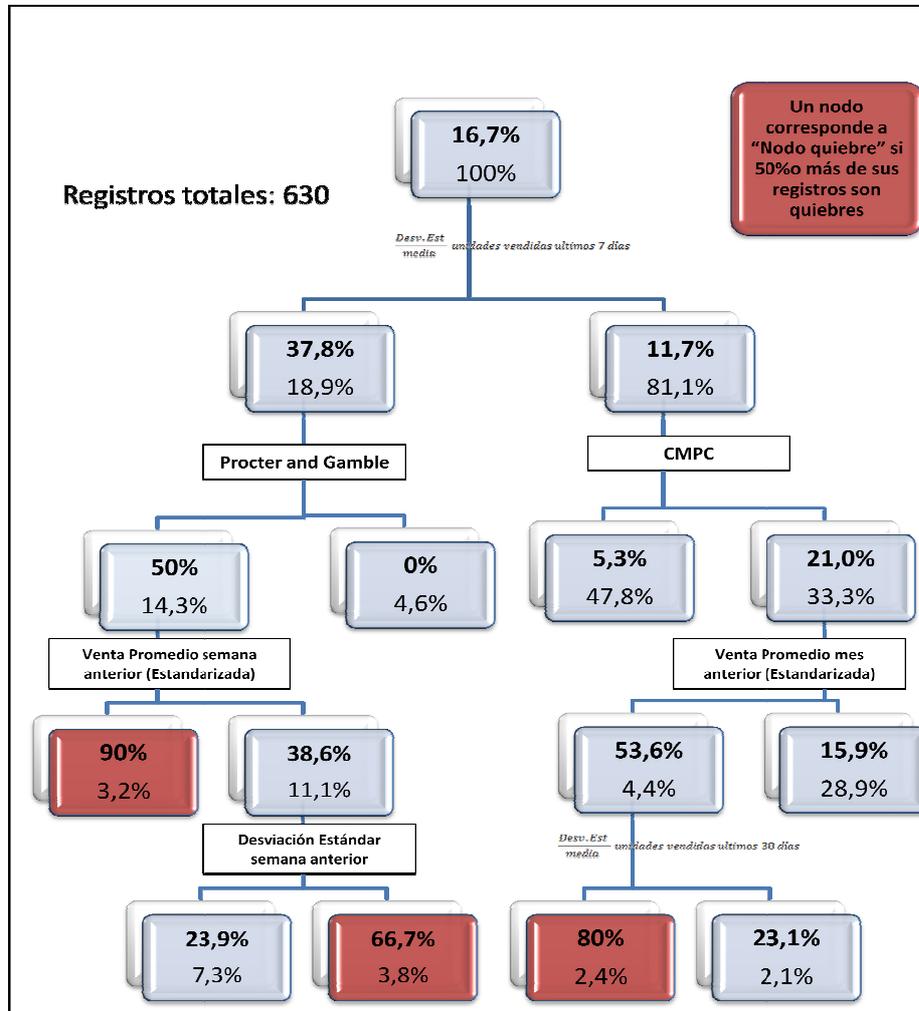
En la tabla 12 se puede ver la eficiencia y la eficacia para ambas clases (quiebre y no quiebre) en el punto en que se minimiza el costo para cada modelo.

El valor de los costos para los modelos propuestos se mueven en torno a \$6.200 aproximadamente (partición de prueba), mientras que el costo del modelo actual del supermercado es bastante más alto (\$25.972, un 314% más caro).

Enfocándose en la diferencia de costos entre los modelos planteados versus el utilizado actualmente por el supermercado, tiene sentido que para los pañales se haya obtenido un valor mucho más alto (314%) con respecto al de la categoría “Leches Líquidas” (52%). Esto se debe a que una categoría es de alta rotación (leches líquidas), mientras que la otra no lo es (pañales), lo que provoca que cuando el modelo actual utilizado por el supermercado predice un quiebre de leches, es más probable que lo sea realmente, no así en los pañales, ya que el modelo se basa en si las ventas del día anterior es 0, en el caso de pañales en escasas ocasiones significa que habrá quiebre.

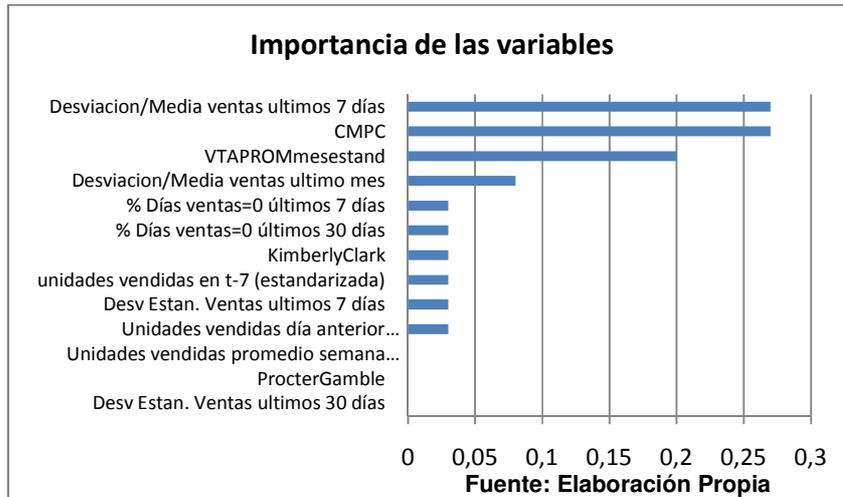
Finalmente, el modelo escogido para esta categoría fue el árbol CART, debido a que el costo de los errores se minimiza.

**Diagrama 3: Arbol final categoría Pañales Desechables**



Fuente: Elaboración Propia

**Gráfico 15 : Importancia de las variables modelo escogido**



A diferencia del modelo de leches líquidas, en que la variable más importante fue el porcentaje de días en que existieron ventas = 0 en la última semana, en este caso el modelo no toma en cuenta dicha variable, ya que como es una categoría de baja rotación, la presencia de días sin ventas era esperable.

Como se puede apreciar en el gráfico de importancia de las variables y en el diagrama del árbol de pañales desechables, la variable más importante al momento de dividir es el coeficiente de variación de las unidades vendidas de la última semana (desviación/media), en otras palabras, como se mueven las ventas durante dicho período.

**Tabla 14: Tablas de confusión modelo final**

**Partición de Entrenamiento**

Real	Predicción		Eficiencia
	0	1	
0	512	13	98%
1	59	46	44%
<b>Eficacia</b>	<b>90%</b>	<b>78%</b>	

% de registros que se predicen quiebre = 9%  
 % quiebres totales = 17%

**Partición de Prueba**

Real	Predicción		Eficiencia
	0	1	
0	128	3	98%
1	14	12	46%
<b>Eficacia</b>	<b>90%</b>	<b>80%</b>	

% de registros que se predicen quiebre = 10%  
 % quiebres totales = 17%

Fuente: Elaboración Propia

Con respecto a la tabla 8, este modelo presenta una alta eficacia en su predicción de quiebres para la categoría de pañales desechables.

#### 4.4 Generalización de los modelos

Para comprobar si los modelos antes expuestos, pueden ser generalizables a otras categorías del supermercado, durante el estudio en sala se midieron otras dos categorías: margarinas, y leches en polvo. Posteriormente se evaluó el desempeño de los modelos en estas nuevas categorías.

También se desarrollaron modelos particulares para cada una de las nuevas categorías. De esta manera, poder comparar los resultados ocupando los modelos anteriores (para Leches líquidas y Pañales) versus utilizando los específicos para cada nueva categoría.

Para la categoría margarinas, el modelo usado fue un CHAID, mientras que para las leches líquidas fue un C5. En la sección “Anexo 3” se encuentran disponibles los detalles de estos modelos.

**Tabla 15: Comparación de resultados para Margarinas**

Entrenamiento					Prueba				
Modelos	% quiebres	Costo	Eficiencia	Eficacia	Modelos	%quiebres	Costo	Eficiencia	Eficacia
Modelo leches líquidas	7%	\$ 13,121	36%	48%	Modelo leches líquidas	10%	\$ 3,375	60%	55%
Modelo pañales desechables	3%	\$ 16,937	3%	8%	Modelo pañales desechables	3%	\$ 5,141	0%	0%
Modelo margarinas	10%	\$ 7,854	73%	67%	Modelo margarinas	11%	\$ 2,965	70%	58%
Modelo actual supermercado	24%	\$ 28,232	61%	23%	Modelo actual supermercado	30%	\$ 9,085	90%	26%

Fuente: Elaboración Propia

La tabla 14 muestra los resultados que se obtuvieron al ocupar los modelos de las categorías: Leches líquidas y Pañales desechables, para predecir las Margarinas, como también los resultados del modelo específico para esta categoría y el modelo del supermercado, esto para la clase Quiebre.

El modelo que mejor predice los quiebres de stock, y a la vez, el que presenta menores costos, es el modelo específico para margarinas. En segundo lugar esta el de leches líquidas que es un 52% más costoso, pero comparado con el de pañales desechables, es bastante mejor, ya que el resultado del modelo de éste último, la eficiencia y eficacia es 0% en la partición de prueba.

**Tabla 16: Comparación de resultados para Leches en Polvo**

Entrenamiento					Prueba				
Modelos	% quiebres	Costo	Eficiencia	Eficacia	Modelos	% quiebres	Costo	Eficiencia	Eficacia
Modelo leches líquidas	24%	\$ 24,557	48%	21%	Modelo leches líquidas	19%	\$ 4,891	40%	27%
Modelo pañales desechables	8%	\$ 10,553	21%	29%	Modelo pañales desechables	7%	\$ 2,294	30%	50%
Modelo leches en polvo	12%	\$ 7,700	64%	57%	Modelo Leche en polvo	14%	\$ 2,977	50%	45%
Modelo actual supermercado	56%	\$ 53,446	55%	23%	Modelo actual supermercado	56%	\$ 12,883	60%	27%

Fuente: Elaboración Propia

En el caso de las Leches en polvo, se da el caso inverso al de las Margarinas, ya que el segundo modelo que mejor predice es el de pañales desechables, con un costo incluso inferior al del modelo específico para la categoría (-23%) en la partición de prueba.

Los resultados de estas pruebas fueron los esperables, debido a que siendo Margarinas una categoría de rutina pero con alta rotación, se esperaba que el modelo que mejor se adaptase a ella fuera el de Leches líquidas. De la misma manera, Leches en polvo es una categoría de baja rotación y el modelo que mejor se ajustó a ella fue el de Pañales desechables.

Para estas dos categorías, el modelo actual del supermercado es bastante más costoso que cualquiera de los propuestos, en el caso de Margarinas es un 200% mayor que el costo del modelo específico para esa categoría, mientras que para Leches en polvo llega a ser un 300% mayor.

Como conclusión, el rol de cada categoría afecta en el tipo de modelo que se debe emplear para detectar los quiebres.

**Tabla 17: Costos por errores de pronósticos mensuales**

Categoría	Costo Mensual Modelo específico	Costo mensual modelo rol	Diferencia Mensual
Margarinas	\$ 32,457	\$ 49,488	\$ 17,031
Leches en polvo	\$ 32,031	\$ 38,541	\$ 6,510

Si se hace el supuesto de que hacer un modelo nuevo tiene un costo de \$250.000 entre la modelación y la implementación, entonces se podría hacer un análisis del período de recuperación del capital invertido<sup>3</sup> en hacer un modelo nuevo versus ocupar un solo modelo por rol.

De esta manera el período de recuperación de capital para la categoría margarinas sería 14 meses<sup>4</sup> aproximadamente, mientras que para leches líquidas este valor ascendería a 38 meses (más de 3 años).

Para el caso de la categoría Margarinas, el costo de usar el modelo de leches líquidas versus uno específico para la categoría es un 52% mayor, y el período de recuperación del capital invertido en el caso de hacer un modelo específico para la categoría sería de 14 meses. Es por esto que para esta categoría es recomendable hacer un modelo específico ya que esta categoría es importante para el supermercado.

Por otro lado, para el caso de Leches en polvo, el ocupar el modelo de Pañales desechables para predecir, es solo un 20% más costoso que con el modelo específico de la categoría. El período de recuperación del capital de hacer un modelo específico para leches en polvo sería de 38 meses, por lo que no se justifica hacer un modelo específico para esta categoría.

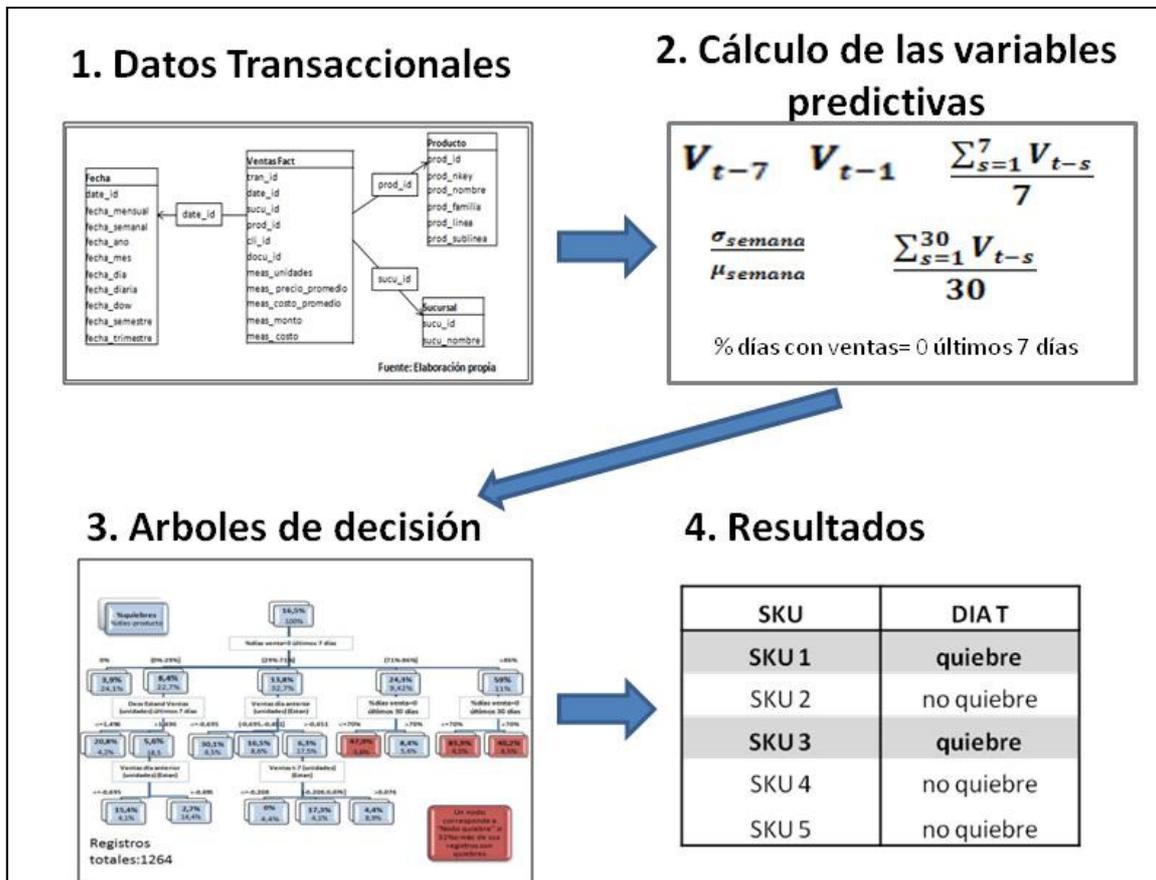
En resumen para categorías de destino es recomendable hacer un modelo por categoría mientras que para las categorías de conveniencia es mejor utilizar un solo modelo para todo el rol.

<sup>3</sup> *Período de recuperación de capital (meses)* =  $\frac{\text{Costo hacer un nuevo modelo}}{\text{Ahorro mensual por usar nuevo modelo}}$

<sup>4</sup>  $250000/17031 \approx 14$

## 5. METODOLOGÍA PARA LA IMPLEMENTACIÓN DE LOS MODELOS.

Para la implementación de los modelos antes propuestos hay que seguir los siguientes pasos:



1. Obtener la información de las ventas por SKU (unidades vendidas) desde t-30 hasta t-1, siendo t el día en que se quiere pronosticar si existirá un quiebre de stock, también se necesita saber el proveedor del SKU.
2. Con la información anterior se procede a calcular las variables predictivas que se describen en el capítulo 4.
3. Luego dependiendo de la categoría a la cual pertenezca cada SKU se define el árbol de decisión que se necesita utilizar. Si la categoría es de conveniencia se utilizaría el árbol creado para Pañales Desechables, mientras que si la categoría es de destino se usará el árbol de Leches Líquidas, menos para la categoría de margarinas para la cual se cuenta con un árbol específico.
4. Siguiendo las reglas de decisión y las definiciones de las hojas que finalmente son definidas como quiebre, se obtiene el resultado de si un SKU X tendrá quiebre en el día t.

## 6. CONCLUSIONES

El rol de una categoría, dentro de un supermercado, juega un papel importantísimo en el manejo operacional que se le debe dar a ésta. Las categorías de destino del supermercado, son categorías con alta presencia en boleta. Son de alta rotación, son la razón de la visita del consumidor al supermercado, entonces lograr tener una buena disponibilidad de los productos en góndola, es fundamental para mantenerlos satisfechos.

Por otro lado, aunque las categorías de conveniencia no tienen presencia en boleta como la categoría de destino, no es recomendable dejarlas de lado, ya que gracias son en estas categorías en las cuales los márgenes de venta son mayores.

Se identificaron variables del POS, de las cuales se logró introducir nuevas variables para crear modelos específicos de predicción de quiebres para cada categoría en análisis. Las variables más importantes en los modelos fueron el porcentaje de días que las ventas eran igual a cero la última semana para el caso de las leches líquidas y el cociente entre la desviación estándar y la media de las unidades vendidas en los últimos siete días para el caso de los pañales desechables. En este último caso también fueron importantes las variables de los proveedores.

Con los nuevos modelos propuestos, se logra reducir el costo asociado al error de pronóstico que genera el modelo actual del supermercado, en el caso de las leches líquidas el costo disminuye en un 35% mientras que para la categoría de pañales desechables este se reduce en más de un 80% por lo que la implementación de los modelos sería un aporte para la sala en estudio.

Con respecto a la cantidad de quiebres que se detectan, los modelos detectan menos quiebres (o sea la eficiencia es menor), pero existe una mayor precisión en la detección de quiebres esto quiere decir que del total que se predice como quiebre un mayor porcentaje son quiebres realmente (alta eficacia). Todo esto en comparación al modelo actual del supermercado.

Como recomendación, se puede decir que para las categorías de destino se justifica hacer un modelo para cada una, ya que éstas son las más importantes del supermercado, y por tanto el monto por ventas perdidas por cada quiebre de stock que no se encuentre, es bastante superior a alguno que ocurra en otra categoría.

En el caso de las categorías de conveniencia, la disminución de los costos de errores de pronóstico, usando un modelo específico para la categoría, versus usar el modelo de pañales desechables, no justifica hacer un modelo específico por categoría. Por esto se recomienda que para estas categorías, usar un sólo modelo que sea el de Pañales Desechables.

La implementación de los modelos propuestos se puede llevar a cabo siempre y cuando se cuente con la información disponible de las unidades vendidas de cada producto desde el día anterior al cual se quiere ser pronosticado, hasta 30 días antes de este, así como también la descripción de cada SKU, categoría a la que pertenece y proveedor. De esta manera se pueden calcular las variables predictivas para los modelos y utilizar los árboles de decisión para definir si en un determinado día-producto se producirá un quiebre o no, así poder alarmar al supermercado acerca de este posible suceso para que se tomen las medidas correspondientes.

Como trabajos futuros se puede dejar pendiente la implementación de los modelos ya que esto requiere de programación computacional para la automatización de estos. Se recomendaría partir usando los modelos para la sala en que se hizo el estudio y evaluar después de un tiempo el desempeño de estos, haciendo nuevas mediciones. Si se considera que se está logrando los resultados esperados, o sea disminuir los quiebres de stock, entonces los modelos podrían ser aplicados en otra sala.

También se podrían identificar las categorías más importantes para la cadena para así hacer modelos específicos para cada una de esas categorías, para eso se necesitaría hacer también nuevas mediciones con las cuales se pueda modelar el fenómeno.

Queda pendiente también el hecho de que si bien aquí se detectan los quiebres eso no quiere decir necesariamente que estos van a dejar de ocurrir, ya que hay un tema de inventario detrás que no depende de si se detecta o no el quiebre, sino si es que hay stock disponible en bodega para reponer. Ese es un tema aparte que no están en los alcances de esta memoria y en el cual se puede trabajar, ya que se podría generar una estadística de los SKU que con mayor frecuencia están en estado de quiebre e investigar si esto se debe a mala reposición, un problema con el cálculo del inventario óptimo o problemas directamente con el proveedor del producto.

## 8. BIBLIOGRAFÍA Y FUENTES DE INFORMACIÓN

- [1] Witten, I. & Frank, E. (2005), Data Mining, Practical Machine Learning Tools and Techniques. Second Edition, Morgan Kaufmann.
- [2] Sainz, J. (2005), Detección de faltantes de mercadería en góndolas de supermercado utilizando información del punto de venta, Santiago, Chile.
- [3] Muñoz, R. (2006) Procedimientos para la reducción de faltantes de mercadería en góndola. Santiago, Chile.
- [4] Bosch, M. (2005) La medición de faltantes en góndola. Santiago, Chile.
- [5] Unanue, O. (2006) Estudio y pronóstico de demanda a nivel de SKU para la cadena regional de supermercados Bryc, Santiago, Chile.
- [6] Jove, J. (2006) Estimación de demanda a nivel de SKU utilizando un enfoque basado en atributos: Aplicación al caso supermercados. Santiago, Chile.
- [7] Revista GS1, 2006, Santiago, Chile, Marzo 2006.
- [8] Ledesma, F. (2004) Desarrollo de un modelo de colocación de tarjetas de crédito para BancoEstado. Santiago, Chile.
- [9] Medel, F. (2002) Creación y prueba de una metodología para árboles de decisión en Data Mining dinámico. Santiago, Chile.
- [10] Manual de uso Clementine 12.0
- [11] Asach, Ventas totales de los Supermercados: Indices INE. < [www.asach.cl](http://www.asach.cl)> [consulta 10 febrero 2009]
- [12] Global Property Solutions (2007) Informe Resumen Retail 2007. Santiago, Chile
- [13] AcNielsen, Child (2004): Cambios en el Mercado Chileno 2004: Entendiendo al Consumidor, Santiago, Chile.
- [14] Berry, M.J.A., Linoff G.S. (2004) Data Mining Techniques for Marketing, Sales, and Customer Relationship Management. Second Edition, Indianapolis, Wiley Publishing.
- [15] Fayyad, U., Piatetsky-Shapiro, G. & Smyth, P. (1996) From Data Mining to knowledge discovery in databases.

[16] Hair, J., Anderson, R., Tatham, R. & Black, W. (1999) Análisis Multivariante, 5ta edición, España, Prentice Hall International.

[17] D&S (2008) Memoria anual 2008 [en línea]

<[http://www.dys.cl/admin/upload/DyS\\_mem2008ESP.pdf](http://www.dys.cl/admin/upload/DyS_mem2008ESP.pdf)> [3 julio 2009]

## 9. ANEXOS

### 9.1 Anexo 1: Indicadores de disponibilidad por categoría

CATEGORIA	Cantidad sku en cat.	Presencia	Unidades tot	Monto Total	ventana promedio (días)	ventana maxima (días)	ratio vmax/vprom	ROL	Nivel de servicio
BEBIDA	190	29%	741009	\$ 344.838.800	3,34	14	3,5	DESTINO	65%
<b>LECHE LIQUIDA</b>	<b>105</b>	<b>37%</b>	<b>550944</b>	<b>\$ 249.786.597</b>	<b>3,36</b>	<b>20</b>	<b>4,8</b>	<b>DESTINO</b>	<b>58%</b>
YOGHURT	165	39%	1305524	\$ 138.808.837	5,15	25	4,3	DESTINO	60%
MARGARINA	46	26%	278210	\$ 100.928.339	3,25	12	3,6	RUTINA	73%
GALLETAS	198	26%	564977	\$ 75.508.475	3,50	17	4,2	RUTINA	69%
QUESO	75	21%	114219	\$ 197.282.038	4,09	16	3,6	RUTINA	61%
ACEITES COMESTIBLES	42	22%	246873	\$ 171.150.538	4,48	21	4,5	RUTINA	65%
DETERGENTE	34	19%	349505	\$ 153.780.573	3,45	11	2,8	RUTINA	82%
HARINA	33	11%	45092	\$ 113.237.899	3,32	20	5,2	RUTINA	60%
PAPEL HIGIENICO	21	25%	309349	\$ 111.358.577	3,29	17	3,5	RUTINA	76%
AZUCAR	15	23%	326265	\$ 97.240.724	2,27	6	2,3	RUTINA	79%
ARROZ	40	19%	192149	\$ 95.976.664	3,11	17	4,4	RUTINA	60%
POSTRE REFRIGERADO	59	25%	514067	\$ 94.774.411	3,51	16	3,2	RUTINA	78%
GUISOS	119	20%	295786	\$ 93.217.335	4,25	23	5,4	RUTINA	58%
MANTEQUILLA	15	15%	193414	\$ 65.569.772	3,75	15	3,8	RUTINA	67%
JUGO EN POLVO	39	18%	81308	\$ 61.541.120	2,13	7	2,7	RUTINA	85%
NECTAR	181	20%	148103	\$ 57.372.252	4,94	25	4,7	RUTINA	53%
VIENESAS	41	18%	154398	\$ 53.130.126	4,35	23	4,2	RUTINA	56%
SALSA DE TOMATES	28	19%	258772	\$ 51.642.703	4,50	16	3,6	RUTINA	64%
TE	31	15%	122280	\$ 46.160.462	7,50	21	3,9	RUTINA	66%
CAFE	23	9%	19063	\$ 39.424.818	3,94	19	3,9	RUTINA	71%
CLORO	30	12%	176582	\$ 37.054.557	3,82	19	4,8	RUTINA	62%
JUGO	49	14%	260229	\$ 35.434.952	3,40	14	3,4	RUTINA	61%
BEBIDA LACTEA	31	13%	81820	\$ 33.549.275	3,23	14	3,1	RUTINA	71%
MAYONESA	17	13%	159185	\$ 33.361.155	3,87	20	4,1	RUTINA	75%
CHOCOLATE	125	12%	35280	\$ 33.198.810	4,77	21	4,7	RUTINA	47%
MANJAR	25	12%	66195	\$ 32.340.087	2,99	15	4,3	RUTINA	61%
MERMELADA	37	10%	110837	\$ 29.640.628	4,77	23	3,6	RUTINA	58%
CREMA DE LECHE	23	10%	50407	\$ 28.323.973	3,58	15	3,9	RUTINA	56%
PATE	26	13%	132181	\$ 26.492.241	3,40	23	4,4	RUTINA	68%
TOALLA DE PAPEL	10	9%	111393	\$ 23.316.895	5,71	28	4,4	RUTINA	55%
PAPAS FRITAS	30	11%	161213	\$ 23.059.506	3,41	18	3,4	RUTINA	72%
CIGARRILLO	31	0%	691675	\$ 575.693.950	7,68	14	1,7	CONVENIENCIA	13%
JAMONADA	16	7%	25019	\$ 38.636.018	3,26	20	5,1	CONVENIENCIA	54%
<b>PANALES DESECHABLES</b>	<b>43</b>	<b>7%</b>	<b>15442</b>	<b>\$ 37.379.626</b>	<b>4,54</b>	<b>18</b>	<b>4,1</b>	<b>CONVENIENCIA</b>	<b>40%</b>
SALCHICHON	15	9%	50943	\$ 28.081.988	2,71	17	4,5	CONVENIENCIA	73%
JUREL EN CONSERVA	7	5%	22426	\$ 26.519.560	7,66	25	3,5	CONVENIENCIA	65%
LECHES EN POLVO	40	5%	25405	\$ 24.325.272	3,27	14	4,8	CONVENIENCIA	49%

## 9.2 Anexo 2: Resultados medición en sala

### Primera Medición

- Leches Líquidas

SKU	DIA 1	DIA 2	DIA 3	DIA 4	DIA 5	DIA 6	DIA 7	DIA 8	DIA 9
	stock								
877	100	120	180	0	0	0	0	0	15
878	0	1	1	1	1	0	0	0	0
1260	72	72	150	155	200	200	130	141	200
1261	52	52	144	160	152	150	130	82	94
2451	90	126	126	96	108	324	108	126	102
2452	36	42	30	36	42	30	30	18	18
2454	60	180	96	114	96	144	108	264	258
2500	36	32	36	20	20	42	24	45	21
2501	22	24	24	26	36	36	24	52	43
2829	48	32	40	48	192	42	48	48	67
2830	18	6	6	3	7	3	5	4	4
2834	100	150	144	36	72	72	96	108	90
2837	36	58	60	36	66	60	60	60	60
3437	0	0	0	0	0	0	0	0	0
3438	10	16	15	11	14	14	12	14	10
3439	0	0	0	0	0	0	0	0	0
3935	5	8	1	1	1	1	1	1	25
3936	0	0	0	3	3	0	0	7	20
3937	20	15	20	13	12	17	10	8	16
3938	10	8	3	20	18	18	12	2	13
3939	8	7	7	3	3	3	3	9	7
3940	15	15	14	4	1	14	12	1	0
3943	22	14	24	24	44	24	28	26	17
3950	30	12	12	12	12	12	12	0	0
3955	7	0	0	0	0	0	0	0	0
4322	2	2	2	2	2	2	2	2	2
5844	24	36	36	84	60	120	0	102	200
5852	50	48	42	48	40	42	45	7	1
7035	48	21	21	14	14	14	8	8	1
7036	432	576	492	1104	516	492	216	204	108
7037	200	294	180	144	192	120	168	168	186
7038	0	252	228	144	144	138	228	150	174
7442	100	108	54	54	48	0	0	168	156
7444	24	72	144	0	102	42	18	60	234
8354	672	600	960	912	576	552	408	432	984
8377	20	24	24	28	28	27	20	24	18
9362	30	39	8	8	10	12	22	8	3
9363	2	4	5	17	5	2	12	1	0
9364	20	18	48	20	20	32	22	6	5
9365	36	18	18	12	16	1	9	18	5
9366	240	132	228	132	108	108	31	22	20
9820	180	162	228	324	276	324	258	330	300

SKU	DIA 1	DIA 2	DIA 3	DIA 4	DIA 5	DIA 6	DIA 7	DIA 8	DIA 9
	stock								
9823	180	204	384	114	72	108	78	70	66
9824	240	570	330	360	216	474	186	456	456
9826	24	8	2	0	0	0	0	0	0
9837	288	372	720	672	720	696	702	234	536
9910	1	0	48	32	48	12	48	2	0
9914	336	540	960	450	420	600	504	453	324
9937	5	0	36	54	22	28	0	2	136
9938	20	37	48	22	36	23	14	0	137
9940	120	192	156	138	96	138	126	114	114
9941	120	102	120	216	126	84	84	84	60
9942	12	12	6	0	0	0	0	0	0
9953	0	360	180	84	84	198	168	180	180
9954	50	216	300	61	108	114	318	336	360
9955	50	216	282	168	156	162	138	186	144
9961	0	0	0	0	0	432	432	336	528
9992	0	0	0	0	0	0	0	0	0
9996	0	0	0	0	0	0	0	0	0
10007	50	102	138	78	78	108	168	174	174
10023	20	70	48	42	42	54	48	48	32
10025	50	126	162	78	78	78	138	180	168
10119	0	1	20	5	5	3	0	0	10
10120	0	0	0	0	0	0	0	0	0
10122	0	19	20	14	9	6	4	8	13
10123	0	17	30	15	22	24	10	14	25
10124	12	17	2	15	16	13	20	3	5
10180	13	13	13	10	10	10	10	9	9
10186	12	11	24	10	0	9	15	11	5
10187	0	0	10	3	0	7	0	5	2
10189	0	0	10	10	7	8	20	3	18
10204	288	600	1000	1000	1000	2610	2610		1536
10205	300	324	264	102	420	444	210	210	726
10206	600	1008	1200	1320	588	1320	1140	1284	420
10207	12	236	144	192	192	192	150	99	132
10208	72	66	54	4	108	66	60	120	93
10210	600	1416	1752	1980	2088	1944	2280	1536	1160
10211	144	144	144	84	66	68	42	15	17
10212	30	24	15	15	15	14	10	1	0
10213	720	2304	2160	1536	504	1968	1680	768	0
10215	25	5	53	41	41	26	16	3	3
10216	60	900	168	180	150	186	204	180	144

- Pañales Desechables

SKU	DIA 1	DIA 2	DIA 3	DIA 4	DIA 5	DIA 6	DIA 7	DIA 8	DIA 9
	stock								
8862	3	16	8	4	4	4	8	6	10
1097	0	0	0	0	0	0	0	0	0
8863	10	10	10	17	12	16	15	10	10
1232	6	0	6	4	4	5	3	3	0
3973	0	0	0	0	0	0	0	0	0
9439	8	10	10	7	2	2	16	4	3
9440	5	10	10	4	5	4	16	4	8
8872	2	3	3	0	0	2	3	1	0
8873	3	4	4	4	2	7	5	6	3
8874	2	8	10	0	2	5	10	0	4
9441	0	0	0	12	6	10	10	8	13
5325	0	0	9	1	0	0	16	12	16
5326	40	60	44	40	36	35	36	65	64
2157	8	15	12	5	8	7	9	10	6
2123	7	1	0	8	8	6	5	0	0
1411	0	0	0	0	0	0	0	0	1
1413	30	34	30	26	17	20	30	24	20
1412	0	0	0	0	0	0	0	0	0
9435	10	10	7	8	7	5	5	12	3
8271	10	7	0	8	7	8	8	6	6
8270	10	8	9	0	7	8	8	6	6
3885	30	36	26	0	27	27	28	28	34
3884	30	36	26	55	12	32	23	44	36
3882	30	9	44	50	45	25	35	44	35
3861	15	15	20	15	15	15	12	16	16
1227	20	20	32	25	10	18	24	15	18
1231	30	40	20	40	30	29	45	28	22
1228	25	33	24	35	18	20	28	12	25
1229	25	33	24	35	18	20	35	15	26
1230	0	0	8	15	5	5	1	8	28
3865	30	36	30	55	48	24	24	36	12
5294	8	8	10	20	7	5	3	14	12
7928	30	10	7	0	0	9	5	0	5
6555	60	107	100	60	100	100	130	110	145
6522	60	123	120	72	195	195	142	60	145
11433	10	18	15	20	12	10	16	7	8
11462	20	10	10	30	12	12	16	4	8
11427	10	28	7	10	6	6	8	6	3
11434	20	38	30	30	16	20	32	24	18
11463	16	25	10	20	12	12	16	11	14
11435	24	36	30	24	16	26	32	16	20
11426	20	15	12	25	20	20	16	8	24
3883	30	24	28	10	31	12	21	28	27

## Segunda Medición

### • Leches Líquidas

SKU	21-04-2009	22-04-2009	23-04-2009	24-04-2009	25-04-2009	26-04-2009	27-04-2009	28-04-2009	29-04-2009	30-04-2009
	stock									
877	72	24	0	0	60	240	240	288	288	264
878	0	0	0	0	0	0	0	0	0	0
10023	24	24	48	24	24	24	24	24	20	24
8354	2400	2400	1920	1440	1584	1536	1000	1080	1080	24
7444	120	120	84	240	150	90	0	12	120	120
9910	48	48	12	48	21	0	0	0	96	96
9938	24	24	10	24	17	24	24	9	48	24
7442	48	60	0	0	0	0	0	0	0	0
5852	0	0	0	0	0	0	0	0	0	0
9914	600	600	540	480	240	408	408	1170	1170	1170
9937	24	24	48	24	29	48	60	60	48	60
5844	0	0	0	0	0	0	0	120	120	120
1260	50	40	40	40	100	81	54	90	90	72
1261	30	20	0	0	70	135	68	90	90	45
6106	50	40	20	20	100	150	120	108	108	108
9961	0	0	0	0	0	0	0	0	0	0
3937	24	12	12	12	10	12	20	16	16	18
9954	240	240	240	240	240	240	60	270	240	240
9958	288	288	200	192	144	144	144	144	72	72
9992	6	6	6	2	0	0	2	2	0	0
9996	6	6	6	3	3	2	4	4	3	4
3938	12	12	12	12	20	12	20	20	24	20
9953	120	96	96	96	96	60	36	78	120	120
9955	60	60	60	60	60	90	36	96	120	120
10007	120	90	90	90	90	78	84	96	180	180
10025	240	60	60	60	60	72	48	96	120	120
3935	0	20	24	24	18	24	24	24	24	24
3955	0	0	0	0	0	0	0	0	0	0
3940	12	12	7	12	0	0	12	16	12	20
3936	18	12	12	12	12	12	12	16	8	8
2501	48	24	12	24	16	2	20	0	0	0
2500	24	12	24	24	24	24	24	32	30	30
3943	36	24	24	24	20	12	20	27	24	7
3939	12	12	10	12	15	12	16	16	8	8
2834	72	60	60	60	66	42	60	48	42	18
9826	60	60	60	36	20	36	48	60	60	60
7035	24	24	20	24	9	24	48	24	24	30
7037	20	72	60	60	72	78	60	180	120	120
3437	24	24	0	24	8	20	24	24	24	30
3439	0	144	120	90	60	180	84	180	60	60
7036	1200	1200	1080	900	420	1440	1440	1440	1440	1440
7038	60	60	120	60	90	120	60	120	120	120

SKU	21-04-2009	22-04-2009	23-04-2009	24-04-2009	25-04-2009	26-04-2009	27-04-2009	28-04-2009	29-04-2009	30-04-2009
	stock									
8377	24	24	24	24	24	24	24	24	24	24
10213	2400	2400	2160	2184	828	1440	1440	936	936	936
10206	1200	1200	1080	840	708	900	900	900	900	900
10204	1000	960	960	1000	990	300	300	1000	1000	1000
10186	10	10	10	10	6	5	0	0	20	8
10187	6	5	0	20	12	7	17	15	20	10
10189	15	15	5	10	6	3	0	0	0	0
10119	5	5	5	10	0	0	0	0	10	10
10122	2	2	0	20	7	6	5	4	10	8
10124	0	0	0	20	6	6	10	5	0	0
10123	0	0	0	0	0	0	0	0	0	0
2829	24	24	36	36	24	24	36	36	36	24
10208	60	48	60	24	52	48	84	60	60	72
10207	72	60	96	48	132	108	60	144	96	108
10205	24	120	0	120	120	120	0	150	150	0
10215	36	48	48	48	24	24	24	24	16	15
10216	72	72	60	0	72	42	30	36	30	0
10210	1800	1800	1440	1200	1968	1200	1200	1200	1200	1200
2837	12	12	12	11	11	12	12	12	12	11
2830	24	24	20	20	18	24	12	24	15	12
10211	48	48	48	120	102	48	48	72	96	96
2452	72	42	60	60	42	24	12	12	12	0
2454	72	72	72	60	60	60	36	36	30	60
9363	24	24	20	20	12	20	6	5	4	4
9364	12	10	10	10	2	24	4	3	36	24
2451	24	12	24	24	30	24	24	0	18	0
9362	0	0	0	0	0	0	0	0	0	0
9366	240	240	360	192	72	180	72	180	72	60
9365	12	12	10	144	13	24	24	24	36	36
9837	240	240	300	600	504	432	432	432	432	432
9824	300	300	360	240	312	240	240	240	360	360
9821	96	96	96	180	144	180	180	180	360	360
9820	96	96	96	180	252	180	180	180	360	360
9942	48	48	48	48	24	60	60	60	60	60
9941	36	48	48	48	18	60	30	30	24	24
9940	48	48	48	48	24	60	60	60	60	60
760	s/dato	s/dato	s/dato	2	5	6	7	4	5	5
758	s/dato	s/dato	s/dato	0	0	5	2	3	20	10
754	s/dato	s/dato	s/dato	3	10	10	2	6	5	5
755	s/dato	s/dato	s/dato	4	10	8	0	0	0	0
759	s/dato	s/dato	s/dato	0	0	0	0	0	0	0
756	s/dato	s/dato	s/dato	0	0	0	0	0	0	0
757	s/dato	s/dato	s/dato	3	10	10	7	10	10	7
7443	0	0	0	0	162	162	180	156	90	90
10121	s/dato	s/dato	s/dato	10	20	10	10	10	10	10

• **Pañales Desechables**

SKU	21-04-2009	22-04-2009	23-04-2009	24-04-2009	25-04-2009	26-04-2009	27-04-2009	28-04-2009	29-04-2009	30-04-2009
	stock									
1097	5	5	5	10	10	10	10	10	10	10
1227	5	10	10	10	10	10	10	15	10	10
1228	1	20	20	20	20	20	15	30	20	5
1229	10	20	20	20	20	20	15	30	5	5
1230	0	0	0	0	0	0	0	0	0	0
1231	40	20	30	20	20	20	20	30	20	20
1232	7	7	7	6	6	6	6	7	5	5
1411	0	0	20	10	10	10	10	10	20	20
1412	0	5	10	10	10	5	10	10	15	15
1413	0	10	10	20	20	20	20	10	25	25
2123	0	5	0	0	0	0	0	0	0	0
2157	15	10	10	30	30	20	20	30	30	30
3861	20	20	20	20	20	20	20	20	30	30
3865	0	0	0	0	0	0	0	0	0	0
3882	7	10	20	15	15	10	10	10	15	15
3883	0	0	10	10	10	5	0	5	15	15
3884	20	20	20	15	15	20	10	10	15	15
3885	15	20	20	15	15	10	4	10	25	25
5325	0	2	10	10	0	10	10	20	15	15
5326	50	20	15	30	30	30	30	20	30	30
6522	0	0	90	90	90	90	90	90	90	90
6555	99	40	90	90	90	90	90	90	90	90
8270	15	20	20	20	20	20	20	10	10	10
8271	0	0	0	0	0	0	0	0	0	0
8862	5	5	5	10	10	10	10	10	10	10
8863	5	5	5	10	10	10	10	10	10	10
8872	4	2	5	5	1	5	1	0	5	5
8873	4	3	0	0	0	0	8	0	5	5
8874	4	3	6	6	3	5	8	10	10	10
9435	5	5	5	10	10	10	10	10	20	20
9439	10	0	10	10	2	2	8	0	7	5
9440	0	10	10	15	3	3	2	0	0	0
9441	0	0	0	0	0	0	0	10	0	0
11426	20	10	30	30	40	30	30	30	30	30
11427	5	5	10	10	10	6	6	6	6	6
11433	20	20	20	20	20	20	20	20	20	20
11434	20	20	20	20	20	10	10	10	10	10
11435	10	20	10	15	20	30	30	30	30	30
11462	10	10	10	20	20	10	10	10	10	10
11463	20	6	10	10	10	15	15	15	15	15

- Margarinas

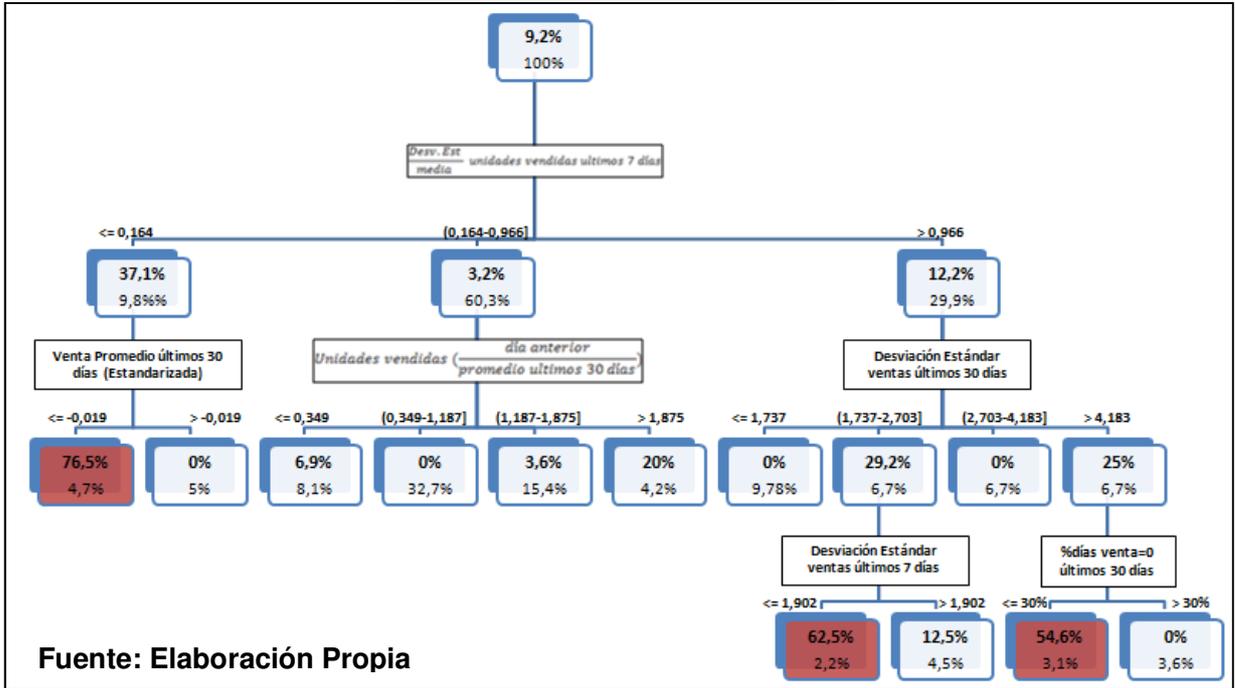
SKU	21-04-2009	22-04-2009	23-04-2009	24-04-2009	25-04-2009	26-04-2009	27-04-2009	28-04-2009	29-04-2009	30-04-2009
	stock									
751	0	4	3	0	0	0	0	0	0	100
6876	30	30	30	15	20	5	10	15	12	12
9720	20	0	0	70	70	70	70	12	50	50
1096	70	70	70	0	0	0	0	0	0	0
3563	50	50	50	50	30	40	30	10	50	50
9737	15	15	15	20	15	15	20	20	15	15
10278	30	30	30	40	40	40	56	56	56	56
10312	50	50	50	50	50	50	92	92	92	92
10271	20	20	20	20	20	40	70	70	70	70
10272	50	50	50	40	40	60	72	72	72	72
10270	60	60	60	60	60	60	42	42	42	42
10264	10	10	10	10	10	11	10	10	10	10
2979	100	100	100	90	90	90	200	100	200	200
9721	12	25	25	50	20	35	50	25	0	0
3562	40	30	30	40	40	40	30	30	25	25
3561	30	30	30	30	30	20	50	15	12	12
11856	9	5	2	11	7	6	16	12	3	3
9732	0	20	20	20	9	18	16	15	20	20
9731	20	20	20	18	12	20	20	20	15	15
6393	10	10	10	9	9	10	13	11	11	11
10292	20	20	20	24	15	17	45	45	30	30
10293	20	20	20	24	24	24	45	45	20	20
5376	0	0	20	15	3	0	15	10	20	20
3324	20	20	20	20	20	20	30	30	20	20
3325	20	20	20	20	6	4	0	0	10	10
2969	20	20	20	20	15	14	10	8	20	20
2311	50	50	50	50	50	50	65	65	65	65
749	6	6	6	12	10	10	1	1	0	30
677	15	10	10	8	6	8	8	8	0	30
10057	100	1000	1000	1000	1000	1000	500	500	500	500
10058	60	60	60	30	10	5	0	0	50	50
10313	40	50	50	50	50	60	52	52	52	52
10269	50	50	50	40	40	25	40	25	40	40
9765	0	20	20	20	7	7	7	6	5	5
6268	15	15	15	15	10	10	10	5	25	25
10065	100	1000	1000	1000	1000	1000	1000	1000	1000	1000
10064	200	200	200	300	300	300	300	300	200	200
10053	0	0	0	0	0	0	0	0	0	0
10063	100	100	100	100	100	100	100	100	100	100
10296	50	70	70	70	70	70	78	78	40	40
4648	50	40	40	50	40	40	35	35	30	30
10274	80	80	80	70	70	70	50	50	50	50
10273	50	40	40	40	40	40	11	21	30	30
10265	25	25	25	25	20	20	15	13	50	50
10059	200	100	0	0	100	60	40	60	0	0
10061	20	20	20	20	20	30	17	20	16	10
3408	60	100	100	400	400	400	400	400	400	400

- Leches en polvo**

SKU	21-04-2009	22-04-2009	23-04-2009	24-04-2009	25-04-2009	26-04-2009	27-04-2009	28-04-2009	29-04-2009	30-04-2009
	stock									
5108	10	10	7	10	10	0	0	0	20	20
4543	10	10	10	10	10	15	15	15	15	15
9964	10	10	12	10	10	10	10	10	10	10
4647	10	15	15	15	15	10	15	15	10	10
9968	70	50	50	50	50	50	50	50	15	15
4824	6	15	15	15	15	10	15	15	15	15
10030	50	70	30	30	30	30	30	30	15	15
9966	15	15	15	15	15	15	15	15	15	15
9965	0	0	0	0	0	0	0	0	0	0
5732	10	10	10	10	10	4	8	8	6	6
5733	10	10	10	10	10	15	10	10	10	10
996	0	0	0	0	0	0	0	0	0	0
2891	10	20	20	20	20	20	20	20	10	10
2827	20	20	20	20	20	30	20	20	20	20
2892	15	15	10	10	10	10	10	10	10	10
2893	5	10	10	10	10	15	10	10	10	10
4782	6	6	10	10	10	10	15	15	10	10
2556	10	20	15	10	10	15	6	6	4	4
2471	20	20	15	20	20	30	15	15	30	30
2472	4	3	3	15	15	15	20	20	20	20
11776	20	10	10	15	5	4	4	4	15	15
12003	20	20	20	18	18	20	20	20	20	20
4857	6	6	6	6	10	6	5	5	10	10
7499	30	30	30	40	40	40	40	40	30	30
3618	15	15	15	15	15	15	15	15	15	15
3616	15	15	15	15	15	15	15	15	15	15
3613	10	10	10	10	10	10	10	10	10	10
1385	8	8	10	8	8	6	6	6	20	20
1386	25	20	20	20	20	20	20	20	20	20
11775	4	4	4	2	4	4	15	15	15	15
595	0	0	0	0	0	0	0	0	0	0
711	0	0	0	0	0	0	0	0	0	0
1627	5	5	5	5	10	5	10	10	10	10
1626	5	5	5	5	10	10	10	10	10	10
10201	20	20	20	20	20	100	100	100	100	100
6753	7	10	10	10	10	10	5	5	10	10
3615	20	20	20	20	20	20	10	10	10	10
7447	20	20	20	20	20	20	15	15	15	15
5981	15	15	15	15	15	15	7	7	7	7
7446	20	20	20	20	6	6	15	15	15	15

### 9.3 Anexo 3: Modelos Margarinas y Leche en polvo

**Diagrama modelo Margarinas**



**Diagrama modelo Leches en polvo**

